

UNIVERSIDADE FEDERAL DO RIO GRANDE
CENTRO DE CIÊNCIAS COMPUTACIONAIS
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO
CURSO DE MESTRADO EM ENGENHARIA DE COMPUTAÇÃO

Dissertação de Mestrado

**Metodologia para Análise EEG Utilizando Árvores de
Decisão: Um Estudo de Caso para Reconhecimento de
Objetos Espaciais**

Narúsci dos Santos Bastos

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Computação da Universidade Federal do Rio Grande, como requisito parcial para a obtenção do grau de Mestre em Engenharia de Computação

Orientador: Prof. Dr. Cleo Zanella Billa
Co-orientador: Prof. Dr^a Diana F. Adamatti

Rio Grande, 2017



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DO RIO GRANDE
CENTRO DE CIÊNCIAS COMPUTACIONAIS
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO
CURSO DE MESTRADO EM ENGENHARIA DE COMPUTAÇÃO

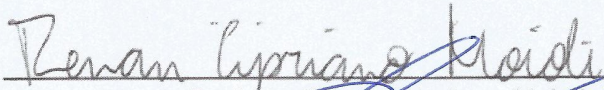
ATA DE SESSÃO DE DEFESA DE DISSERTAÇÃO DE MESTRADO

Ata nº 07/2017

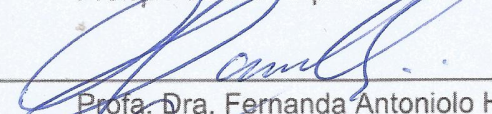
Na data de 30 de março de 2017 às 14 horas, ocorreu a Sessão de Defesa de Dissertação de Mestrado de Narúsci dos Santos Bastos, que apresentou a dissertação intitulada "Metodologia para análise EEG utilizando árvores de decisão: um estudo de caso para reconhecimento de objetos espaciais", realizada sob a orientação do Prof. Dr. Cleo Zanella Billa e co-orientação da Profa. Dra. Diana Francisca Adamatti. A banca examinadora foi constituída pelo Prof. Dr. Renan Cipriano Moiola (Instituto Internacional de Neurociências Edmond e Lily Safra), Profa. Dra. Fernanda Antoniolo Hammes de Carvalho (FURG) e o Prof. Dr. Leonardo Ramos Emmendorfer (FURG), sob a presidência do orientador. Após a apresentação do trabalho, a banca arguiu o candidato e, a seguir, deliberou pela

- (X) aprovação da Dissertação
- () aprovação da Dissertação, sugerindo modificações no texto
- () reprovação da Dissertação

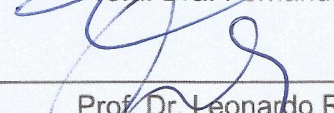
Rio Grande, 30 de março de 2017



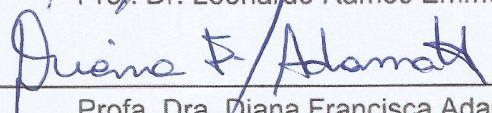
Prof. Dr. Renan Cipriano Moiola



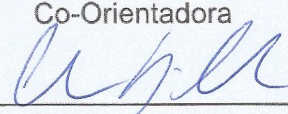
Profa. Dra. Fernanda Antoniolo Hammes de Carvalho



Prof. Dr. Leonardo Ramos Emmendorfer



Profa. Dra. Diana Francisca Adamatti
Co-Orientadora



Prof. Dr. Cleo Zanella Billa
Orientador

Ficha catalográfica

B327m Bastos, Narúsci dos Santos.

Metodologia para análise EEG utilizando árvores de decisão: um estudo de caso para reconhecimento de objetos espaciais / Narúsci dos Santos Bastos. – 2017.

92 p.

Dissertação (mestrado) – Universidade Federal do Rio Grande – FURG, Programa de Pós-graduação em Engenharia de Computação, Rio Grande/RS, 2017.

Orientador: Dr. Cleo Zanella Billa.

Coorientadora: Dr^a. Diana Francisca Adamatti.

1. Mineração de dados 2. Árvores de decisão 3. Brain Machine Interface
4. Deficiência Visual 5. Eletroencefalograma I. Billa, Cleo Zanella
II. Adamatti, Diana Francisca III. Título.

CDU 004.6

Dedico este trabalho a Deus, minha família e aos meus mestres

*“Aprenda como se você fosse viver para sempre.
Viva como se você fosse morrer amanhã.”*

ISIDORO DE SEVILHA

RESUMO

BASTOS, Narúsci dos Santos. **Metodologia para Análise EEG Utilizando Árvores de Decisão: Um Estudo de Caso para Reconhecimento de Objetos Espaciais**. 2017. 95 f. Dissertação (Mestrado) – Programa de Pós-Graduação em Computação. Universidade Federal do Rio Grande, Rio Grande.

O Eletroencefalograma (EEG) baseia-se em registros de atividade elétrica cerebral medidas através do escalpo, e é comumente utilizado para estudos e exames neurológicos. Atualmente tem sido usado em conjunto com sistemas BMI (*Brain Machine Interface*), que permitem a comunicação entre um indivíduo e um equipamento externo, como um computador, somente através do estímulo cerebral, sem que haja qualquer movimento muscular. Estas ferramentas normalmente apresentam os dados em forma de gráficos ou mapas topográficos, para monitoramento ou análise das atividades cerebrais. Sendo assim, propõem-se uma metodologia de análise EEG através da mineração de dados, que trata de extrair conhecimento de uma grande base de dados. Neste trabalho é apresentado um estudo de caso utilizando sinais EEG de indivíduos cegos e videntes durante a execução de uma atividade que estimulou a habilidade espacial. A fim de verificar a hipótese de que videntes e cegos utilizam áreas diferentes do cérebro para visualizar objetos espaciais. Em videntes, prioritariamente o lobo occipital é ativado. Em cegos, prioritariamente, o lobo parietal é ativado. Foi feito um experimento e através dos dados dos sinais cerebrais gravados foram aplicadas técnicas de árvores de decisão para compreender as principais áreas cerebrais envolvidas durante a execução da tarefa de reconhecimento de objetos. Os resultados obtidos sugerem que a hipótese é verdadeira mostrando que os sujeitos videntes e cegos ativam áreas cerebrais distintas.

Palavras-chave: Mineração de dados, Árvores de decisão, Brain Machine Interface, Deficiência Visual, Eletroencefalograma.

ABSTRACT

BASTOS, Narúsci dos Santos. **Methodology for EEG Analysis Using Decision Trees: A Case Study for Recognition of Spatial Objects**. 2017. 95 f. Dissertação (Mestrado) – Programa de Pós-Graduação em Computação. Universidade Federal do Rio Grande, Rio Grande.

The Electroencephalogram (EEG) is based on records of brain electrical activity measured through the scalp, and is commonly used for studies and neurological examinations. It has now been used in conjunction with BMI (Brain Machine Interface) Systems, which allow the communication of an individual and external equipment, such as a computer, through brain stimulation, without any muscle movement. These tools typically present data in the form of graphs or topographic maps for monitoring or analysis of brain activities. In this work, a methodology of EEG analysis is proposed through data mining, which tries to extract knowledge from a large database. This paper presents a case study using EEG signals from blind and sighted individuals during the execution of an activity that stimulated spatial ability. In order to verify the hypothesis that sighted use the sense of sight, even with blindfold, and blind people use the sense of touch to identify spatial geometric objects. An experiment was made and through the data of the recorded brain signals, decision tree techniques were applied to understand the main areas involved in the brain activities during the execution of the recognition task. The results suggest that the hypothesis is true confirming that blind and sighted subjects activate different brain areas.

Keywords: Data Mining, Decision trees, Brain Machine Interface, Visual Impairment, Electroencephalogram.

LISTA DE FIGURAS

1	Estrutura do neurônio (STERNBERG; OSÓRIO, 2000).	19
2	Células da glia do sistema nervoso central (SILVERTHORN, 2010) .	20
3	Divisão dos hemisférios cerebrais e suas funções (LENT, 2008). . . .	22
4	Os lobos dos hemisférios cerebrais: parietal, occipital, temporal e frontal (GAZZANIGA; HEATHERTON; VERONESE, 2005).	23
5	Funções relacionadas as áreas cerebrais (LENT, 2004)	24
6	Ilustração dos eletrodos para aquisição de sinais de forma não-invasiva usando EEG, no sistema 10-20 (SOCIETY et al., 2006).	26
7	Processo de KDD (TAN et al., 2006)	33
8	Árvore de Decisão - Exemplo de construção.	35
9	Matriz de confusão para duas classes (TAN et al., 2006).	36
10	Metodologia proposta.	44
11	Mapa dos eletrodos Acticap de acordo com o padrão internacional 10-20 (Acticap).	48
12	Interface de desenvolvimento do Openvibe Designer - Nível de utilização do Autor.	50
13	Área de monitoramento - Nível de utilização do Operador (PRADA, 2010).	51
14	Cenário handball - Nível de utilização do Usuário (PRADA, 2010). .	51
15	Sequência dos objetos utilizados na coleta. Cada letra seguida de um número representa uma das combinações possíveis para os três objetos.	53
16	Momento em que os objetos foram colocados na mão de um dos indivíduos.	54
17	Autômato utilizado para a gravação e monitoramento dos sinais cerebrais.	55
18	Autômato para transformar os dados GDF em CSV.	56
19	Módulo Temporal Filter.	56
20	Módulo Simple DSP.	57
21	Ilustração dos dados após a limpeza dos dados e adição das classes. .	58
22	Modelo de arquivo do formato ARFF.	58
23	Modelo de arquivo do formato ARFF.	59
24	Configuração da tarefa de classificação utilizando o algoritmo J48. . .	60

25	Representação gráfica dos dados EEG de um vidente. Os valores do eixo Y correspondem ao sinal elétrico dos canais cerebral. Foram acrescentados valores de 1000 a 32000 nos sinais elétricos para permitir que cada canal ficasse em uma escala diferente como, por exemplo, os valores obtidos do canal 1 (FP1) acrescidos 1000; canal 2 (Fz) acrescidos de 2000; canal 3 (F3) acrescidos de 3000 e assim sucessivamente até o canal 32 (FP2) que foram acrescidos 32000. Já o eixo X diz respeito aos milissegundos.	61
26	Representação gráfica dos dados EEG de um cego. Os valores do eixo Y correspondem ao sinal elétrico dos canais cerebral. Foram acrescentados valores de 1000 a 32000 nos sinais elétricos para permitir que cada canal ficasse em uma escala diferente como, por exemplo, os valores obtidos do canal 1 (FP1) acrescidos 1000; canal 2 (Fz) acrescidos de 2000; canal 3 (F3) acrescidos de 3000 e assim sucessivamente até o canal 32 (FP2) que foram acrescidos 32000. Já o eixo X diz respeito aos milissegundos.	62
27	Hierarquia dos testes realizados com a ferramenta Weka.	63
28	Configuração padrão dos parâmetros do algoritmo J48.	65
29	Número de instâncias por classe - Sujeito 1. No gráfico de barras o eixo x quando selecionado mostra o valor do atributo escolhido; eixo Y apresenta o número de instâncias de cada classe. (1) representa o número de instâncias da classe cubo; (2) o número de instâncias da classe paralelogramo; (3) número de instâncias da classe pirâmide.	70
30	Árvore gerada a partir do algoritmo J48 - Sujeito 1. Os números circulados em vermelho representam os possíveis caminhos para a classificação de cada tarefa.	71
31	Número de instâncias por classe - Sujeito 2. No gráfico de barras o eixo x quando selecionado mostra o valor do atributo escolhido; eixo Y apresenta o número de instâncias de cada classe. (1) representa o número de instâncias da classe cubo; (2) o número de instâncias da classe paralelogramo; (3) número de instâncias da classe pirâmide.	73
32	Árvore gerada a partir do algoritmo J48 - Sujeito 2. Os números circulados em vermelho representam os possíveis caminhos para a classificação de cada tarefa.	74
33	Número de instâncias por classe - Sujeito 3. No gráfico de barras o eixo x quando selecionado mostra o valor do atributo escolhido; eixo Y apresenta o número de instâncias de cada classe. (1) representa o número de instâncias da classe cubo; (2) o número de instâncias da classe paralelogramo; (3) número de instâncias da classe pirâmide.	75
34	Árvore gerada a partir do algoritmo J48 - Sujeito 3. No gráfico de barras o eixo x quando selecionado mostra o valor do atributo escolhido; eixo Y apresenta o número de instâncias de cada classe. (1) representa o número de instâncias da classe cubo; (2) o número de instâncias da classe paralelogramo; (3) número de instâncias da classe pirâmide.	76

35	Número de instâncias por classe - Sujeito 4. No gráfico de barras o eixo x quando selecionado mostra o valor do atributo escolhido; eixo Y apresenta o número de instâncias de cada classe. (1) representa o número de instâncias da classe cubo; (2) o número de instâncias da classe paralelogramo; (3) número de instâncias da classe pirâmide. . .	78
36	Árvore gerada a partir do algoritmo J48 - Sujeito 4. Os números circulados em vermelho representam os possíveis caminhos para a classificação de cada tarefa.	79

LISTA DE TABELAS

1	Resumo dos trabalhos apresentados por RANGEL et al. (2010).	33
2	Porcentagem da acurácia dos classificadores em cada conjunto de dados.	40
3	Porcentagem da acurácia dos classificadores	41
4	Porcentagem da acurácia dos classificadores em diferentes conjunto de dados (WANG et al., 2009).	42
5	Síntese dos trabalhos relacionados	43
6	As cores correspondentes às impedâncias - valores padrão	49
7	Áreas cerebrais, eletrodos e as funções correspondentes. As linhas marcadas em negrito indicam os lobos, canais e funções referentes a hipótese deste trabalho.	49
8	Marcação do tempo em que um dos sujeito manipulou os objetos de uma amostra. A disposição dos objetos foi dada de acordo com a lista de sequências da seção 7.2.2 item 7.	57
9	Métodos implementados pelo Weka	59
10	Dados dos modelos gerados através dos testes realizados - Sujeito 1 .	66
11	Dados dos modelos gerados através dos testes realizados - Sujeito 2 .	67
12	Dados dos modelos gerados através dos testes realizados - Sujeito 3 .	68
13	Dados dos modelos gerados através dos testes realizados - Sujeito 4 .	69
14	Caminhos apresentados na árvore gerada para a classificação das tarefas - Sujeito 1	72
15	Caminhos apresentados na árvore gerada para a classificação das tarefas	74
16	Caminhos apresentados na árvore gerada para a classificação das tarefas	77
17	Caminhos apresentados na árvore gerada para a classificação das tarefas.	79
18	Áreas cerebral que estavam presente nos modelos de cada indivíduo. A letra X representa as áreas que apresentaram os canais nas ramificações das árvores geradas e NDA significa que a área não apresentou canais nas ramificações das árvores dos modelos gerados.	80

LISTA DE ABREVIATURAS E SIGLAS

ANN	Artificial Neural Network
BMI	Brain Machine Interface
CT	Computerized Tomography
SCV	Command-Separated Value
DT	Decision Tree
EEG	Electroencephalography
EMG	Electromyogram
GDF	Graph Data Format
KDD	Knowledge Discovery Database
KFD	Kernel Fisher Discriminant
KNN	K-Nearest Neighbor
LDA	Linear Discriminant Analysis
LOC	Lateral Occipital Complex
LVQ	Learning Vector Quantization
MD	Mineração de Dados
MEG	Magnetoencephalography
MLP	Multi-Layer perceptron
MRI	Magnetic Resonance Imaging
QDA	Quadratic Discriminant Analysis
PA	Percentage Accuracy
PCA	Principal Component Analysis
PET	Positron Electron Tomography
SNC	Sistema Nervoso Central
SNP	Sistema Nervoso Periférico
SVM	Support Vector Machine
TOR	Tactile Object Recognition

SUMÁRIO

1	INTRODUÇÃO	15
1.1	Motivação	16
1.2	Objetivo Geral	17
1.3	Objetivos Específicos	17
1.4	Organização do Texto	17
2	REFERENCIAL TEÓRICO	18
2.1	Sistema Nervoso	18
2.1.1	O Cérebro Humano	20
2.2	Sistemas BMI e Eletroencefalograma	24
2.2.1	Técnicas de captura de Sinais	25
2.2.2	Eletroencefalograma e Sinais	25
2.3	Os sentidos do corpo humano	27
2.4	Deficiência Visual	29
2.5	Deficiência Visual e os Sentidos	30
2.6	Sistemas BMI e Deficiência Visual	32
2.7	Mineração de Dados e Descoberta de Conhecimento	33
2.7.1	Aprendizado supervisionado	34
2.7.2	Aprendizado não-supervisionado	37
2.8	Considerações finais do capítulo	37
3	TRABALHOS RELACIONADOS	39
3.1	Comparação de Técnicas de aprendizagem para a classificação de EEG	39
3.1.1	Aplicação de técnicas de aprendizagem automática para classificação de emoções humanas com sinais de EEG	39
3.1.2	Avaliação de ANN, LDA e Árvore de Decisão para Sistema BMI baseado em EEG	40
3.1.3	Comparação de diferentes métodos de classificação para BMI baseado em EEG	41
3.2	Considerações finais do capítulo	42
4	METODOLOGIA PROPOSTA	44
5	ESTUDO DE CASO	47
5.1	Definição do Problema	47
5.2	Coleta dos Dados	48
5.2.1	Ferramentas para coleta de sinais cerebrais	48
5.2.2	Coletando os dados	51

5.3	Pré-processamento	55
5.3.1	Limpeza dos dados	57
5.3.2	Transformação dos dados	58
5.4	Escolha da Técnica	59
5.4.1	Gráficos gerados	60
5.5	Execução do Algoritmo J48	63
5.5.1	Modelos gerados	70
5.6	Análise e Discussão dos dados	79
6	CONSIDERAÇÕES FINAIS	81
	REFERÊNCIAS	84
	ANEXO 1	89
	ANEXO 2	94

1 INTRODUÇÃO

A cegueira é uma alteração grave ou total de uma ou mais funções elementares da visão que afeta de modo irremediável a capacidade de perceber cor, tamanho, distância, forma, posição ou movimento em um campo mais ou menos abrangente (SÁ; CAMPOS; SILVA, 2007). A expressão deficiência visual refere-se ao espectro que vai da cegueira até a visão subnormal, para isso existem dois tipos de deficientes visuais: cegos congênitos (nascidos sem capacidade visual) e cegos adquiridos. Cegos congênitos possuem o sistema cognitivo, desde o nascimento, constituído com base nos outros sentidos e sem referência a elementos visuais. Já os cegos adquiridos apresentam transformações cognitivas relacionadas à redução da eficiência de habilidades e hábitos anteriores (KASTRUP, 2007).

O sistema nervoso é fundamentalmente empregado para a recepção, armazenamento e liberação de informação, é um sistema complexo, constituído de diversas estruturas e órgãos especializados em diferentes funções (EYZAGUIRRE, 1977). Esses sistemas realizam uma de três funções gerais: os sistemas sensoriais, que representam as informações sobre o estado do organismo e do ambiente, os sistemas motores, organizam e geram as ações, e os sistemas associativos. Sabe-se que indivíduos que nascem ou perdem a capacidade visual tem suas capacidades de orientação, movimentação no espaço com segurança e independência comprometidas (GIL, 2000). Para isso, é de extrema importância estimular as capacidades dos outros órgãos do sentido como: tato, audição, olfato e paladar, pois é a partir dos outros sentidos que o indivíduo irá conseguir se adaptar ao mundo.

Os sistemas BMI (*Brain Machine Interface*) surgem como ferramentas que permitem uma forma de comunicação baseada em atividade neural gerada pelo cérebro, sem exigir que haja outros estímulos, como movimentos musculares criados pelo cérebro (MACHADO et al., 2009). O EEG (Eletroencefalograma) baseia-se em registros de atividade elétrica cerebral que são medidas na superfície do escalpo. Esses sistemas apresentam alta resolução temporal que é capaz de medir a atividade a cada milésimo de segundo, gerando uma grande quantidade de dados.

A Mineração de Dados (MD) trata da extração de conhecimento de grandes volumes de dados (DEVÊZA, 2011). De acordo com TAN et al. (2006) é um processo geral

de conversão de dados brutos em informações úteis. A MD apresenta diversas técnicas, como: extração de regras de associação, agrupamento (Clustering), classificação e regressão. Neste trabalho utilizamos a técnicas de classificação dando ênfase em Árvores de Decisão (ADs).

As ADs consistem em classificadores que apresentam uma estrutura de árvore condicional, em que cada nó específica um teste que irá ser realizado em um único atributo, são utilizadas como ferramentas de classificação e previsão de dados. As ADs geram regras que explicam o comportamento dos dados e um modelo de classificação (SILVEIRA, 2013). Além disso os modelos gerados são de fácil interpretação.

1.1 Motivação

O cérebro humano é uma estrutura multifacetada, capaz de armazenar grandes volumes de informações, transformando-as, aprendendo e tomando decisões complexas, nos provendo a capacidade de descobirmos e influenciarmos o mundo ao nosso redor (COSENZA; GUERRA, 2011). Neste sentido, o ramo da neurociência é uma ciência interdisciplinar que une distintas áreas do conhecimento com o intuito de interpretar o sistema nervoso como um todo, assim, diferentes estudos baseados em sistemas BMI são publicados e aplicados com variados propósitos como proporcionar melhor qualidade de vida a pessoas com problemas motores graves (PRADA, 2010), reabilitação de pacientes vítimas de AVC (Acidente Vascular Cerebral) (MACHADO et al., 2009), movimentação de sistemas robóticos (NASCIMENTO et al., 2010), classificação de objetos de ensino relacionando o nível de atenção do estudante (VELLOSO; PEREIRA, 2014), além de que, em conjunto com equipamentos EEG permite a análise da atividade cerebral através de imagens e mapas topográficos 2d e 3d e análises gráficas.

A fim de buscar uma forma de análise da atividade cerebral que fosse diferente da análise gráfica, procurou-se analisar dados EEG através de árvore de decisão. A árvore de decisão apresenta como uma das suas características mais importantes a facilidade na interpretação das regras inferidas através delas (ADAMATTI; SILVEIRA; CARVALHO, 2016).

Deficientes visuais tem suas capacidades de orientação, movimentação no espaço com segurança e independência comprometidas (GIL, 2000). Sendo assim é muito importante estimular as capacidades dos outros órgãos do sentido, pois é a partir dos outros sentidos que o indivíduo irá se adaptar ao mundo (SILVEIRA NUNES; LOMÔNACO, 2008). A partir de então surge o questionamento: videntes e cegos ativam as mesmas áreas cerebrais durante o reconhecimento de um objeto espacial? Uma vez sabendo que pessoas que possuem a capacidade de enxergar, tem o lobo occipital responsável pela capacidade da visão, qual área é responsável pela atividade espacial em um deficiente visual?

Neste contexto, este trabalho apresenta um estudo de caso com tarefas que exploram

a habilidade espacial de indivíduos cegos e videntes.

Alguns trabalhos discutem esse tipo de abordagem, porém, utilizam técnicas de mineração de dados para classificação. No entanto, este trabalho não envolve a classificação dos dados, e sim uma forma de visualizar e interpretar os dados através de árvores de decisão. A literatura pesquisada não apresenta trabalhos semelhantes.

1.2 Objetivo Geral

Apresentar uma metodologia para o uso de árvores de decisão como meio de compreender a atividade cerebral a partir de um estudo de caso com o reconhecimento de objetos espaciais.

1.3 Objetivos Específicos

1. Estudo da neurociência;
2. Exploração de ferramentas para análise de dados EEG;
3. Definição de um protocolo para coleta de sinais cerebrais;
4. Coletar sinais EEG com o ActiChamp, ferramenta utilizada;
5. Realizar o pré-processamento dos dados;
6. Definição de uma metodologia para a análise de sinais cerebrais utilizando árvores de decisão;
7. Análise e validação da metodologia utilizada.

1.4 Organização do Texto

O restante do texto está organizado da seguinte forma: o capítulo 2 apresenta a fundamentação teórica sobre o sistema nervoso, sistemas BMI, sentidos do corpo humano, deficiência visual e mineração de dados; trabalhos que estudam a utilização de algoritmos de mineração de dados e sistemas BMI ou EGG são analisados no capítulo 3; a metodologia proposta é apresentada no capítulo 4; o estudo de caso está presente no capítulo 5, juntamente com a análise e discussão dos dados. Por fim a conclusão no capítulo 6.

2 REFERENCIAL TEÓRICO

2.1 Sistema Nervoso

O Sistema nervoso é fundamentalmente empregado para a recepção, armazenamento e liberação de informação. Segundo EYZAGUIRRE (1977) este sistema é complexo com diversas estruturas e órgãos especializados com diferentes funções. O conhecimento do sistema nervoso baseia-se principalmente na detecção, propagação e transmissão dos sinais elétricos através de diferentes canais - os nervos. Para EYZAGUIRRE (1977), quando se refere à estes processos, fala-se de “ impulsos nervosos ”. O impulso nervoso é um sinal elétrico que é conduzido a uma velocidade bem inferior à da eletricidade, esta condução ocorre através de uma série de eventos químicos e físicos. Além disso, a propagação do impulso requer estruturas anatômicas adequadas, sem as quais o processo torna-se impraticável (EYZAGUIRRE, 1977).

O sistema nervoso humano inicia seu desenvolvimento nas primeiras semanas de vida embrionária, sob a forma de um minúsculo tubo, cuja a parede é formada por células-tronco, que irão dar origem a todos os neurônios e também a maior parte das células auxiliares, as células gliais (COSENZA; GUERRA, 2011). PURVES et al. (2001) afirma que “os estudos histológicos de Cajal, de Golgi e outros sucessores, levaram ao consenso de que as células do sistema nervoso podem ser divididas em duas grandes categorias: células nervosas (neurônios) e células de suporte ou sustentação chamadas de células neurogliais (glia)”.

SILVERTHORN (2010) destaca que o sistema nervoso é dividido em duas partes: o sistema nervoso central (SNC), que consiste no encéfalo e na medula espinal; o sistema nervoso periférico (SNP) que se resume em neurônios aferentes (sensoriais) e neurônios eferentes. O sistema nervoso central é um centro que integra os reflexos neurais, nesse contexto, os neurônios do SNC unem as informações que chegam a partir do ramo aferente do SNP e determinam se uma resposta é necessária (SILVERTHORN, 2010).

Os neurônios transmitem sinais elétricos de um local para o outro no sistema nervoso, sendo especializados na sinalização elétrica em longas distância (STERNBERG; OSÓRIO, 2000)(PURVES et al., 2001). A maior concentração de neurônios se encontra

no neocórtex cerebral, que é a parte do cérebro associada à cognição complexa (STERNBERG; OSÓRIO, 2000). Os neurônios tendem a se organizar na forma de redes e se interligam, trocando informações e promovendo vários tipos de processamento de informação. Os neurônios variam em sua estrutura, mas normalmente apresentam quatro partes básicas: corpo celular (soma), dendritos, um axônio e feixes terminais (STERNBERG; OSÓRIO, 2000), as partes são dispostas conforme mostrado na Figura 1, que apresenta a estrutura de um neurônio.

Os dendritos são o alvo primário de sinais de entradas sinápticas, informações vinda de outros neurônios. A soma ou corpo celular integra essas informações (PURVES et al., 2001)(STERNBERG; OSÓRIO, 2000). As informações conduzidas pelas sinapses sobre os dendritos neuronais são integradas e lidas na origem do axônio, a porção da célula nervosa que é especializada em conduzir sinais elétricos, consiste em uma única extensão a partir do corpo celular do neurônio que pode viajar desde poucas centenas de micrômetros até muito além, dependendo do tipo de neurônio e da espécie (PURVES et al., 2001). Existem dois tipos de axônios: os revestidos com mielina e os não revestidos. A mielina é uma substância branca gordurosa que envolve (como uma capa) alguns axônios do sistema nervoso e é responsável por parte da massa branca apresentada no cérebro. Esse revestimento, isola e protege o axônio mais longos de interferências elétricas de outros neurônios, além disso acelera o transporte da informação (STERNBERG; OSÓRIO, 2000).




Figura 1: Estrutura do neurônio (STERNBERG; OSÓRIO, 2000).

As células gliais, Figura 2, possuem funções essenciais no encéfalo em desenvolvimento e no adulto. Além disso, contribuem para a regeneração do sistema nervoso lesionado. De acordo com PURVES et al. (2001), essas células, em alguns casos, podem proporcionar um novo crescimento de neurônios com lesão e, em outros, não permitir que haja regeneração (PURVES et al., 2001). SILVERTHORN (2010) considera as células gliais como os “Heróis não reconhecidos”, pois de acordo com o autor, ainda que essas células não tenham participação direta na transmissão dos sinais elétricos por

longa distância, elas se comunicam com os neurônios e fornecem um importante suporte físico e bioquímico. As células da glia fornecem estabilidade estrutural para os neurônios enrolando-se neles (como uma capa). As células de Schwann, um tipo de célula glia do SNP, e os oligodendrócitos, tipo de célula glia do SNC, sustentam e isolam o axônio, formando a mielina (SILVERTHORN, 2010).




Figura 2: Células da glia do sistema nervoso central (SILVERTHORN, 2010)

2.1.1 O Cérebro Humano

Segundo COSENZA; GUERRA (2011), a parte mais importante do sistema nervoso é o cérebro, pois é através dele que obtemos consciência das informações que chegam pelos órgãos dos sentidos e processamos essas informações, comparando-as com nossas vivências e expectativas, sendo capaz de modificar nossos comportamentos e aprender. Há também os processos mentais como o pensamento, capacidade de julgamento e a atenção que são resultados do seu funcionamento (COSENZA; GUERRA, 2011). SILVERTHORN (2010), em seus estudos, diz que “os circuitos mais complexos são os do encéfalo, nos quais bilhões de neurônios são conectados em redes intrincadas, que convergem e divergem, criando um número infinito de vias possíveis”. O autor afirma ainda que, a sinalização dentro dessas vias são responsáveis pela produção do pensamento, linguagem, sentimento, aprendizado e a memória.

O cérebro humano é dividido em dois hemisférios, direito e esquerdo (Figura 3), os quais apresentam muitas dobraduras denominadas circunvoluções, giros ou folhas, que são separados por sulcos ou fissuras. Inicialmente, entendia-se que existia um hemisfério dominante e outro dominado. No entanto, passado um século, este conceito tornou-se ultrapassado, e que na verdade existem dois hemisférios especializados. Sendo assim,

cada hemisfério é responsável por um conjunto de funções, que acabam por trabalhar em conjunto (COSENZA; GUERRA, 2011).

Para GAZZANIGA; HEATHERTON; VERONESE (2005), no que diz respeito aos hemisférios, “este é o local de todos os pensamentos, percepções detalhadas e consciência, em resumo tudo o que nos torna humanos”. Uma estrutura muito grande que proporciona a cultura e comunicação complexa.

As especialidades dos hemisférios podem ser bem diferentes (Figura 3), mas dificilmente essa especialidade possui exclusividade funcional, de acordo com COSENZA; GUERRA (2011), o hemisfério esquerdo é normalmente responsável pelo processamento da linguagem, que na maioria das pessoas é muito mais competente que o hemisfério direito na sua percepção e expressão, havendo algumas exceções, como indivíduos canhotos que eventualmente podem ter as áreas da linguagem localizadas no hemisfério direito. Para LENT (2004), o hemisfério esquerdo é também melhor na realização mental de cálculos matemáticos, no comando da escrita e na compreensão dela através da leitura. Já o hemisfério direito é melhor na percepção de sons musicais e reconhecimento de faces.

Apesar de o hemisfério esquerdo ser melhor na realização mental de cálculos matemáticos, o hemisfério direito é melhor na detecção de relações espaciais, particularmente nas relações métricas, quantificáveis, que são úteis para nosso deslocamento. O hemisfério esquerdo participa dessa função, mas com a habilidade no reconhecimento de relações espaciais e categoriais qualitativas. Embora cada hemisfério tenha sua especialidade, eles muitas vezes se complementam, assim como o hemisfério direito é especialmente capaz de identificar categorias gerais de objetos e seres vivos, o esquerdo é que detecta as categorias específicas (COSENZA; GUERRA, 2011)(LENT, 2008).

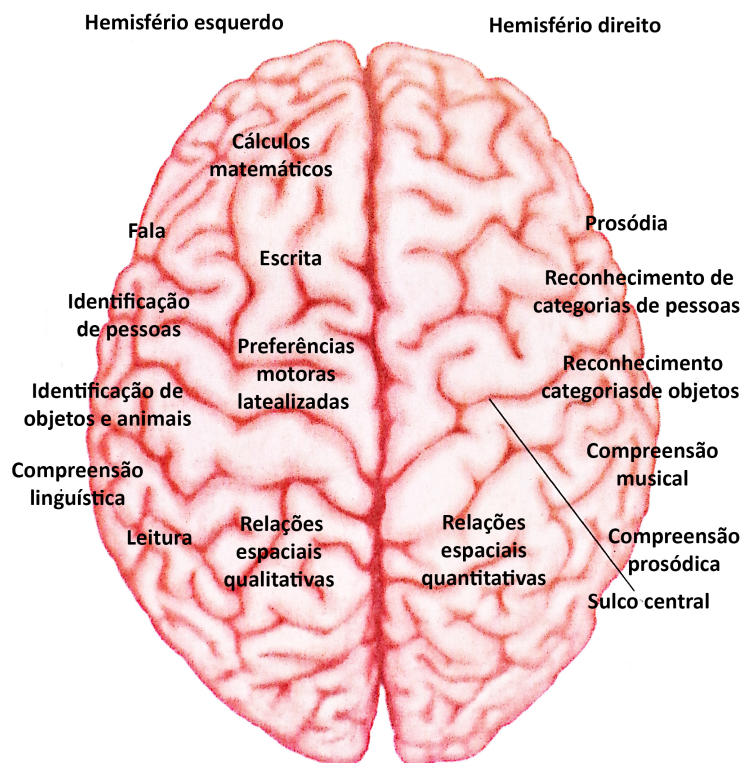


Figura 3: Divisão dos hemisférios cerebrais e suas funções (LENT, 2008).

Contrapondo com a complexidade do padrão de giros do encéfalo humano, os anatomistas geralmente agrupam em grandes regiões, chamadas lobos (Figura 4), em que os limites nem sempre são precisos, mas transmitem uma ideia inicial de localização regional (LENT, 2008). Os lobos são cinco: quatro visíveis externamente e um posicionado no interior dos grandes sulcos do encéfalo, o sulco lateral (LENT, 2008). Os quatro lobos visíveis são: o frontal que é relacionado com a frente; o parietal que se localiza sob o osso craniano do mesmo nome; o temporal relacionado com a têmpora; e o occipital sob o osso craniano homônimo. O lobo da ínsula que só pode ser visto no momento em que se abre o sulco lateral (LENT, 2008) (GAZZANIGA; HEATHERTON; VERONESE, 2005). Existem muitas outras estruturas presentes no SNC, as quais muitas vezes situam-se no seu interior, porém para este trabalho importa somente compreender as quatro grandes áreas, os quatro lobos.




Figura 4: Os lobos dos hemisférios cerebrais: parietal, occipital, temporal e frontal (GAZZANIGA; HEATHERTON; VERONESE, 2005).

Cada uma dessas regiões apresentam funções especializadas (Figura 5). O lobo occipital é fundamentalmente envolvido com o sentido da visão, está dividido em múltiplas áreas visuais distintas, na qual a maior é o córtex visual primário. O parietal é parcialmente dedicado ao sentido do tato, agrupa funções de sensibilidade corporal e reconhecimento espacial. O lobo temporal contém o córtex auditivo primário, processa dados auditivos, aspectos elaborados da visão, a compreensão linguística e alguns aspectos da memória. Finalmente, o lobo frontal, que é essencial para o planejamento de ações cognitivas, memória e movimento (LENT, 2004), (GAZZANIGA; HEATHERTON; VERONESE, 2005).




Figura 5: Funções relacionadas as áreas cerebrais (LENT, 2004)

2.2 Sistemas BMI e Eletroencefalograma

Os sistemas BMI consistem em ferramentas que permitem um método de comunicação baseado em atividade neural gerada pelo cérebro, sem que haja a necessidade de qualquer outro tipo de estímulo, como movimentos musculares gerados pelos comandos cerebrais. Estes sistemas utilizam sinais elétricos, detectados no escalpo da superfície cortical ou em áreas subcorticais. Seu objetivo é proporcionar a interação entre o usuário e o dispositivo externo, como computadores, interruptores ou próteses (MACHADO et al., 2009).

SILVEIRA (2013) lembra que Hans Berger, em 1929, desenvolveu estudos sobre um dispositivo que ao passar dos anos veio a ser conhecido como eletroencefalograma, que poderia gravar potenciais elétricos gerados pela atividade cerebral. A partir desta ideia, quarenta anos mais tarde, os pesquisadores foram capazes de desenvolver sistemas de controle primitivo baseado na atividade elétrica cerebral.

Trabalhos desenvolvidos pelo laboratório de BMI da UCLA (Universidade da Califórnia, Los Angeles), dirigido por Jacques Vidal, provaram que os sinais de atividade cerebral podem ser usados para comunicar eficazmente a intenção do usuário. Também criou uma separação clara entre os sistemas utilizando a atividade EEG e aqueles que usaram a atividade EMG (eletromiograma) gerados a partir de terminações nervosas musculares ou movimentos dos músculos faciais. Trabalhos desenvolvidos posteriormente apresentaram outras técnicas de captura de atividade neural utilizadas em sistemas BMI além do EEG (Vallabhaneni et. al, 2005 *apud* (SILVEIRA, 2013)).

Atualmente, os sistemas BMI desenvolvidos, são ferramentas que podem auxiliar os usuários a se comunicar com o ambiente externo e a realizar atividades cotidianas, ainda

que apresentem um sucesso limitado e se encontrem principalmente em ambientes de pesquisa. No entanto, tem sido desenvolvido para usuários com deficiências mentais e físicas, para pessoas que não apresentam nenhum tipo de deficiência e principalmente no ramo do entretenimento, na indústria de jogos digitais.

Algumas de suas funcionalidades consistem em prover um novo canal de comunicação e ampliar a interação de humanos com o mundo exterior (como pacientes com doenças neurológicas), auxiliar na reabilitação de funções motoras, através de equipamentos como neuropróteses e, ainda, favorecer a análise de dados cerebrais para auxiliar na compreensão de atividade neurológica.

2.2.1 Técnicas de captura de Sinais

- Técnicas Invasivas

Os dispositivos BMI “brutos” fazem uso de implantes corticais, ou seja, eletrodos são implantados dentro do crânio do paciente. Alguns dos exemplos mais conhecidos são a matriz de Utah e a matriz de Michigan.

A matriz de Utah compreende uma matriz de 8x8 ou 10x10 eletrodos que são inseridos diretamente no córtex. Com base na organização colunar do córtex, por exemplo, em relação à sensibilidade de orientação, o objetivo é traduzir a separação espacial de “pensamentos” individuais no córtex, em sinais discretos para formar um padrão na matriz de eletrodos (SILVEIRA, 2013).

- Técnicas Não-invasivas

Existem os métodos não-invasivos para medir as atividades cerebrais, são técnicas que permitem reduzir os riscos aos usuários, uma vez, que não há necessidade de procedimentos cirúrgicos ou fixação permanente de eletrodos. Algumas dessas técnicas são a tomografia computadorizada (CT- Computerized Tomography), tomografia por emissão de pósitrons (PET- Positron Electron Tomography), ressonância magnética (MRI- Magnetic Resonance Imaging), magnetoencefalografia (MEG - Magnetoencephalography) e eletroencefalografia.

A eletroencefalografia tem sido o método mais utilizado para aquisição de sinais BMI, baseado na captação e análise de sinais cerebrais, através de dados EEG (SILVEIRA, 2013). Como exemplo, para a captura de sinais EEG, é a inserção de uma touca na cabeça do indivíduo, e nela são acoplados os eletrodos, que facilmente, fazem o contato e enviam os estímulos cerebrais para a máquina, computador ou prótese.

2.2.2 Eletroencefalograma e Sinais

O eletroencefalograma é baseado em registros de atividade elétrica cerebral medidos na superfície do escalpo. Alterações muito pequenas na atividade elétrica dentro do

cérebro são captadas pelos eletrodos no escalpo (EYSENCK; KEANE, 2010). Ainda assim, por possuir uma alta resolução temporal, capaz de medir a atividade a cada milésimo de segundo, se faz uma das opções mais usuais. Aparelhos modernos de EEG apresentam uma resolução espacial razoável, com sinais de até 256 eletrodos ao mesmo tempo. Além disso, outra vantagem de aparelhos EEG para uso laboratoriais e em ambientes do mundo real é que os dispositivos são portáteis e os eletrodos são facilmente colocados na cabeça do usuário com o auxílio de uma touca.

Desde o surgimento deste método, os aparelhos EEG tem sido usados em inúmeros campos, o que fez necessário a criação de padrões para as técnicas e tecnologias de aquisição de sinal. A forma da disposição dos eletrodos no escalpo sugerida pelo sistema internacional 10-20, conforme pode ser observado na Figura 6. Para uma melhor resolução espacial também é comum o uso de uma variante do sistema 10-20, que preenche os espaços entre os eletrodos com eletrodos adicionais (Vallabhaneni et. al., 2005 *apud* (SILVEIRA, 2013)).




Figura 6: Ilustração dos eletrodos para aquisição de sinais de forma não-invasiva usando EEG, no sistema 10-20 (SOCIETY et al., 2006).

Este arranjo padronizado de eletrodos (Figura 6) sobre o couro cabeludo é conhecido como o sistema internacional 10-20 o qual garante ampla cobertura de todas as regiões da cabeça (VALLABHANENI; WANG; HE, 2005).

As posições exatas para cada eletrodo está na interseção das linhas calculadas a partir de medições entre marcos padrão no crânio. Ainda de acordo com a Figura 6, o nome de cada eletrodo, ou seja, a letra indica a região do cérebro, em que FP indica a região pré-frontal; F, frontal; T, temporal; C, central; P, parietal e O, occipital. Já o número ou a segunda letra correspondem a localização hemisférica, Z é a linha zero no centro da cabeça; números pares representam o hemisfério direito e os números ímpares indicam o hemisfério esquerdo. Os números são expostos em ordem crescente com o aumento da distância do centro (VALLABHANENI; WANG; HE, 2005).

Os sinais que são capturados pelos equipamentos EEG medem diferenças de potenciais entre regiões do córtex. Essas diferenças se devem ao fluxo de íons entre os diferentes neurônios do cérebro. No momento em que o neurônio é ativado, o mesmo se polariza gerando um potencial de ação que pode ser propagado para outros neurônios, gerando assim a circulação da informação. Com isso, os registros elétricos de EEG, colhidos na superfície do escalpo, mostram atividade elétrica do encéfalo (KUGLER, 2003).

Os registros obtidos através dos eletrodos apresentam intensidade das ondas cerebrais registradas do escalpo que podem variar entre $0 \mu V$ e $200 \mu V$ em faixa de frequência que varia entre 0,3 Hz a 100 Hz.

O sinal resultante de um eletroencefalograma mostra picos relacionados com a existência de atividade elétrica, mostrando de uma forma muito geral a localização espacial desta atividade, pois este sinal é resultante da soma da atividade de um grande número de neurônios que se comunicam uns com os outros (OLIVEIRA et al., 2008).

2.3 Os sentidos do corpo humano

De acordo com PURVES et al. (2001) os sentidos básicos do corpo humano são: sensação somática, visão, audição, sensação vestibular e os sentidos químicos (gustação e olfato). Para EYZAGUIRRE (1977) um receptor sensorial é uma estrutura que pode ser estimulada por alterações provenientes tanto do meio externo quanto do meio interno. O receptor pode transformar diferentes tipos de energia em impulsos nervosos que se propagam, através de fibras aferentes sensitivas, em direção ao sistema nervoso central. A informação fornecida pelos impulsos nervosos, após a codificação e análise pode provocar sensação consciente. PURVES et al. (2001) afirmam ainda que esses impulsos, propagados através das fibras aferentes, ativam neurônios centrais capazes de representar tanto aspectos qualitativos quanto quantitativos do estímulo (o quanto forte esse estímulo é) e, em algumas modalidades (sensação somática, visão e audição), a localização do estímulo no espaço (onde ele está).

- **Sistema Somatossensorial:** A somestesia é a sensação corpórea consciente de toque e temperatura. De acordo com EYZAGUIRRE (1977), as modalidades sensoriais que envolvem somestésicos incluem, especificamente, as sensações de toque, pressão, vibração, dor e temperatura. Já para PURVES et al. (2001), o sistema somatossensorial, pode ser considerado “o mais variado dos sistemas sensoriais, mediando um amplo espectro de sensações”. Essas sensações, assim como o tato, são transduzidas por receptores localizados dentro da pele ou dos músculos e transmitidas para uma variedade de alvos no SNC.

- **Sistema Auditivo:** Segundo EYZAGUIRRE (1977) é o sistema auditivo que nos põe em contato com o mundo externo através dos sons. O som é uma energia vibratória que pode se propagar através de um meio gasoso, líquido ou sólido e, se de intensidade e frequência adequadas, pode estimular os mecanorreceptores do ouvido. A rapidez das respostas auditivas diante das informações acústicas facilitam a orientação inicial da cabeça e do corpo a um novo estímulo, em especial para os que não estão inicialmente no campo visual (PURVES et al., 2001). PURVES et al. (2001) afirmam ainda que, “embora o ser humano seja uma criatura principalmente visual, grande parte da comunicação humana é medida pelo sistema nervoso auditivo”.

- **Sistema Quimioceptor:** Os quimioceptores são terminais sensoriais que responde primariamente a alterações químicas, tanto no meio interno como externo. Os quimioceptores externos são responsáveis pelas sensações como olfato e gustação, que tem a função de auxiliar no contato com o meio externo (EYZAGUIRRE, 1977).
 O olfato permite a distinção entre milhares de odores diferentes. Nos humanos, os odores fornecem informações sobre si, outras pessoas, animais, plantas, e ainda ajudam a identificar no meio ambiente alimentos e substâncias nocivas e irritantes (PURVES et al., 2001). PURVES et al. (2001) dizem que a informação olfatória influencia as interações sociais, a reprodução, respostas defensivas e o comportamento alimentar.
 O sentido da gustação está intimamente ligado ao sentido de olfação, muitas vezes o que considera-se do gosto de um alimento é na verdade o aroma, fato que pode ser percebido quando uma pessoa apresenta um resfriado forte. O gosto é uma combinação de cinco sensações: salgado, azedo, doce, amargo e umami (SILVERTHORN, 2010) (PURVES et al., 2001). EYZAGUIRRE (1977) distingue somente quatro sensações: acre, salgado, doce e amargo, para as quais apresentou suas áreas de localização: o acre nas bordas da língua; o salgado e o doce, na ponta da língua; e o amargo, na base da língua.

- **Sistema Visual:** Para SILVERTHORN (2010), o olho é um receptor sensorial que

funciona como câmera fotográfica, ele foca a luz sobre uma superfície sensível à luz (retina) usando uma lente e uma abertura (pupila), em que o tamanho pode ser ajustado de acordo com a quantidade de luz que entra. O autor define que a visão é o processo em que a luz refletida nos objetos no meio externo é transformada em imagem mental.

2.4 Deficiência Visual

Deficiência visual é um termo empregado para se referir à perda visual que não pode ser corrigida com lentes por prescrição regular (TEENAGERS; SEXUALITY, 2006). Se entende por deficiente visual, pessoas que apresentam impedimento total ou parcial da visão, decorrente de imperfeição do sistema visual (LOCH, 2008).

Existem dois tipos de deficiência visual: cegueira e baixa visão. As duas formas mais comuns de avaliar a capacidade visual são através da acuidade (discriminação de formas) e pelo campo visual (capacidade de percepção da amplitude dos estímulos) (SILVEIRA NUNES; LOMÔNACO, 2008). O sujeito cego é aquele com acuidade menor que 0.1 ou campo visual com menos de 20 graus. Já a baixa visão é definida por uma acuidade de 6/60 e 18/60 e/ou um campo visual entre 20 e 50 graus (SILVEIRA NUNES; LOMÔNACO, 2008). A definição sobre cegueira e visão subnormal, sob os enfoques médicos-oftalmológico e pedagógico é dado por:

Cegueira: Redução da acuidade visual central desde cegueira total (nenhuma percepção de luz) até acuidade visual menor que 20/400p (ou seja 0.5) em um ou ambos os olhos, ou redução do campo visual ao limite inferior a 10 graus.

Visão subnormal (visão reduzida): Acuidade visual central maior que 20/400 até 20/70, ou seja 0.3 (BRASIL, 1995).

Para ALMEIDA (2000), a cegueira ou perda total da visão pode ser adquirida ou congênita. A cegueira congênita pode ser a partir do nascimento ou adquirida até dois anos de idade, já a cegueira adquirida é considerada a partir dos dois anos de idade (SMITH, 2008). SMITH (2008) destaca a importância desta distinção, pois crianças que perdem a visão após 2 anos de idade recordam a aparência de alguns objetos. Quanto mais tarde a deficiência ocorre, maior será a sua memória visual, esses indivíduos conseguem lembrar de imagens, luzes e cores que conheceu, e isso se torna útil para sua readaptação (ALMEIDA, 2000) (SMITH, 2008).

Os impactos da deficiência visual (congênita ou adquirida) sobre o desenvolvimento individual e psicológico variam muito entre os indivíduos. Esses impactos dependem da idade em que ocorre a perda da visão, do grau de deficiência, da dinâmica familiar, de intervenções que forem tentadas, da personalidade da pessoa, e uma infinidade de outros fatores (ALMEIDA, 2000).

A delimitação pela acuidade visual tem, para fins educacionais, mostrado ser pouco apropriada, dando preferência aquela referente à eficiência visual. Sendo assim, alguns autores consideram que o modo pelo qual uma pessoa utiliza a visão é mais importante que a medida de sua capacidade visual (RABÊLLO, 2011).

A definição sugerida por *American Foundation for the Blind*¹ sugere que a criança cega é aquela em que a perda de visão indica que pode e deve funcionar em seu programa educacional, principalmente através do uso do sistema Braille, de aparelhos de áudio e de equipamentos especiais, necessários para que alcance seus objetivos educacionais com eficiência, sem o uso da visão residual (MASINI, 1994) (RABÊLLO, 2011).

ALMEIDA (2000), revela em seu estudo que enxergar não é uma habilidade inata, ou seja, ao nascer não sabemos enxergar: é preciso aprender a ver.

2.5 Deficiência Visual e os Sentidos

A deficiência visual, em qualquer grau, compromete a capacidade da pessoa de se orientar e de se movimentar no espaço com segurança e independência (BRASIL, 1995).

Uma vez que uma pessoa nasce sem a capacidade visual, ou a perde ao longo da vida, visto que as informações não chegam aos indivíduos através da visão, são necessárias adaptações, e é através dos outros sentidos que ele encontra outras possibilidades de conhecer o mundo (SILVEIRA NUNES; LOMÔNACO, 2008). SILVEIRA NUNES; LOMÔNACO (2008) afirmam que este processo não acontece de forma automática, como supunha a teoria da substituição, em que um sentido seria substituído por outro, pois se trata de um processo de aprendizagem como outro qualquer.

No início da vida, um bebê nascido cego necessita do apoio de pessoas disponíveis para ajudá-lo a explorar o mundo e a elaborar suas próprias informações, usando os demais sentidos - audição, olfato, tato e paladar, permitindo assim que ganhe confiança e senso de equilíbrio (BRASIL, 1995).

VIVEIROS (2013) em seus estudos, apresenta noções de Vigotsky que diz:

- o cego de nascimento não forma imagens mentais visuais;
- possui concentração e memória mais desenvolvidas do que os videntes;
- a cegueira impulsiona o indivíduo a criar mecanismos internos de compensação para vencer o obstáculo da ausência da visão;
- a linguagem falada é o mecanismo por excelência que o cego se utiliza.

Entre os sentidos, a audição é extremamente importante, pois é através dela que o que não pode ser visto pode ser interpretado (entendido) através da linguagem, ajudando ainda

¹<http://www.afb.org/default.aspx>

a criança portadora de deficiência visual a compreender que existe uma realidade exterior, separada dela (SILVEIRA NUNES; LOMÔNACO, 2008) (BRASIL, 1995). Porém, é necessário que pessoas videntes descrevam o que é visual, sendo assim, SILVEIRA NUNES; LOMÔNACO (2008) lembram que os videntes estão menos acostumados a perceber o mundo através dos outros sentidos, o que exige do cego frequentes “ajustes” do que ele conhece através das suas percepções e do que ele conhece através da fala das pessoas que estão ao seu redor.

Neste contexto, RABÊLLO (2011) diz que “alguns cegos se tornam muito sensíveis as matizes de inflexão, de volume, de cadência, de ressonância e das várias intensidades dos sons da fala dos outros, que passam despercebidos aos videntes”. O que para SILVEIRA NUNES; LOMÔNACO (2008) não significa que o cego tenha uma super capacidade, e sim, utiliza de forma aprofundada a audição possível a qualquer pessoa.

A audição também possui um papel importante na diferenciação de estímulos e na detecção de obstáculos, tal como ocorre no fenômeno de ecolocalização. Através da localização dos objetos por sons, que muitas vezes não são ouvidos pelos videntes, a audição pode proporcionar aos cegos indicações sobre a direção e a distância de objetos (KASTRUP, 2007).

Para KASTRUP (2007), o tato é considerado o sentido mais adequado para fornecer as referências de deslocamento no espaço, que deixaram ou nunca de existir devido a falta de visão, e é através dele que a maior parte do conhecimento espacial deve ser construída. VENTORINI (2007) afirma que “a identificação de objetos por meio do tato não se realiza simplesmente ao tocá-los e explorá-los, é necessário desenvolver uma sensibilidade tátil para percebê-los e/ou conhecê-los”. O autor propõe que para desenvolver a sensibilidade tátil devem ser considerados alguns aspectos, como:

- discriminação de texturas: para a estimulação tátil são importantes a utilização e o incentivo da exploração de materiais agradáveis ao toque, que não ofereçam riscos de acidentes, como objetos quentes e cortantes;
- tamanhos e formas: o tato compõe a imagem do objeto gradualmente, ou seja, a formação da imagem mental de um objeto pelo tato ocorre por meio da organização e montagem. Por isso as formas dos objetos não devem ser complexas. A complexidade das formas de objetos para a estimulação tátil deve ser gradual e estar de acordo com a idade, grau de maturidade e experiência do sujeito;
- estética tátil: o objeto que possui uma beleza estética tátil é aquele que tem textura, forma e tamanho adequado à exploração tátil.
- componente afetivo: o tato permite as sensações por meio do contato direto com plantas, animais e pessoas.

Os sentidos como paladar e olfato, também contribuem para a ampliação do conhecimento das pessoas cegas sobre o seu local vivido e as relações sociais estabelecidas em seu dia a dia. Os odores do caminho por onde andam possibilitam o conhecimento de quais objetos compõem o lugar (VENTORINI, 2007). O olfato auxilia as pessoas, cegas ou não, a perceberem, (re)conhecerem e estudarem os diversos objetos que compõem a paisagem de um local, seja este natural ou artificial. Já o paladar, proporciona a degustação de sabores agradáveis ou não de alimentos e bebidas. Para VENTORINI (2007), o paladar estimula socialização, através da realização de encontros ambientes alimentícios, como restaurantes.

Neste contexto, o uso dos sentidos não devem ser considerados isoladamente. Para VIVEIROS (2013), a aprendizagem apresentará muito mais eficiência, no que diz respeito a exploração de objetos, se o indivíduo utilizar o maior número possível de sentidos para fazer o reconhecimento, do que apenas um sentido isolado.

2.6 Sistemas BMI e Deficiência Visual

Em seu trabalho, AMEDI et al. (2010) analisam o fato de que muitas vezes a ativação do córtex occipital mostrou ser um reflexo dos processos de imagens visuais mentais desencadeadas por outras modalidades. Sendo assim se o córtex occipital é verdadeiramente ativado durante o toque, para AMEDI et al. (2010), esta pode ser a base da enorme plasticidade cruzada observada em cegos congênitos. Para isso, os autores utilizaram FMRI para comparar padrões de ativação evocada por uma tarefa de reconhecimento de objetos táteis (TOR - Tactile Object Recognition). Foram analisados os sinais cerebrais de 8 indivíduos videntes e 8 cegos congênitos. Os autores conseguiram observar que regiões seletivas TOR apresentaram forte atividade no complexo occipital lateral (LOC/LOtv - Lateral Occipital Complex) nos sujeitos cegos, indicando que o objeto identificado só pelo toque, ou seja, sem a imagem visual, é o suficiente para evocar respostas do LOC/LOtv. Com isso, concluíram que a imagem visual não é uma condição obrigatória para o objeto de ativação no córtex visual.

RANGEL et al. (2010) analisaram de que forma a reorganização dos sentidos remanescentes após a perda da visão, com base nas ideias sobre as áreas multimodais e meta-modais. Os autores fizeram um estudo com base na revisão de quatro trabalhos. Para eles, seus estudos podem produzir *insights* sobre a organização cerebral e as compensações comportamentais que ocorrem após a provação sensorial. RANGEL et al. (2010) observam que a maioria dos estudos sobre a cegueira e plasticidade subsequente mostra que a amplitude da reorganização cortical está correlacionada com a idade do surgimento da deficiência. A Tabela 1 mostra um resumo sobre os trabalhos analisados no estudo de RANGEL et al. (2010).

Tabela 1: Resumo dos trabalhos apresentados por RANGEL et al. (2010).

Autor	Resumo
COHEN et al. (1997)	Relataram atividade no córtex visual em tarefas discriminativas táteis em cegos congênitos ou precoces, mas não em cegos tardios.
SADATO et al. (2002)	Mostraram resultados semelhantes, isto é, maior atividade no córtex visual primário (V1) de cegos precoces (antes dos 16 anos) do que em cegos tardios e ativação semelhante nas áreas extra estriadas nos dois grupos.
BURTON et al. (2002)	Mostraram ativação em V1 durante leitura em Braille tanto em cegos precoces quanto em tardios.
BÜCHEL et al. (1997)	Em oposição à maioria dos outros estudos - Descreveram ativação de V1 em cegos tardios, mas não em cegos congênitos.

Os autores ainda destacam que os resultados discrepantes revelam a necessidade da realização de mais estudos que abordem a plasticidade intermodal em função da idade de início da cegueira.

2.7 Mineração de Dados e Descoberta de Conhecimento

A Mineração de dados (MD) é uma parte integral da descoberta de conhecimento em banco de dados (KDD - knowledge Discovery in Database), que é definida por TAN et al. (2006) como o processo geral de conversão de dados brutos em informações úteis. Este processo compõe-se de uma série de passos de transformação, do pré-processamento até o pós-processamento dos resultados da mineração de dados (TAN et al., 2006).




Figura 7: Processo de KDD (TAN et al., 2006)

O pré-processamento é a etapa para transformar os dados de entrada brutos em um formato apropriado para análises subsequentes, essa etapa envolve uma série de etapas

como a junção de dados de fontes diferentes, a limpeza e remoção de artefatos, a seleção de registros e características que sejam essenciais para a tarefa de mineração de dados. Já o pós-processamento diz respeito à garantia de que somente resultados válidos e úteis serão incorporados ao sistema de apoio a decisão (TAN et al., 2006).

A MD, de modo simples, trata-se de extrair ou minerar conhecimento de grandes volumes de dados. Esta envolve o estudo de tarefas e técnicas, em que as tarefas são as classes de problemas definidos por estudos na área e as técnicas os grupos de soluções para resolvê-las (DEVÊZA, 2011).

Em seu trabalho, ALENCAR (2007) aponta que uma das definições de mineração de dados que possui maior aceitação por parte de pesquisadores da área é a de FAYYAD; PIATETSKY-SHAPIRO; SMYTH (1996), que afirmam: "Extração de conhecimento de bases de dados é o processo de identificação de padrões válidos, novos, potencialmente úteis e compreensíveis embutidos nos dados."

Os métodos ou técnicas de mineração de dados são divididos em aprendizado supervisionado (preditivo) e não-supervisionado (descritivo). As tarefas não-supervisionadas concentram-se em buscar padrões que descrevam os dados de forma interpretável para os seres humanos, as principais tarefas descritivas são: a extração de regras de associação e agrupamento (*clustering*). Já as tarefas supervisionadas buscam inferir informações sobre os dados já existentes para prever o comportamento dos novos dados, as principais tarefas preditivas são a classificação e regressão (CAMILO; SILVA, 2009) (DEVÊZA, 2011).

2.7.1 Aprendizado supervisionado

2.7.1.1 Classificação

É o processo de encontrar um conjunto de modelos (funções) que descrevem e distinguem classes ou conceitos, com o propósito de utilizar o modelo para prever a classe de objetos que ainda não foram classificados (DEVÊZA, 2011). Nesta tarefa, o modelo analisa o conjunto de registros fornecidos, com cada registro já contendo a indicação à qual classe pertencem a fim de "aprender" como classificar um novo registro (aprendizado supervisionado) (CAMILO; SILVA, 2009).

TAN et al. (2006) definem a classificação como a tarefa de aprender uma função alvo f que mapeie cada conjunto de atributos x para um dos rótulos de classes y pré-determinados. Essas técnicas são apropriadas para prever ou descrever conjuntos de dados com categorias nominais ou binárias e menos efetivas para categorias ordinais, porque não consideram a ordem implícita entre as categorias (TAN et al., 2006).

Os algoritmos de classificação incluem métodos que utilizam árvore de decisão, redes bayesianas, vizinhos mais próximos, algoritmos genéticos, lógica nebulosa, classificação baseada em regras, entre outros. Este trabalho tem como foco utilizar árvore de decisão para análise de sinais cerebrais, assim sendo será melhor detalhado.

- **Árvore de decisão**

A árvore de decisão é uma técnica de classificação baseada na divisão de um problema complexo em vários subproblemas, repetindo este processo de forma recursiva através da geração de uma árvore.

Em uma árvore de decisão, cada nodo folha recebe um rótulo de classe, os nodos não terminais, que incluem o nodo raiz e outros nodos internos, contém condições de testes de atributos para separar registros que possuem características diferentes (TAN et al., 2006).




Figura 8: Árvore de Decisão - Exemplo de construção.

A Figura 8 apresenta um esquema típico de árvore de decisão. As variáveis X são os nós de decisão. A cada nó está associado um atributo, as variáveis a e b representam os limites dos atributos que dividem a decisão em três caminhos da árvore, estes podem ser nominais ou numerais. As variáveis Classe representam as folhas da árvore, que permitem efetuar a classificação do objeto em análise.

No final da década de 70 e início dos anos 80, J. Ross Quinlan desenvolveu o ID3 (Iterative Dichotomiser), um algoritmo para gerar árvore de decisão, que alguns anos a frente viria propor o algoritmo C4.5, sendo uma versão otimizada do ID3, que até hoje, de acordo com CAMILO; SILVA (2009), serve como base para novos métodos supervisionados.

O algoritmo J48 é uma extensão do algoritmo de classificação C4.5, surgiu a partir da necessidade de recodificar para a linguagem Java, já que o C4.5 é originalmente escrito na linguagem C (LIBRELOTTO; MOZZAQUATRO, 2014). Este algoritmo utiliza o método de divisão e conquista para aumentar a capacidade de predição das árvores de decisão. Com isso, sempre usa o melhor passo avaliado localmente, sem se preocupar se esse passo vai produzir a melhor solução, pega um problema

e divide em vários subproblemas sendo criadas sub-árvores entre a raiz e as folhas (ALVARENGA, 2015).

- **Matriz de confusão:** A avaliação do desempenho de um modelo de classificação é baseada nas contagens se números de registros de testes previstos corretamente e incorretamente pelo modelo (TAN et al., 2006). Estas contagens são tabuladas na matriz de confusão. A Figura 9 mostra a matriz de confusão para um problema de classificação binária. Cada entrada f_{ij} na tabela representa o número de registro da classe 0 previstos incorretamente como da classe 1. Baseado nas entradas da matriz de confusão, o número total de previsões corretas feitas pelo modelo é $(f_{11}+f_{00})$ e o número total de previsões incorretas é $(f_{10}+f_{01})$ (TAN et al., 2006).

		Classe prevista	
		Classe = 1	Classe = 0
Classe real	Classe = 1	f_{11}	f_{10}
	Classe = 0	f_{01}	f_{00}

Figura 9: Matriz de confusão para duas classes (TAN et al., 2006).

- **Métricas de performance:** Para facilitar a leitura do quanto melhor um modelo de classificação é executado, esta informação foi resumida em uma métrica de desempenho denominada precisão (TAN et al., 2006). A equação da precisão (1) é definida como sendo a razão entre o número de instâncias corretamente classificadas (N_{pc}) pelo número total de instâncias classificadas (N_p).

$$\frac{N_{pc}}{N_p} = \frac{f_{11} + f_{00}}{f_{11} + f_{10} + f_{01} + f_{00}} \quad (1)$$

Sendo assim, o desempenho de um modelo pode ser expresso em termos de sua taxa de erro, que é dada pela equação (2) onde N_{pe} é o número de previsões erradas e N_p o número total de previsões.

$$\frac{N_{pe}}{N_p} = \frac{f_{10} + f_{01}}{f_{11} + f_{10} + f_{01} + f_{00}} \quad (2)$$

Em geral, os algoritmos de classificação tem como objetivo buscar modelos que alcancem a maior precisão ou a menor taxa de erro quando aplicado ao conjunto de testes.

2.7.1.2 Regressão

A regressão é utilizada quando um registro é identificado por um valor numérico e não categórico.

O objetivo desta tarefa é encontrar uma relação entre um conjunto de atributos de entrada e um atributo-meta contínuo. Por exemplo, seja $X = X_1, X_2, \dots, X_D$ o atributo de entrada e Y o atributo-meta, o objetivo é encontrar um mapeamento da seguinte forma $Y=f(X_1, X_2, \dots, X_D)$ (CASTANHEIRA, 2008). Sendo assim, CAMILO; SILVA (2009) afirmam que esta técnica permite estimar o valor de uma determinada variável analisando-se os valores das demais.

2.7.2 Aprendizado não-supervisionado

2.7.2.1 Agrupamento (Clustering)

O agrupamento trabalha sobre dados que não exigem a categorização prévia dos registros, a tarefa consiste em identificar um conjunto finito de classes para descrever os dados, também conhecido como identificação de classes, segmentação, ou agrupamento automático (LUCAS, 2002). Esta técnica é utilizada para separar objetos de uma base de dados em grupos, de maneira que os objetos que compartilhem um mesmo grupo tenham alguma similaridade entre si e que sejam diferentes dos objetos contidos em outros grupos (TAN et al., 2006). Algumas das técnicas que utilizam este método são: K-means, Agrupamento Hierárquico Aglomerativo, DBSCAN.

2.7.2.2 Regras associativas

A regra associativa é comumente usada para descobrir relacionamentos interessantes escondidos em grandes conjuntos de dados. Esta regra é uma expressão na forma $X \rightarrow Y$, em que X e Y são conjunto de valores (itens). A regra indica que a ocorrência de um item X implica na ocorrência de um item Y (AMO, 2004). Para determinar estas regras, normalmente são avaliados dois fatores: o suporte e confiança. O Suporte determina a frequência na qual uma regra é aplicável a um determinado conjunto de dados, enquanto a confiança determina a frequência em que os itens em Y aparecem em transações que contenham X (TAN et al., 2006)(DEVÊZA, 2011).

2.8 Considerações finais do capítulo

Esse capítulo apresentou os principais temas para o desenvolvimento deste trabalho. O sistema nervoso que é fundamentalmente empregado para a recepção, armazenamento e liberação de informação, através dos órgãos dos sentidos. Estas informações são enviadas para o cérebro, que nos permite processar e obter consciência destas informações. Quando uma pessoa apresenta alguma deficiência, como a falta de visão, os sentidos são altera-

dos, uma vez que os outros órgãos dos sentidos precisam trabalhar mais para substituir a falta da visão. Nos dias de hoje existem diversas formas de auxiliar esses indivíduos, dentre elas os sistemas BMI surgem como ferramenta para auxiliar a comunicação entre o usuário com deficiências e o meio externo, como computadores, pois não exigem nenhum tipo de estímulo, além dos sinais cerebrais. Como forma de compor análises voltadas para estes sistemas acredita-se que a mineração de dados torna-se eficiente, pois é capaz de extrair conhecimento de uma grande quantidade de dados, de forma mais precisa.

3 TRABALHOS RELACIONADOS

3.1 Comparação de Técnicas de aprendizagem para a classificação de EEG

Recentemente muitos trabalhos tem sido desenvolvidos com o uso de algoritmos de classificação, são comumente utilizados para treinamento de máquina e extração de características. Nesta seção apresentamos três trabalhos que utilizam dados EEG e algoritmos de classificação. Estes trabalhos apresentam estudos comparativos dos algoritmos a fim de mostrar qual pode ser o melhor classificador para cada problema proposto. A escolha destes trabalhos foi feita, principalmente por abordarem o algoritmo de árvore de decisão, que foi o algoritmo usado no estudo de caso. No entanto, não foram encontrados trabalhos que utilizassem árvore de decisão como meio de entendimento dos dados de sinais cerebrais, que é o objetivo deste trabalho.

3.1.1 Aplicação de técnicas de aprendizagem automática para classificação de emoções humanas com sinais de EEG

Em seu trabalho CAPELA; GEORGIEVA (2012) apresentam um estudo sobre técnicas de aprendizagem automática e suas aplicações para diferenciar dois tipos de emoções humanas - valência emocional positiva e valência emocional negativa - com base em dados EEG. Para isso, os autores aplicaram as técnicas de classificação: KNN (K-Nearest Neighbor), NaiveBayes, SVM (Support Vector Machine), Redes Neurais Artificiais (Artificial Neural Networks - ANN) e Árvore de Decisão (Decision Tree - DT). O experimento foi feito com 26 voluntários que, durante a aquisição do sinal EEG, visualizaram 24 imagens com um elevado nível de excitação (> 6) e com níveis de valência positiva ($7.29 +$ ou $- 0.65$) e negativa ($1.47 +$ ou $- 0.24$). Amostras de 21 canais de EEG posicionados de acordo com o sistema 10 - 20 e 2 canais de Electro-Óculo-Grama (EGO) foram gravados e pré-processados. Para cada um dos sinais obtidos foram determinadas as suas médias, logo os autores determinaram os máximos e mínimos das médias obtidas, a fim de definir os atributos amplitude e latência, com base nos mínimos e máximos consecutivos. O experimento criou três bases de dados, através de filtros específicos, Filtro AB [0.5-15]Hz,

Filtro AB Delta [0.5-4]Hz e Filtro AB Teta [4-8]Hz.

A análise de performance das técnicas de classificação proposta no estudo de CAPELA; GEORGIEVA (2012), foi realizada através da matriz de confusão. Para o processo de classificação, utilizaram o software PaidMiner (CAPELA; GEORGIEVA, 2012). Em suas análises, constataram que independentemente da base de dados considerada, a técnica que apresentou melhor performance foi a KNN, no entanto as técnicas ANN e DT apresentaram tempo de processamento muito superior ao KNN.

A classificação de emoções humanas com sinais EEG foi obtida com maior sucesso utilizando a base de dados Filtro AB que corresponde a maior gama de frequência (0.5-15Hz), pois observaram que o Filtro AB apresenta maior discrepância entre os atributos das duas classes (amplitudes e latências da valência positiva e negativa), ou seja, obtiveram maior facilidade em identificar diferentes classes nesta base de dados. Os resultados citados anteriormente dizem respeito a amostras com 21 canais de EEG, como os autores consideraram o tempo de processamento da base de dados elevada, resolveram realizar o mesmo experimento, porém com apenas dois canais: P3 e P4, que correspondem ao córtex visual (CAPELA; GEORGIEVA, 2012). Nesta segunda análise observaram que as técnicas classificação DT e ANN classificaram melhor as emoções humanas com sinal EEG.

Em sua conclusão CAPELA; GEORGIEVA (2012) afirmaram que as técnicas que apresentaram uma melhor performance foram KNN, DT e ANN. Sendo que, KNN se destacou em termos de tempo de procedimento e complexidade da solução. Já no que diz respeito a robustez perante as várias bases de dados, as técnicas de DT e ANN apresentaram melhor resultado. A Tabela 2 apresenta a acurácia de cada classificador para cada filtro.

Tabela 2: Porcentagem da acurácia dos classificadores em cada conjunto de dados.

Classificador	filtro AB	Filtro AB Delta	Filtro AB Teta
KNN	81.59%	77.48%	77.48%
Naive Bayes	59.98%	79%	57.6%
SVM	49.54%	49.54%	49.54%
NN	71.6%	66.76%	68.77%
DT	72.44%	70.34%	67.85%

3.1.2 Avaliação de ANN, LDA e Árvore de Decisão para Sistema BMI baseado em EEG

ISHFAQUE et al. (2013) utilizaram um conjunto de dados de sinais EEG para identificar o classificador que executa de maneira mais eficiente a tarefa de classificação, uma vez que os autores acreditam que para um BMI ser bem implementado, questões como

a redução de dimensionalidade e a classificação são tarefas fundamentais. Para isso, reduziram a dimensionalidade dos dados, através da PCA (Principal Component Analysis), logo realizaram a classificação do conjunto destes dados, os classificadores foram: ANN, LDA (Linear Discriminant Analysis) e DT. As métricas de desempenho para fazer a análise comparativa entre os três classificadores são a matriz de confusão e PA (Percentage Accuracy), ambos são usados para verificar a predição e precisão dos classificadores treinados.

Os dados EEG foram adquiridos a partir de indivíduos com os olhos fechados fazendo movimentos aleatórios das mãos direita e esquerda. Os eletrodos utilizados foram: FP1, FP2, F3, F4, C3, C4, P3, P4, O1, O2, F7, F8, T3, T4, T5, T6, FZ, PZ, CZ. Os dados gravados tem os dois movimentos: para trás e para frente da mão direita e mão esquerda, estabelecendo assim um problema de classificação com 4 classes, os autores utilizaram somente o primeiro momento de cada movimento independente dos dados (ISHFAQUE et al., 2013). As atividades cerebrais dos indivíduos foram processadas no domínio do tempo e a dimensionalidade dos dados foi reduzida de 19 colunas para 5 colunas usando PCA. A amplitude de todas as quatro classes diferenciadas no tempo fez com que os dados ficassem visivelmente separáveis.

Os autores constataram que a LDA não trabalhou sobre os dados, pois separou os dados de forma linear, já que, os dados apresentam uma sobreposição máxima de cada classe de dados. Por outro lado o ANN e DT realizaram bem a tarefa porque a sobreposição dos dados não afeta seu desempenho. Por fim, concluíram que as métricas de desempenho, acurácia e matriz de confusão mostraram que a ANN é capaz de classificar os sinais cerebrais melhor em comparação aos algoritmos DT e LDA. A ANN apresentou acurácia de 81.6% , taxa bem maior que os algoritmos LDA: 24.0% e DT: 75.6% conforme pode ser observado na Tabela 3 (ISHFAQUE et al., 2013).

Tabela 3: Porcentagem da acurácia dos classificadores

Classificador	PA
ANN	81.6%
LDA	24.0%
DT	75.6%

3.1.3 Comparação de diferentes métodos de classificação para BMI baseado em EEG

WANG et al. (2009) desenvolveram um trabalho utilizando a imagética motora e o movimento dos dedos, para investigar o desempenho dos diferentes métodos de classificação. A fim de fornecer o algoritmo apropriado para a tarefa de EEG. Os algoritmos LDA, QDA (Quadratic Discriminant Analysis), KFD (Kernel Fisher Discriminant), SVM, MLP (Multilayer Perceptron), LVQ (Learning Vector Quantization), ANN, KNN e DT são compa-

rados e avaliados através da acurácia.

O conjunto de dados III foi adquirido a partir de um indivíduo do sexo feminino durante uma sessão de feedback, em que foram apresentadas, em uma tela, setas indicando direita e esquerda enquanto o indivíduo era convidado a imaginar esses movimentos. Os canais utilizados foram C3,CZ e C4, constituindo um conjunto de 280 ensaios (140 para esquerda e 140 para direita) com o tempo de 9 segundos. Já o conjunto de dados IV foram gravados a partir de um sujeito normal durante uma tarefa de movimento dos dedos, em que o indivíduo deveria pressionar com os dedos indicador e mínimo as teclas correspondentes, em uma ordem auto-escolhida. Foram utilizados 28 eletrodos expostos de acordo com o sistema 10-20, os dados foram constituídos de um conjunto com 416 ensaios, 316 para treinamento e 100 para teste.

Por fim, após a execução dos classificadores os autores puderam concluir através da Tabela 4 que o modelo Gaussian SVM e KNN atingiram um bom desempenho nos dois conjuntos de dados, enquanto LVQ, QDA, KDF e MLP apresentaram acurácia baixa, já os classificadores lineares LDA e SVM apresentaram desempenho semelhante. WANG et al. (2009) ressaltam ainda que o classificador K-NN não é comumente usado para BMI, mas se aplicados os métodos de extração de recursos adequados e a dimensão do vetor reduzida, o K-NN pode conseguir um bom desempenho. Os autores concluíram ainda que os valores da acurácia do DT foram satisfatórias, especialmente para o conjunto II.

Tabela 4: Porcentagem da acurácia dos classificadores em diferentes conjunto de dados (WANG et al., 2009).

Classificador	Acurácia Dataset I	Acurácia Dataset II
LDA	82.86%	84%
QDA	78.57%	79%
KFD	80.71%	81%
Linear SVM	82.86%	82%
Gaussian SVM	84.29%	84%
MLP	80.71%	81%
LVQ	77.86%	80%
K-NN	84.29%	83%
DT	82.14%	86%

3.2 Considerações finais do capítulo

Os trabalhos relacionados tratam da comparação e avaliação de diferentes algoritmos de classificação para aprendizagem automática ou extração de características utilizando dados EEG. Os autores destacam a importância do algoritmo de classificação adequado

para a implementação de um sistema BMI bem sucedido. Neste contexto, os autores buscam avaliar e encontrar os métodos de classificação mais eficientes para cada problema proposto. As técnicas ANN, KNN e DT apresentaram os melhores resultados entre as avaliações dos três trabalhos. CAPELA; GEORGIEVA (2012) obtiveram a melhor acurácia com o algoritmo KNN, porém relata que as técnicas de DT e ANN obtiveram melhor resposta no quesito robustez. WANG et al. (2009) em seus estudos também obteve acurácia satisfatória para o KNN juntamente com o Gaussian SVM. Já ISHFAQUE et al. (2013) constataram que o ANN apresentou melhor eficiência, com acurácia de 81.6%, com DT ficando em segundo lugar com 75.6%. A Tabela 5 apresenta um resumo dos trabalhos apresentados.

Tabela 5: Síntese dos trabalhos relacionados

Trabalho	Resumo
CAPELA; GEORGIEVA (2012)	Apresenta um estudo de diferentes técnicas de aprendizagem automática e a sua discriminação para diferenciar dois tipos de emoções humanas, valência emocional positiva e negativa, baseado em dados de EEG. As técnicas abordadas no estudo foram KNN, NaiveBayes, SVM, ANN e DT. As técnicas que apresentaram melhor performance forma KNN, ANN e DT.
ISHFAQUE et al. (2013)	Utiliza dados EEG para identificar o classificador mais eficiente. Utilizam dados EEG para redução de dimensionalidade através da PA e logo a classificação do conjunto desses dados, utilizando três técnicas: ANN, LDA e DT. Utilizaram a matriz de confusão e acurácia para avaliar o desempenho dos algoritmos. A técnica que apresentou maior eficiência foi a ANN.
WANG et al. (2009)	Analisa o desempenho de diferentes classificadores para dados EEG de duas tarefas, imagética motora e movimento dos dedos. Os classificadores são: LDA, ADQ, KFD, SVM, ANN, KNN e DT. Como critério de avaliação os autores utilizaram a acurácia. O algoritmo KNN apresentou-se um método muito eficiente, no entanto a DT, que é pouco utilizada em BMI, demonstrou-se uma técnica promissora.

4 METODOLOGIA PROPOSTA

Esse trabalho tem como objetivo apresentar uma metodologia para o uso de árvores de decisão como meio de compreender a atividade cerebral a partir de um estudo de caso com o reconhecimento de objetos espaciais. Para isso, a Figura 10 ilustra os passos que devem ser seguidos na metodologia proposta.



Figura 10: Metodologia proposta.

- 1. Problema:** Nesta primeira etapa deve-se formular um problema ou hipótese para investigar a sua veracidade, podem ser testados e confirmados ou refutados.

GAZZANIGA; HEATHERTON; VERONESE (2005) dizem que o processo empírico reflete uma interação dinâmica entre três elementos essenciais. Primeiro, existe uma teoria, que é uma ideia ou modelo de como algo no mundo funciona. Segundo, uma hipótese, que é uma predição específica do que deve ser observado se a teoria em consideração estiver correta. Dessa maneira, a hipótese serve como um teste direto da teoria. Se a teoria for exata, a predição estruturada na hipótese estará correta. Terceiro, deve haver uma pesquisa, que envolve a sistemática e cuidadosa

coleta de dados, ou informações objetivas, para examinar ou testar se a hipótese e, essencialmente, a teoria correspondente é na verdade sustentável. Uma vez de posse dos achados do estudo, o pesquisador retorna à teoria original para avaliar as implicações dos dados obtidos. Ou os achados apoiam a teoria ou requerem que ela seja modificada para levá-los em conta (GAZZANIGA; HEATHERTON; VERONESE, 2005).

2. **Coleta dos dados:** A atividade do cérebro pode ser medida de várias formas, uma delas é a eletroencefalografia, que é um método de coleta de dados que mede a atividade elétrica no cérebro para ver como ela se relaciona às tarefas cognitivas e perceptivas. Para isso são fixados eletrodos no couro cabeludo do participante, que captam a atividade elétrica do cérebro (GAZZANIGA; HEATHERTON; VERONESE, 2005). Alguns equipamentos EEG são: Emotiv Epoc, Actichamp, OpenBMI ou Biosemi Active Two. No entanto, antes de de iniciar a coleta de sinais cerebrais é preciso garantir o bem estar dos participantes da pesquisa, sendo assim cabe aos Comitês de Ética em Pesquisa, a tarefa de revisar as pesquisas propostas para garantir que sigam os padrões científicos aceitos. Nesta etapa deve-se definir um protocolo para a coleta de dados, em que se estabelece o tipo de atividade que será realizada com os indivíduos e o ambiente adequado para a realização da atividade e coleta dos dados. O ambiente deve ser propício para a realização da coleta, deve ser silencioso, estarem presentes na sala somente os participantes da pesquisa e oferecer conforto ao indivíduo.
3. **Pré-processamento:** Os dados gravados EEG devem passar por uma série de processos que permitam mineração de dados. Os dados de entrada podem ser armazenado em diferentes formatos. O propósito do pré-processamento, de acordo com TAN et al. (2006), é transformar os dados de entrada brutos em um formato apropriado para análises. O primeiro passo a ser verificado deve ser o formato do arquivo, posteriormente extrair ruídos, adequar os dados conforme a necessidade da aplicação. Geralmente o pré-processamento envolve etapas como: limpeza dos dados, balanceamento, normalização, redução de dimensionalidade (TAN et al., 2006).

4. **Escolha da técnica:**

As técnicas de MD são aplicadas para alcançar objetivos específicos que podem ser descritos como tarefas, que consistem na especificação do que se deseja buscar nos dados, que tipo de regularidade ou categoria de padrões se quer encontrar. Após a escolha da tarefa, é preciso escolher qual algoritmo/técnica deve ser usado. Essas técnicas consistem na especificação de métodos que garantam como descobrir padrões de interesse. Elas devem ser escolhidas de acordo com as características

dos dados e os requisitos apresentados pelo usuário (DAMASCENO, 2005). Escolher a tarefa e técnica adequada é fundamental para que se obtenha resultados satisfatórios. Algumas das tarefas e técnicas mais comuns:

- Classificação: Árvore de decisão, Classificação Bayesiana, Redes Neurais, SVM;
- Agrupamento: K-Means, DBSCAN (A Density-Based Clustering Method Based on Connect Regions with Sufficiently High Density), COBWEB, CURE.
- Associação: Mineração de itens frequentes, Apriori.

De acordo com DAMASCENO (2005), as técnicas apresentam parâmetros que são usados para seu funcionamento. Encontrar os melhores parâmetros também faz parte desta etapa, para que o método possa ser o mais preciso e ágil possível.

5. **Execução do algoritmo:** Após a realização dos passos anteriores, é possível executar o algoritmo de mineração. O algoritmo irá buscar padrões utilizando suas estratégias, através dos dados informados. Para executar a técnica escolhida, deve-se escolher o software para mineração de dados, configurar os parâmetros de acordo com o que se deseja. Os softwares de MD disponibilizam uma variedade de filtros para pré-processamento e algoritmos para executar a mineração dos dados. Alguns dos softwares são: Weka¹, Rattle², RapidMiner³, Orange⁴.
6. **Modelos gerados:** As ferramentas de MD permitem que os pesquisadores visualizem os padrões extraídos ou os modelos que resumem a estrutura e as informações presentes nos dados. Além da visualização, são utilizadas medidas tanto técnicas quanto subjetivas para avaliar os padrões extraídos (DAMASCENO, 2005). Como por exemplo, a árvore de decisão que apresenta a matriz de confusão, taxa de acerto e erro.
7. **Análise :** Por fim, deve-se analisar e validar os resultados obtidos através dos modelos gerados. Para isso, é importante a participação de especialistas na área de estudo, a fim de validar e garantir a consistência dos resultados.

¹<http://www.cs.waikato.ac.nz/ml/weka/>

²<http://rattle.togaware.com/>

³<https://rapidminer.com/>

⁴<http://orange.biolab.si/>

5 ESTUDO DE CASO

Este estudo de caso consiste no uso árvores de decisão para o entendimento de sinais EEG de videntes e cegos congênitos, durante a execução de uma atividade de reconhecimento de objetos espaciais. Este capítulo apresenta os passos da metodologia proposta no capítulo 4. Cada seção refere-se a uma etapa, em que a seção 5.1 definição do problema, apresenta a hipótese; 5.2 coleta dos dados, apresenta as principais ferramentas utilizadas para a coleta de sinais cerebrais e o protocolo de coleta dos dados; 5.3 pré-processamento; 5.4 escolha da técnica, nesta seção é apresentado o porque da escolha da técnica de árvore de decisão; 5.5 execução do algoritmo, as principais configurações utilizadas na execução do algoritmo; e por fim a seção 5.6 análise e discussão dos dados, apresenta os modelos gerados pelo algoritmo de árvore de decisão.

5.1 Definição do Problema

Em indivíduos sem deficiência visual a análise espacial como identificação de objetos, pessoas, localização e movimentação no espaço, é naturalmente dominada pelo sentido da visão. Este sentido é enviado e processado no lobo occipital. Já pessoas que nascem sem a visão ou perdem com o tempo, tem este sentido comprometido, sendo assim, precisam buscar nos outros sentidos uma maneira de vencer o obstáculo da ausência da visão (VIVEIROS, 2013). KASTRUP (2007) considera o tato o sentido mais adequado para fornecer as referências de deslocamento no espaço. Este sentido é processado no lobo parietal. Ainda neste contexto, GARDNER (1995) afirma em seus achados que “Existe um sistema perceptual comum tanto à modalidade tátil quanto à visual: *insights* atingidos por indivíduos normais a partir de uma combinação de modalidades provam ser acessíveis aos cegos a partir de esferas táteis somente”. Com isso, surgiu o questionamento: indivíduos videntes e cegos utilizam diferentes áreas cerebrais quando a habilidade espacial é estimulada? Desta forma tem-se a seguinte hipótese:

Videntes e cegos utilizam áreas diferentes do cérebro para “visualizar” objetos espaciais. Em videntes, prioritariamente o lobo occipital é ativado. Em cegos, prioritariamente, o lobo parietal é ativado.

5.2 Coleta dos Dados

5.2.1 Ferramentas para coleta de sinais cerebrais

5.2.1.1 ActiChamp

O Actichamp é uma ferramenta desenvolvida por Brain Vision LLC, é um sistema de amplificação modular, que integra componentes finais para análise eletrofisiológica como EEG, ERP e BMI. Para esta pesquisa foi utilizado em conjunto com eletrodos Acticap 32 canais, que é uma touca posicionada no escalpo do indivíduo, que apresenta 32 eletrodos, os quais são expostos no padrão internacional “10-20”. O Acticap é conectado a um módulo do amplificador, permitindo a transmissão dos impulsos elétricos captados pelos eletrodos. A partir da Figura 11 pode-se observar como os eletrodos são distribuídos ao longo do encéfalo.




Figura 11: Mapa dos eletrodos Acticap de acordo com o padrão internacional 10-20 (Acticap).

Os eletrodos possuem LEDs integrados, que indicam a qualidade da transição da corrente de resistência do eletrodo, por meio de cores: vermelho, amarelo e verde. As configurações podem ser observadas através da Tabela 6, que mostra a cor verde para impedância inferior a 25kOhm, que é a ideal para a aquisição dos sinais cerebrais.

Tabela 6: As cores correspondentes às impedâncias - valores padrão

Cor	Impedância
Verde	Inferior a 25kOhm
Amarelo	entre 25 a 60kOhm
Vermelho	Maior que 60kOhm

Com o auxílio da Prof^ª. D^ª. Fernanda Antoniolo Hammes de Carvalho, que é especialista nesta área, baseando-se na literatura em neurociências formulou a Tabela 7, em que apresenta as regiões cerebrais, bem como os eletrodos espacialmente posicionados, conforme o padrão internacional “10-20”, referentes as suas funcionalidades (BASTOS; ADAMATTI; CARVALHO, 2016).

Tabela 7: Áreas cerebrais, eletrodos e as funções correspondentes. As linhas marcadas em negrito indicam os lobos, canais e funções referentes a hipótese deste trabalho.

Região	Eletrodo	Funções proprietárias
Lobo Frontal	FP1, FP2, FZ, F7, F3, F4, F8, FT9, FT10, FC5, FC1, FC2, FC6.	Funções executivas (gerenciamento dos recursos cognitivos/emocionais diante de uma dada tarefa)
Lobo Temporal	T7, TP9, T8, TP10.	Percepção de movimentos biológicos
Lobo Parietal	P7, P3, PZ, P4, P8, C3, CZ, C4, CP1, CP2, CP6, CP5	Percepção somatossensorial, representações espaciais e percepções táteis.
Lobo occipital	O1, OZ, O2.	Visualização de imagens (inclusive durante um diálogo).

5.2.1.2 OpenVibe

Openvibe é uma plataforma de software que permite projetar, testar e utilizar sistemas BMI, além disso pode ser usado como sistema de aquisição em tempo real dos dados fisiológicos e anatômicos do cérebro. É desenvolvido entre três parcerias, a INRIA/IRISA (Buraku Project), especialista em realidade virtual e engenharia de software, a INSERM U821 (Mental processes and brain activation), conhecimentos em Neurofisiologia e processamento EEG em tempo real, e por fim a France Telecom R&D, especialista em processamento de sinal e interação humano computador (PRADA, 2010).

A plataforma consiste em módulos que podem ser integrados no desenvolvimento de um sistema BMI, os conjuntos de módulos são dedicados a aquisição, pré-processamento, processamento e visualização de atividade cerebral (online ou offline). Apresenta uma

interface simples (Figura 12), sem exigir do usuário conhecimento de programação, é baseado na técnica de arrastar e soltar. Cada parte da cadeia de processamento de sinal é representado por uma caixa (boxe), que são ligados um ao outro formando um algoritmo, assim cada usuário pode desenvolver a aplicação que satisfaça a necessidade do seu sistema BMI.

A plataforma é desenvolvida para quatro tipos de usuários:

- programador de plataforma, que pode adicionar novas funcionalidades e testá-las no software, a nível de kernell e plug-ins;
- programador de aplicação, que cria aplicações independentes, usando o Openvibe como biblioteca;
- autor, utiliza o *Visual Scenario Editor* para organizar os módulos de maneira a criar um cenário através das caixas. A Figura 12 apresenta a interface de criação dos algoritmos, onde seleciona-se a caixa na barra lateral e arrasta para o centro;
- operador de cenários, que normalmente é um clínico e não tem conhecimento do Openvibe ou computador, apenas monitora e opera as aplicações prontas, conforme a Figura 13 que mostra três formas de monitoramento: gráfica, mapa topográfico 2D e mapa topográfico 3D.

A Figura 14 apresenta um cenário disponibilizado pelo software, em que o usuário é instruído a empurrar a bola apenas com o pensamento, podendo empurrar para esquerda ou direita.

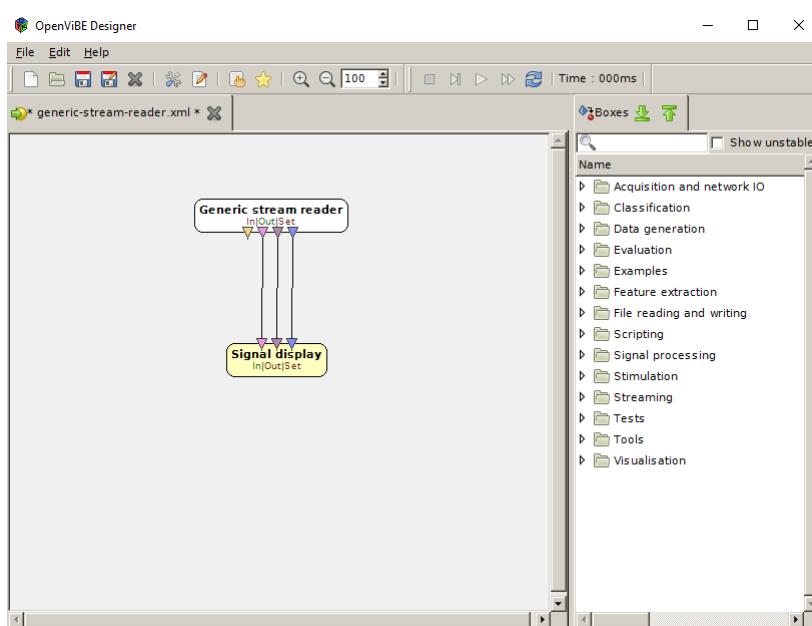


Figura 12: Interface de desenvolvimento do Openvibe Designer - Nível de utilização do Autor.

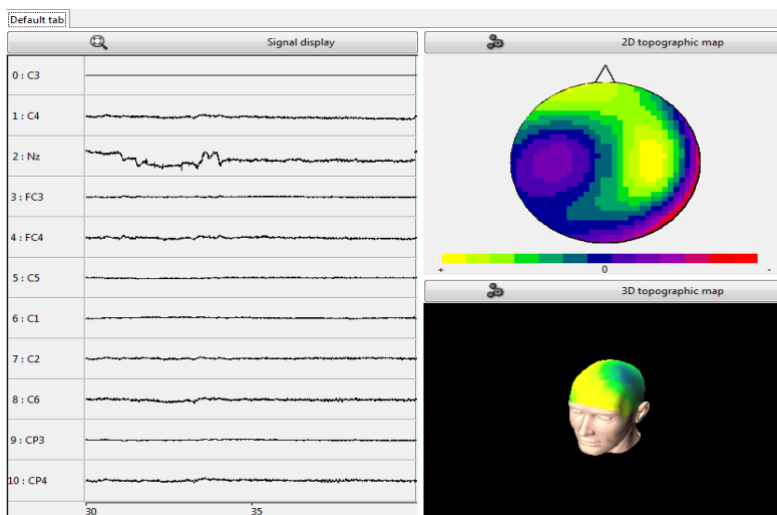


Figura 13: Área de monitoramento - Nível de utilização do Operador (PRADA, 2010).

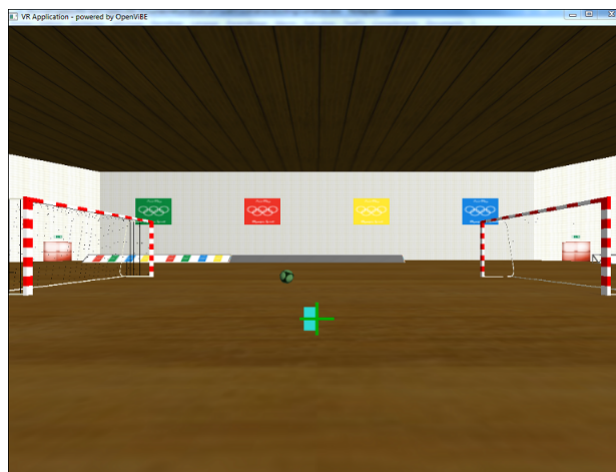


Figura 14: Cenário handball - Nível de utilização do Usuário (PRADA, 2010).

Além das propriedades apresentadas, o *Openvibe* permite que seja realizada a aquisição dos dados de um utilizador enquanto este realiza uma tarefa mental específica, e logo esses dados são analisados de maneira offline, sendo possível calibrar os parâmetros do utilizador, bem como a eliminação de artefatos e a realização do pré-processamento desses dados.

5.2.2 Coletando os dados

Para a coleta de dados realizou-se a aquisição de sinais cerebrais durante a execução de um protocolo, com 4 indivíduos do sexo feminino: 2 videntes e 2 cegos congênitos. Os videntes executaram o teste com os olhos vendados e foram orientados a permanecer com as pálpebras fechadas. Os indivíduos foram submetidos a identificar diferentes objetos de formas geométricas sólidas, a fim de estimularem sua habilidade espacial. Foram utilizados três objetos: cubo, pirâmide e paralelogramo. Foram coletadas 6 amostras de cada

indivíduo, as quais tiveram um intervalo de no mínimo 10 minutos. Cada amostra consistiu em 6 sequências dos objetos, em que os indivíduos identificaram 18 vezes os objetos em cada amostra. Todos os testes foram realizados mediante aprovação do Comitê de Ética em Pesquisa na Área da Saúde¹(CEPAS) e a assinatura do Termo de Consentimento Livre² (TCL).

As coletas foram realizadas de acordo com o seguinte protocolo:

1. foi fornecido aos indivíduos participantes das coletas um protocolo com orientações gerais, tais como lavar cabelo com xampu neutro, não ingerir cafeína até 4h antes da coleta;
2. a coleta foi realizada em uma sala, onde estavam presentes a pesquisadora, assistentes e o participante do experimento;
3. foram tomados cuidados para que não houvessem interrupções, poluição sonora e temperatura desagradável;
4. com o equipamento devidamente organizado, foi posicionada a touca sobre a cabeça do indivíduo;
5. logo os eletrodos foram estimulados até que apresentassem impedância baixa o suficiente para realizar a coleta de sinais cerebrais;
6. uma câmera foi posicionada a frente do indivíduo, a fim de permitir que as coletas fossem gravadas e posteriormente analisadas;
7. o indivíduo foi orientado a identificar 3 objetos geométricos: cubo, pirâmide e paralelogramo;

- **Sequência dos objetos**

Para realizar as seis amostras foi definido inicialmente um conjunto de seis sequências diferentes com os objetos cubo, pirâmide e paralelogramo. Essas sequências representam o total de combinações possíveis para os três objetos. A Figura 15 mostra as sequências dos elementos.

¹CCAAE:344172114.3.0000.5324 - Disponível em Anexo 1

²Disponível em Anexo 2



Figura 15: Sequência dos objetos utilizados na coleta. Cada letra seguida de um número representa uma das combinações possíveis para os três objetos.

Cada amostra foi realizada através da combinação das seis seqüência (S1...S6) definida na Figura 15. Por exemplo, um indivíduo A recebe os objetos contidos em S1, S2, S3, S4, S5 e S6 e realiza-se uma coleta. Em um segundo momento, o mesmo indivíduo recebe as seqüências dos objetos reordenadas, ou seja, S2, S1, S3, S4, S5 e S6 e novamente realiza-se uma nova coleta. Repete-se o processo 6 vezes, resultando em 6 medições de tempo. As seqüências apresentadas em cada uma das amostras são:

- Amostra 1: S1, S2, S3, S4, S5, S6
- Amostra 2: S1, S2, S3, S4, S5, S6
- Amostra 3: S6, S3, S2, S5, S1, S4
- Amostra 4: S2, S5, S1, S4, S6, S3
- Amostra 5: S5, S4, S6, S2, S5, S1
- Amostra 6: S4, S1, S5, S3, S6, S2

8. ao início da coleta, o indivíduo foi instruído a identificar cada objeto após um estímulo sonoro (esse estímulo permitiu uma marcação de tempo precisa - início e ao final da identificação de cada objeto). O sinal sonoro foi emitido através do software Openvibe;
9. os dados foram gravados através do software Openvibe, utilizado para a gravação e monitoramento dos impulsos cerebrais;

10. o indivíduo realizou o teste tocando no objeto e no instante que julgou necessário, após o estímulo sonoro, verbalizou o nome da forma, a Figura 16 mostra os objetos sendo colocados na mão de uma das participantes.




Figura 16: Momento em que os objetos foram colocados na mão de um dos indivíduos.

11. quando o objeto é verbalizado, o passo 7 é executado novamente até que se conclua o teste, terminando a sequência dos objetos.

5.2.2.1 Aquisição dos sinais cerebrais

A aquisição dos sinais cerebrais foi feita com o hardware Actichamp em conjunto com o software Openvibe, o qual apresenta um módulo apropriado para o amplificador. As configurações do servidor Openvibe para a aquisição com Actichamp:

- Número de canais: 32
- Sampling Frequency: 512 Hz
- Impedância: 10 - 1kOhm

A Figura 17 apresenta o autômato utilizado para aquisição dos sinais cerebrais durante a identificação dos objetos.

- “*Acquisition client*” : Este algoritmo recebe dados de um amplificador EEG e o distribuí para o cenário. Abre um canal de comunicação para ler informações do experimento, sinal, estímulos e dados de localização do canal enviado através do amplificador.
- “*GDF file writer*” : Grava dados de informação do experimento de entrada, sinais e estímulos para um arquivo com formato GDF.

- “*Keyboard stimulator*” : Permite que seja enviado estímulos de acordo com a tecla pressionada, este plugin traduz a tecla pressionada em estímulos OpenVibe;
- “*Sound Player*” : Esta caixa é utilizada para emitir um sinal sonoro, permite configurar estímulos sonoros utilizando “Play” para marcar o início da gravação dos dados e “Stop” para marcar o final.
- “*Stimulation listner*” : Imprime os registros dos estímulos recebidos, utilizando o nível de registro especificado pelo usuário.
- “*Signal display*” : Permite que o usuário visualize o fluxo de sinal recebido.

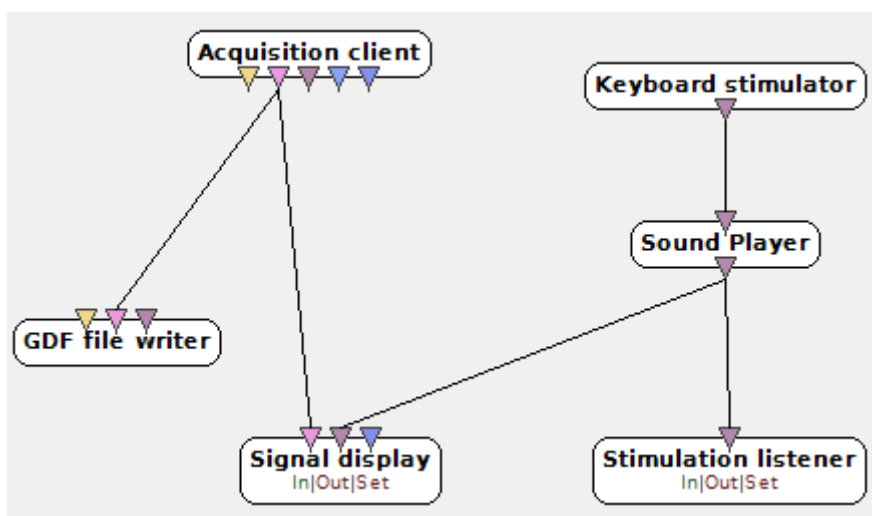


Figura 17: Autômato utilizado para a gravação e monitoramento dos sinais cerebrais.

5.3 Pré-processamento

Os sinais foram gravados através do software Openvibe, sem a utilização de filtros, sendo gravados diretamente no formato GDF (Graph Data Format). Sendo assim os filtros foram aplicados posteriormente, no momento em que foi feita a conversão dos dados para CSV (Comma-Separated Value). Para a conversão dos dados, ainda no Openvibe, utilizou-se um algoritmo para transformar os dados GDF em CSV e a aplicação de filtros. Os dados foram tratados para melhorar a leitura dos sinais. A Figura 18 mostra o autômato utilizado.

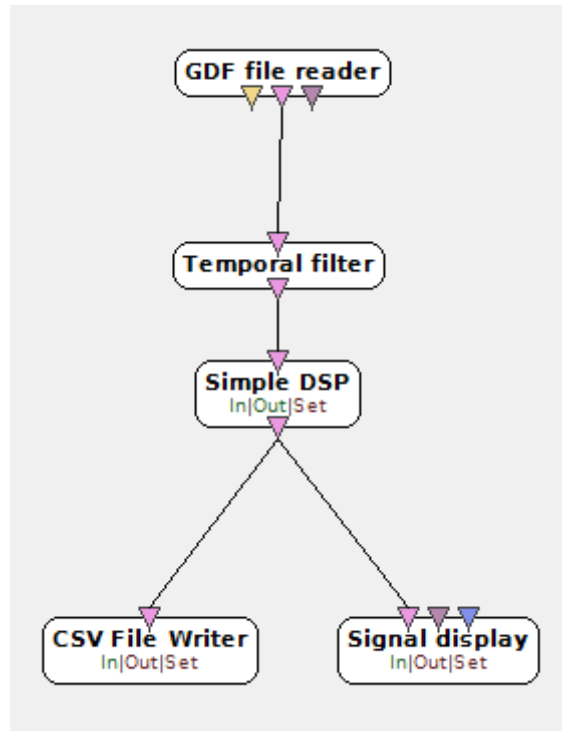


Figura 18: Autômato para transformar os dados GDF em CSV.

A caixa *Temporal Filter* foi utilizada para filtrar os sinais EEG brutos, inicialmente os dados foram alisados por filtragem *Butterworth* de quarta ordem, tal como ilustrado na Figura 19. Ainda na mesma figura é possível verificar a faixa de frequência entre 3.5 e 30Hz, que permite adquirir as ondas de interesse para esse trabalho: Delta, Teta, Alfa e Beta. A caixa *Simple DSP* é utilizada para aplicar uma fórmula matemática para cada amostra de entrada, e apresentar o sinal resultante na saída, aplicou-se a equação $x*x$, para retirar o sinal negativo dos dados, conforme pode ser visualizado na Figura 20.

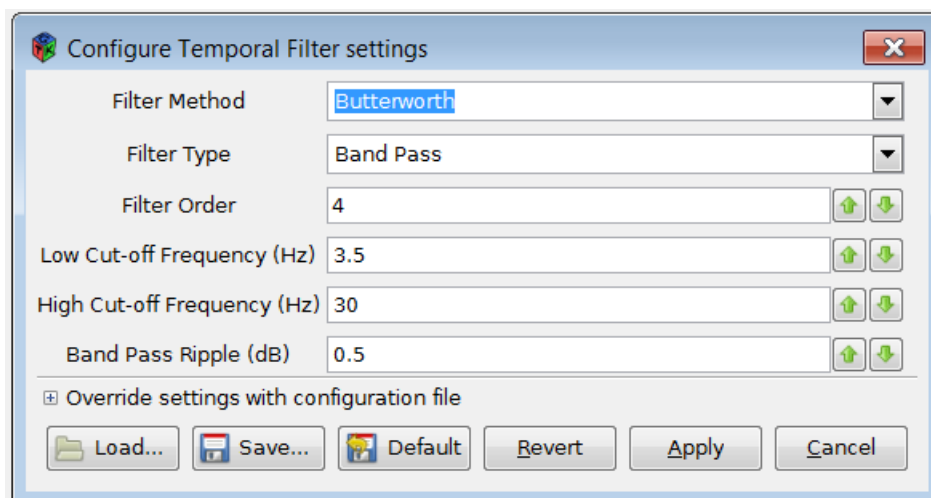


Figura 19: Módulo Temporal Filter.




Figura 20: Módulo Simple DSP.

As principais etapas do pré-processamento dos dados CSV constituí-se em: Limpeza dos dados, eliminação de ruídos e a transformação dos dados CSV para o formato ARFF.

5.3.1 Limpeza dos dados

Para o processo de limpeza de dados inicialmente foram retiradas as colunas consideradas desnecessárias para o estudo. A coluna “*Time*” foi retirada logo após a adição das classes (cubo, pirâmide, paralelogramo) que foram marcadas de acordo com o tempo, o tempo foi marcado através do registro do estímulo sonoro. Um exemplo deste processo pode ser observado na Tabela 8.

Tabela 8: Marcação do tempo em que um dos sujeito manipulou os objetos de uma amostra. A disposição dos objetos foi dada de acordo com a lista de sequências da seção 7.2.2 item 7.

Tempo	Objeto
6.945 - 8.414	cubo
13.352 - 14.477	pirâmide
19.570 - 20.820	paralelogramo
25.852 - 26.758	cubo
31.883 - 33.195	paralelogramo
38.695 - 39.914	pirâmide
45.727 - 47.195	pirâmide
52.352 - 53.352	cubo
58.758 - 59,977	paralelogramo

A Figura 21 ilustra esta primeira etapa, (a) representa os dados brutos, no formato CSV, já a imagem (b) mostra os dados após terem as casas decimais reduzidas, as classes inseridas, retirada a coluna “*time*” e o cabeçalho com o nome dos canais.

Time(s)	Fp1	Fz	F3	F7	FT9
9,758	1,65E+01	4,64E+00	5,51E-01	1,22E+01	3,15E+01
9,76	5,63E+00	1,63E+01	5,77E+00	4,34E+00	3,17E+01
9,762	7,61E-01	3,02E+01	1,32E+01	1,20E+00	3,47E+01
9,764	6,11E-02	3,45E+01	1,37E+01	1,55E+00	4,99E+01
9,766	4,71E-01	2,51E+01	6,13E+00	7,12E+00	8,55E+01
9,768	3,23E+00	1,12E+01	1,65E-01	2,35E+01	1,41E+02
9,77	8,05E+00	2,91E+00	2,67E+00	4,73E+01	1,94E+02
9,771	9,70E+00	7,85E-01	7,86E+00	6,23E+01	2,12E+02

(a) Dado bruto

1,65E+01	4,64E+00	5,51E-01	1,22E+01	3,15E+01	CUBO
5,63E+00	1,63E+01	5,77E+00	4,34E+00	3,17E+01	CUBO
7,61E-01	3,02E+01	1,32E+01	1,20E+00	3,47E+01	CUBO
6,11E-02	3,45E+01	1,37E+01	1,55E+00	4,99E+01	CUBO
4,71E-01	2,51E+01	6,13E+00	7,12E+00	8,55E+01	CUBO
3,23E+00	1,12E+01	1,65E-01	2,35E+01	1,41E+02	CUBO
8,05E+00	2,91E+00	2,67E+00	4,73E+01	1,94E+02	CUBO

(b) Dado após a limpeza

Figura 21: Ilustração dos dados após a limpeza dos dados e adição das classes.

5.3.2 Transformação dos dados

Os dados foram transformados para o formato ARFF (Attribute Relation File Format), que é um arquivo de texto ASCII que descreve uma lista de instâncias que compartilham um conjunto de atributos. Este formato foi desenvolvido para ser utilizado especificamente com a ferramenta Weka. Em uma visão global, os arquivos ARFF apresentam duas seções diferentes: o cabeçalho (*Header*) e os dados (*Data*) (TAVARES; BOZZA; KONO, 2007).

A seção do cabeçalho (Figura 22) tem os campos: *Relation*, define o nome do problema; *Attribute*, define cada atributo e seu tipo de dado.

```
@relation Sujeito1
@attribute C3 numeric
@attribute CP5 numeric
@attribute CP1 numeric
@attribute PZ numeric
@attribute P3 numeric
@attribute P7 numeric
@attribute O1 numeric
@attribute class {cubo,paralelogramo,piramide}
```

Figura 22: Modelo de arquivo do formato ARFF.

A seção dos dados (*Data*) contém uma instância por linha que tem os valores de todos os atributos na sequência listada na seção do cabeçalho. A Figura 23 ilustra a seção dos dados.

```
@data
1.13E+02,1.62E+02,8.82E+01,1.06E+02,1.44E+02,4.67E+01,8.55E+01,5.49E+01,cubo
1.09E+02,1.71E+02,8.56E+01,1.02E+02,1.49E+02,5.41E+01,8.34E+01,5.81E+01,cubo
6.17E+01,1.17E+02,4.48E+01,5.43E+01,9.49E+01,2.95E+01,4.48E+01,2.93E+01,cubo
1.90E+01,5.54E+01,1.01E+01,1.24E+01,3.62E+01,6.28E+00,1.14E+01,4.68E+00,cubo
2.85E+00,2.23E+01,1.57E-01,7.46E-02,7.64E+00,9.25E-02,7.74E-01,2.36E-01,cubo
9.09E-01,1.37E+01,3.08E-01,1.65E+00,1.23E+00,7.36E-03,8.33E-02,2.08E+00,cubo
4.78E+00,1.97E+01,1.23E-01,1.14E+00,1.32E+00,1.74E+00,2.54E+00,3.83E-01,cubo
2.01E+01,3.66E+01,5.01E+00,7.06E-03,4.35E+00,1.26E+01,1.49E+01,1.37E+00,cubo
4.33E+01,5.35E+01,1.48E+01,9.55E-01,7.61E+00,2.78E+01,3.36E+01,7.49E+00,cubo
5.54E+01,5.29E+01,1.76E+01,4.48E-01,5.05E+00,2.97E+01,4.08E+01,9.90E+00,cubo
4.61E+01,3.21E+01,9.11E+00,1.18E+00,9.61E-02,1.45E+01,2.90E+01,4.66E+00,cubo
2.59E+01,9.26E+00,6.37E-01,1.44E+01,6.51E+00,6.76E-01,1.10E+01,8.26E-02,cubo
```

Figura 23: Modelo de arquivo do formato ARFF.

5.4 Escolha da Técnica

A ferramenta utilizada para a realização do estudo de caso foi o Weka³, que apresenta diversos métodos para mineração de dados. Alguns métodos implementados pela ferramenta podem ser visualizados na Tabela 9.

Tabela 9: Métodos implementados pelo Weka

Tarefa	Técnica
Classificação	Árvore de decisão induzida, Regras de aprendizagem, Naive Bayes, Tabelas de decisão, Regressão local de pesos, Perceptron, Perceptron multicamada, SVM
Predição numérica	Regressão linear, Geradores de árvores modelo, Regressão local de pesos, Aprendizado baseado em instâncias, Tabela de decisão
Agrupamento	EM, Cobweb, SimpleKMeans, DBScan, CLOPE
Associação	Apriori, FPGrowth, PredictiveApriori, Tertius

A escolha desta ferramenta ocorreu pelo fato de que é disponibilizada gratuitamente, apresenta interface acessível e apresenta diversas técnicas de mineração de dados. A Figura 24 apresenta a interface da ferramenta para a área da tarefa de classificação. Os itens selecionados em vermelho correspondem a configuração utilizada neste estudo de caso.

³<http://www.cs.waikato.ac.nz/ml/weka/>

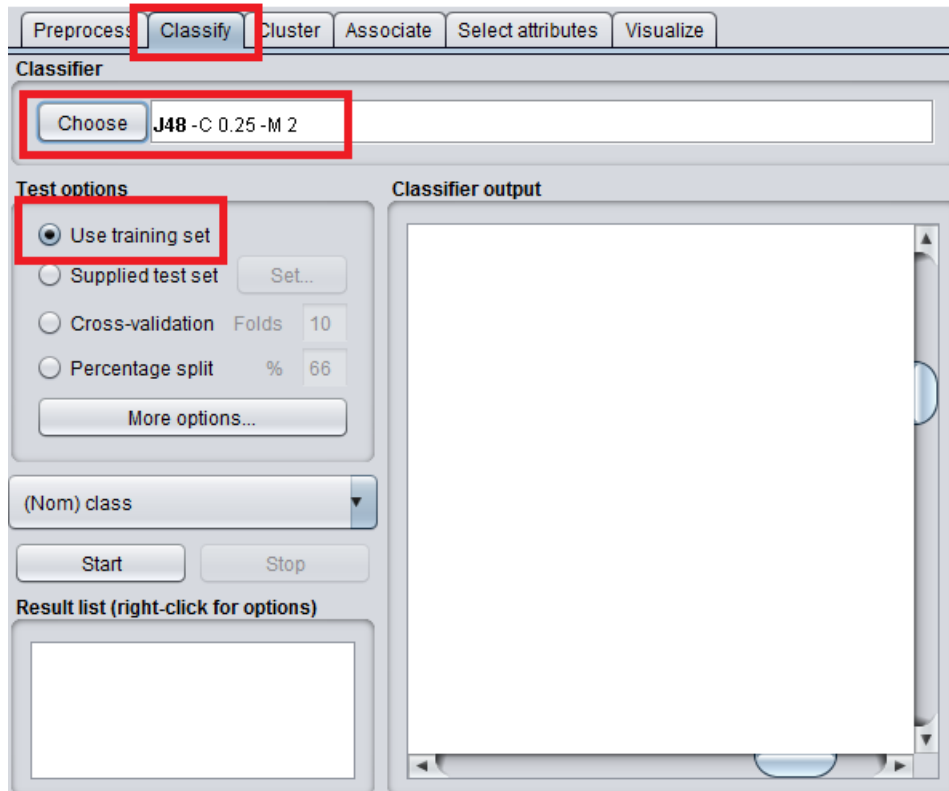


Figura 24: Configuração da tarefa de classificação utilizando o algoritmo J48.

O algoritmo J48 foi escolhido para este estudo por ser uma técnica de árvore de decisão desenvolvida para ser utilizada no Weka. A técnica de árvore de decisão tem como ponto forte a eficiência em termos de tempo e processamento, além disso apresenta um meio intuitivo para analisar os resultados, pois mostra como estrutura final do classificador, uma forma de representação simbólica simples e normalmente de fácil interpretação, o que facilita a compreensão do problema em análise (GARCIA, 2003). A facilidade e a forma de representação simbólica gerada pelo algoritmo foram fatores fundamentais, já que o trabalho visou a compreensão dos dados através da árvore de decisão e não a classificação.

5.4.1 Gráficos gerados

Foram gerados modelos gráficos para cada amostra dos indivíduos, as Figuras 25 e 26 referem-se respectivamente a um indivíduo vidente e um cego. Os dados pertencem a amostra 1, sendo representado somente o momento em que ambas manuseiam e identificam pela primeira vez o cubo.




Figura 25: Representação gráfica dos dados EEG de um vidente. Os valores do eixo Y correspondem ao sinal elétrico dos canais cerebral. Foram acrescentados valores de 1000 a 32000 nos sinais elétricos para permitir que cada canal ficasse em uma escala diferente como, por exemplo, os valores obtidos do canal 1 (FP1) acrescidos 1000; canal 2 (Fz) acrescidos de 2000; canal 3 (F3) acrescidos de 3000 e assim sucessivamente até o canal 32 (FP2) que foram acrescidos 32000. Já o eixo X diz respeito aos milissegundos.

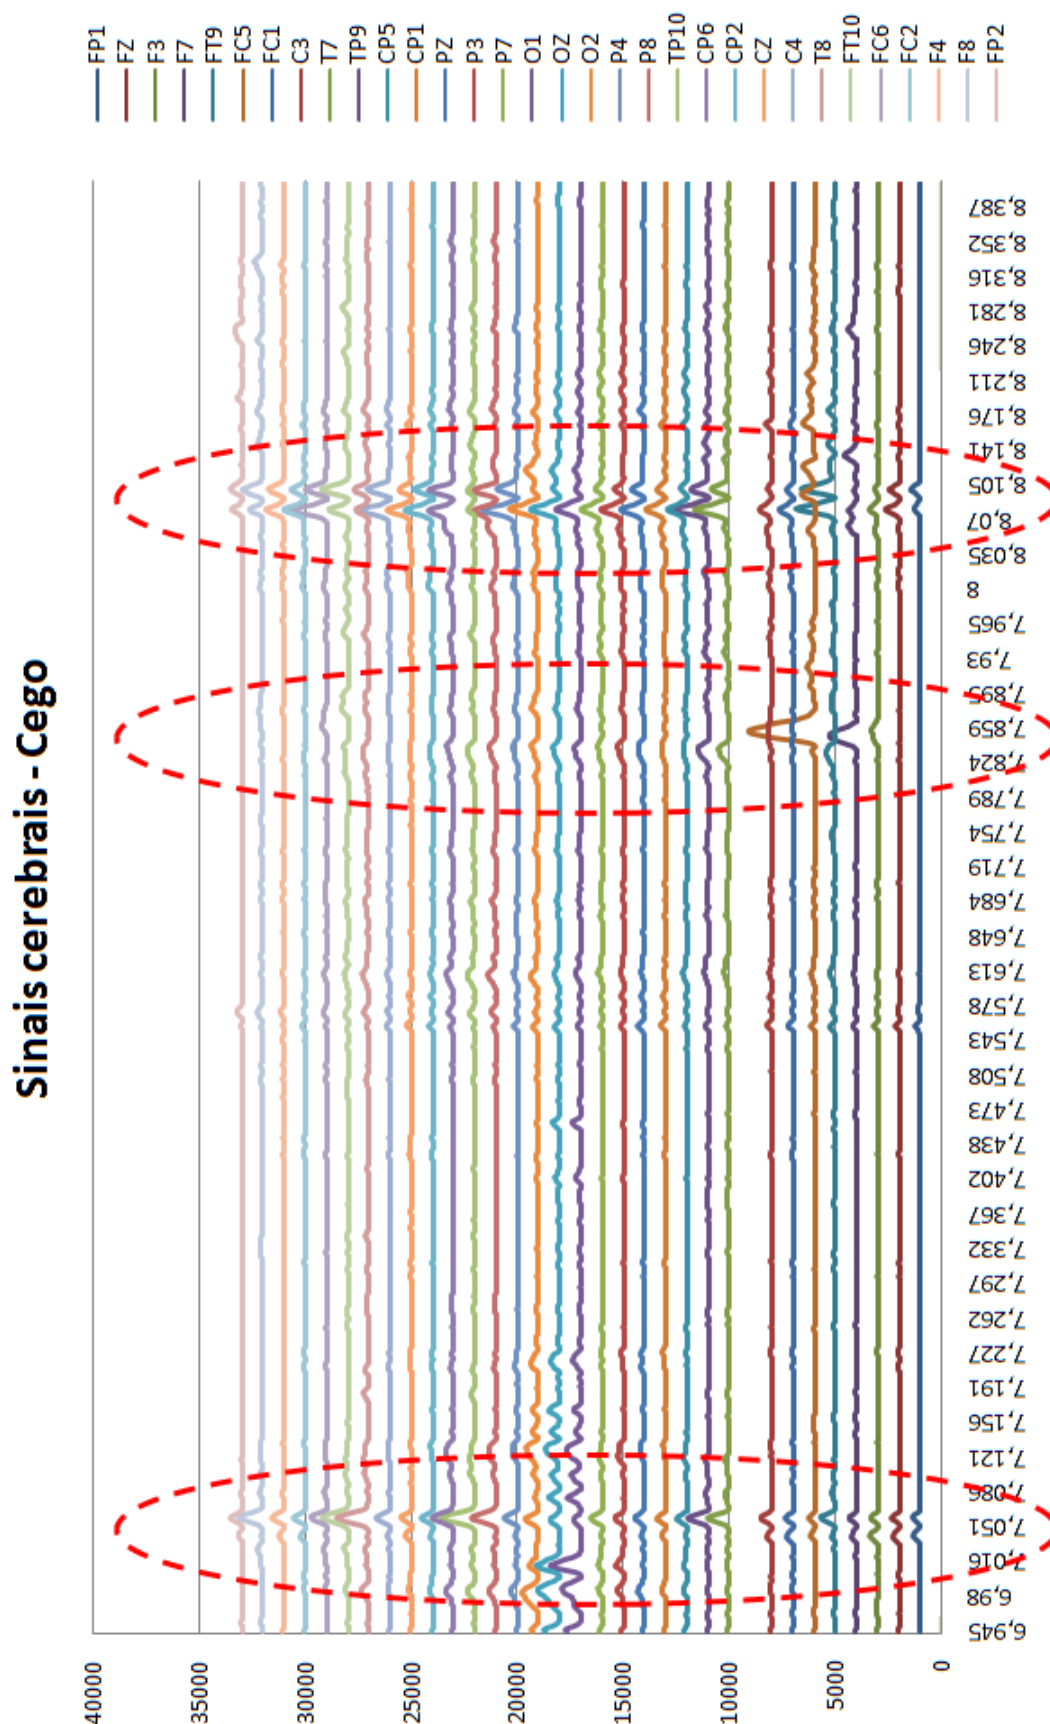


Figura 26: Representação gráfica dos dados EEG de um cego. Os valores do eixo Y correspondem ao sinal elétrico dos canais cerebral. Foram acrescentados valores de 1000 a 32000 nos sinais elétricos para permitir que cada canal ficasse em uma escala diferente como, por exemplo, os valores obtidos do canal 1 (FP1) acrescidos 1000; canal 2 (Fz) acrescidos de 2000; canal 3 (F3) acrescidos de 3000 e assim sucessivamente até o canal 32 (FP2) que foram acrescidos 32000. Já o eixo X diz respeito aos milissegundos.

A Figura 25, apresenta o gráfico com a atividade cerebral de um vidente, em que se verifica picos, que estão marcados com círculos vermelhos, na atividade em três momentos: 10.03 a 10.07, 10.54 a 10.58 e 11.16 a 11.28ms. O primeiro milissegundo (10.03-10.07ms) provavelmente refere-se ao instante em que o indivíduo tocou o objeto, logo de 10.03 a 11.16ms o indivíduo fez o reconhecimento do objeto e por fim, de 11.16 a 11.28ms o indivíduo verbalizou o nome do objeto geométrico.

Por meio da Figura 26 é possível identificar que os picos de atividade cerebral, do sujeito cego, deram-se em três momentos: 7.016 - 7.086ms, 7.824-7.895ms e 7.824 - 8.105ms. De acordo com o controle das atividades, estes picos referem-se aos momentos em que o sujeito identifica o objeto e verbaliza o nome, neste caso um cubo.

Sendo assim, através da observação dos gráficos ilustrados nas Figuras 25 e 26 é possível identificar o momento em que os indivíduos apresentaram maior atividade cerebral durante o a manipulação e reconhecimento do objeto. Entretanto, não foi possível realizar distinção dos canais que apresentaram maior atividade durante os picos, pois os dados são muito semelhantes. Logo, para permitir uma maior precisão e entendimento da atividade cerebral optou-se por utilizar árvores de decisão.

5.5 Execução do Algoritmo J48

A partir dos dados gravados nas coletas de sinais cerebrais realizadas conforme o protocolo citado na seção 5.2.2, foram feitos diferentes testes utilizando árvore de decisão. Estes testes basearam-se na variação dos seguintes parâmetros: número de canais, valores dos sinais e a ordem de execução das tarefas. A Figura 27 ilustra a hierarquia dos testes, em que o teste 1 originou os demais testes realizados no Weka.

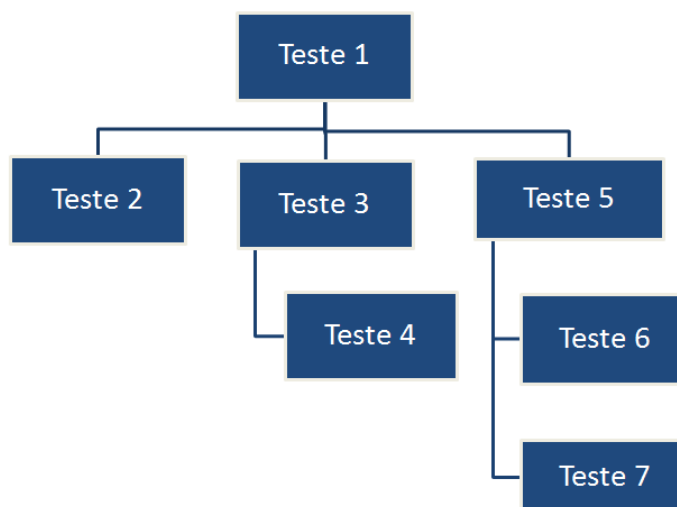
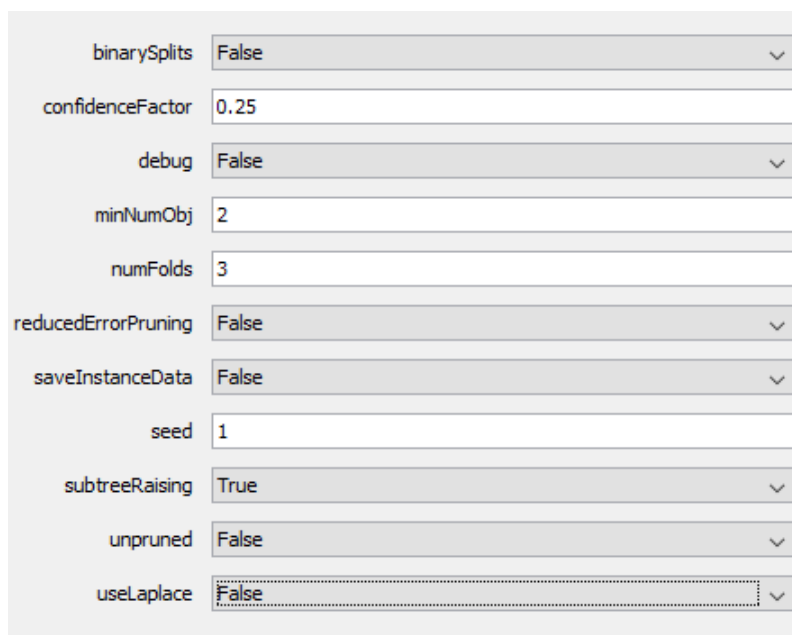


Figura 27: Hierarquia dos testes realizados com a ferramenta Weka.

Testes realizados com os dados das coletas de sinais cerebrais:

- **Teste 1:** O primeiro teste foi feito com os 32 canais. Inicialmente através dos registros do tempo foi realizado a classificação dos objetos entre cubo, pirâmide e paralelogramo. Após a classificação dos objetos, foi feita a limpeza retirando a coluna do tempo e o cabeçalho com o nome dos canais. Por fim os dados CSV foram transformados para o formato ARFF para serem executados no Weka.
- **Teste 2:** O segundo teste foi realizado a partir dos dados do teste 1, porém foram testados somente os dados dos canais considerados prioritários para a execução da tarefa, ou seja, as áreas consideradas essenciais para a manipulação e identificação de objetos geométricos. Ao todo são 15 canais, que envolvem os lobos parietal, occipital e central. Os canais são: P7, P3, PZ, P4, P8, C3, CZ, C4, CP1, CP2, CP6, CP5, O1, O2 e OZ. Os canais não utilizados foram retirados diretamente na ferramenta Weka.
- **Teste 3:** Este teste foi feito a partir de um arquivo contendo somente as três primeiras amostras de cada sujeito, com os 32 canais. A seleção das amostras foram realizadas através da conferência do tempo em que cada indivíduo realizou cada atividade (amostra). Logo foram realizadas as etapas de pré-processamento como a limpeza dos dados, inserção das classes e transformação dos dados para ARFF.
- **Teste 4:** Foram utilizadas as últimas três amostras de cada indivíduo, com os 32 canais cada uma. Passando pelas etapas de limpeza, classificação dos dados e a transformação para o formato ARFF.
- **Teste 5:** O teste 5 foi realizado através do conjunto de 32 canais, os dados foram compilados em um sistema que agrupou os maiores valores contidos a cada 10 linhas de cada coluna (canal), criando assim um novo arquivo CSV somente com os maiores valores de cada eletrodo, em um intervalo de 10. Os dados foram limpos e logo transformados para ARFF.
- **Teste 6:** Este teste foi realizado com base no teste 5, em que foram testados os maiores valores dos canais, no entanto foram utilizados somente os 15 canais considerados prioritários para a realização da tarefa. Como já citado, os canais considerados foram: P7, P3, PZ, P4, P8, C3, CZ, C4, CP1, CP2, CP6, CP5, O1, O2 e OZ.
- **Teste 7:** Os modelos gerados deste teste foram realizados a partir do agrupamento dos dados, com os maiores valores de cada grupo de cada um dos 32 canais, baseado no teste 5. Foram gerados 6 modelos para cada amostra, com as janelas de tamanho 25, 50 e 100 variando a porcentagem do número mínimo de objetos entre 10% e 1% da quantidade de instâncias de cada amostra.

Os testes foram compilados com o algoritmo J48, a opção utilizada para o teste foi “*Use training set*” que neste caso usa para fazer o teste no mesmo conjunto que de treinamento, que será usado para construir o classificador. Esta opção permite que tenhamos uma boa porcentagem de acerto. As demais configurações, em “*GenericObjectEditor*” em geral os parâmetros utilizados foram padrão, com exceção do “*MinNumObj*”, que determina o número mínimo de instâncias por folhas. A Figura 28 apresenta a configuração padrão para a utilização do algoritmo J48.



binarySplits	False
confidenceFactor	0.25
debug	False
minNumObj	2
numFolds	3
reducedErrorPruning	False
saveInstanceData	False
seed	1
subtreeRaising	True
unpruned	False
useLaplace	False

Figura 28: Configuração padrão dos parâmetros do algoritmo J48.

As Tabelas 10, 11, 12 e 13 mostram os dados dos modelos gerados dos testes (subseção 5.3.4). Os dados apresentados são: número de canais, número de instâncias, número mínimo de objetos utilizado como parâmetro na ferramenta Weka, tamanho da árvore e a porcentagem de instâncias classificadas corretamente. Para a alteração do número mínimo de objetos por folha, os valores escolhidos para este trabalho foram os equivalentes a 1% e 10% do número de instâncias de cada teste. Foram realizados diversos testes para identificar os modelos que melhor se adequariam para satisfazer a proposta do trabalho. Como critério de escolha para o teste que foi usado para verificar a hipótese do estudo de caso, considerou-se uma taxa de acerto e árvore de tamanho pequeno para facilitar a interpretação.

Através da Tabela 10 pode-se observar que o modelo de teste 7 do sujeito 1 com 70% de instâncias classificadas corretamente apresenta uma árvore de tamanho 127, o que considerou-se um tamanho de difícil interpretação. Já o teste 7 com 46.19% considera-se uma taxa de acerto baixa pois é abaixo de 50%. Contudo, esta taxa de acerto apresenta uma árvore de tamanho 15, permitindo uma melhor interpretação dos dados, aspecto que o trabalho, fundamentalmente, prima, ou seja, entender o caminho que os canais percorrem

através da árvore para atingir os nodos folhas, que neste caso são os objetos.

Tabela 10: Dados dos modelos gerados através dos testes realizados - Sujeito 1

Teste	Canais	Instâncias		Objetos por folha	Tamanho árvore	Instâncias corretas
1	32	87516		1%	131	41.28%
				10%	11	38.10%
2	15	87516		1%	115	40.60%
				10%	13	37.38%
3	32	47622		1%	147	42.56%
				10%	9	38.06%
4	32	39894		1%	111	43.83%
				10%	11	38.81%
5	32	8708		1%	41	40.93%
				10%	7	38.75%
6	15	8708		1%	21	39.08%
				10%	9	38.31%
7	32	25	3549	1%	105	49.28%
				10%	7	38.65%
		50	1823	1%	135	65.66%
				10%	9	43.06%
100	1037	1%	127	70%		
				10%	15	46.19%

A Tabela 12 com os dados do modelo gerado do sujeito 2 mostra que existem dois valores com a taxa de acerto maior que 50% que são: Teste 7, janela de 50, número mínimo de objetos por folha 1%, tamanho da árvore de 71 e instâncias classificadas corretamente 50.66% e o teste 7 janela 100, número mínimo de objetos por folha 1%, com árvore de tamanho 119 e 63.13%. Ambos apresentam uma taxa de acerto maior que 50% porém o tamanho das árvores geradas não favorecem a interpretação dos sinais cerebrais. Já o teste 7 com janela 100, objetos mínimo por folha 10% gerou uma árvore de tamanho 11 e baixa taxa de acerto de 44.19% foi considerado para análise por apresentar um tamanho que favorece a interpretação e uma taxa de acerto intermediária.

Tabela 11: Dados dos modelos gerados através dos testes realizados - Sujeito 2

Teste	Canais	Instâncias		Objetos por folha	Tamanho árvore	Instâncias corretas
1	32	123883		1%	95	40.83%
				10%	11	38.55%
2	15	123883		1%	79	40.10%
				10%	9	38.14%
3	32	65669		1%	109	42.70%
				10%	11	39.60%
4	32	58214		1%	137	43.09%
				10%	13	39.27%
5	32	12341		1%	61	42.41%
				10%	11	39.36%
6	15	12341		1%	23	38.77%
				10%	7	38.19%
7	32	25	5108	1%	107	49.72%
				10%	11	40.40%
		50	2554	1%	71	50.66%
				10%	11	42.48%
100	1405	1%	119	63.13%		
				10%	11	44.19%

Por meio da Tabela 12, constata-se que dois modelos apresentaram taxa de acerto maior que 50%. O modelo gerado através do teste 7 com janela de 50, ainda que tenha apresentado uma árvore de tamanho 15, considerado favorável para análise não foi escolhido para análise, pois optou-se pela árvore do teste 7, janela 100 com tamanho 15 e taxa de acerto 43%, pois apresenta o mesmo tamanho da árvore mas uma taxa de acerto intermediária.

Tabela 12: Dados dos modelos gerados através dos testes realizados - Sujeito 3

Teste	Canais	Instâncias		Objetos por folha	Tamanho árvore	Instâncias corretas
1	32	164348		1%	131	37.89%
				10%	9	35.67%
2	15	164348		1%	87	36.70%
				10%	11	35.38%
3	32	85622		1%	137	39.38%
				10%	9	35.70%
4	32	78726		1%	153	40.50%
				10%	11	37.00%
5	32	16384		1%	31	36.50%
				10%	11	36.73%
6	15	16384		1%	11	35.26%
				10%	5	35.88%
7	32	25	5108	1%	53	40.78%
				10%	3	36.42%
		50	2554	1%	15	54.24%
				10%	11	38.86%
100	1405	1%	71	52.07%		
				10%	15	43.00%

O teste 7 foi escolhido para o sujeito 4. A fim de manter um padrão para os dados analisados levou-se em consideração os testes escolhidos para os demais sujeitos. Neste caso a Tabela 13 o teste 7 apresenta árvores com taxa de acerto maior 50% porém com árvores de tamanho grande. O modelo escolhido foi o com janela de 50, com número mínimo de objetos por folha de 10%, tamanho 5 e taxa de 45.54%.

Tabela 13: Dados dos modelos gerados através dos testes realizados - Sujeito 4

Teste	Canais	Instâncias		Objetos por folha	Tamanho árvore	Instâncias corretas
1	32	104728		1%	95	46.38%
				10%	7	44.01%
2	15	104728		1%	51	45.32%
				10%	7	43.91%
3	32	54450		1%	133	43.90%
				10%	13	39.38%
4	32	50278		1%	107	45.77%
				10%	11	40.94%
5	32	10423		1%	93	45.17%
				10%	9	39.09%
6	15	10423		1%	15	37%
				10%	7	37%
7	32	25	4347	1%	43	48.19%
				10%	7	43.82%
		50	2173	1%	65	51.54%
				10%	5	45.54%
100	1086	1%	153	70.62%		
		10%	3	44.56%		

Entretanto, como pode ser observado nas Tabelas 10, 11, 12 e 13, as colunas tamanho da árvore e instâncias classificadas corretamente, não indicam valores adequados para satisfazer este trabalho, pois não apresentam uma boa relação de tamanho da árvore e taxa de correção.

Diante dos resultados indicados nas tabelas 10, 11, 12 e 13, a técnica de árvore de decisão pode classificar melhor os elementos caso os parâmetros permitam que ela seja maior, o que daria maior capacidade de distinção entre as instâncias. Então, se o objetivo do trabalho fosse fazer classificação dos dados poucos testes apresentam taxa de acerto maior que 50%. Mas já que o objetivo deste trabalho é o entendimento dos sinais cerebrais através da visualização das árvores de decisão, considerou-se que os testes 7 apresentam boa relação entre o tamanho da árvore e a taxa de correção, mesmo não sendo maior que 50%, pois as árvores são pequenas e favorecem a interpretação.

5.5.1 Modelos gerados

5.5.1.1 Sujeito 1 - Vidente

Os dados utilizados para gerar a árvore do sujeito 1, apresentam um total de 1037 instâncias, com 328 para o cubo, 327 para paralelogramo e 382 para a pirâmide (Figura 29). Esses dados são referentes ao teste 7 (seção 5.5). Neste caso foram utilizados os dados do maior eletrodo em uma janela de 100 instâncias, com o número mínimo de objetos de 10%. A árvore gerada apresentou taxa de acerto de 46.2%.

Selected attribute				
Name: class		Distinct: 3		Type: Nominal
Missing: 0 (0%)				Unique: 0 (0%)
No.	Label	Count		Weight
1	cubo	328		328.0
2	parale	327		327.0
3	piramide	382		382.0

Class: class (Nom) Visualize All




Figura 29: Número de instâncias por classe - Sujeito 1. No gráfico de barras o eixo x quando selecionado mostra o valor do atributo escolhido; eixo Y apresenta o número de instâncias de cada classe. (1) representa o número de instâncias da classe cubo; (2) o número de instâncias da classe paralelogramo; (3) número de instâncias da classe pirâmide.

Os canais que apresentaram atividade significativa no modelo apresentado conforme a Figura 30 foram: TP10, CP6, FP1, F7, FP2, O1 e F3. Os canais FP1, F7, FP2 e F3 correspondem ao lobo frontal, que de acordo com a Tabela 7 é responsável pelas funções executivas e gerenciamento dos recursos cognitivos; o canal TP10 pertence ao lobo temporal, o qual trata da percepção de movimentos biológicos; o canal CP6, pertence ao lobo parietal e é responsável pelo sentido tátil. O canal O1 pertence ao lobo occipital onde ocorre o processamento das imagens.

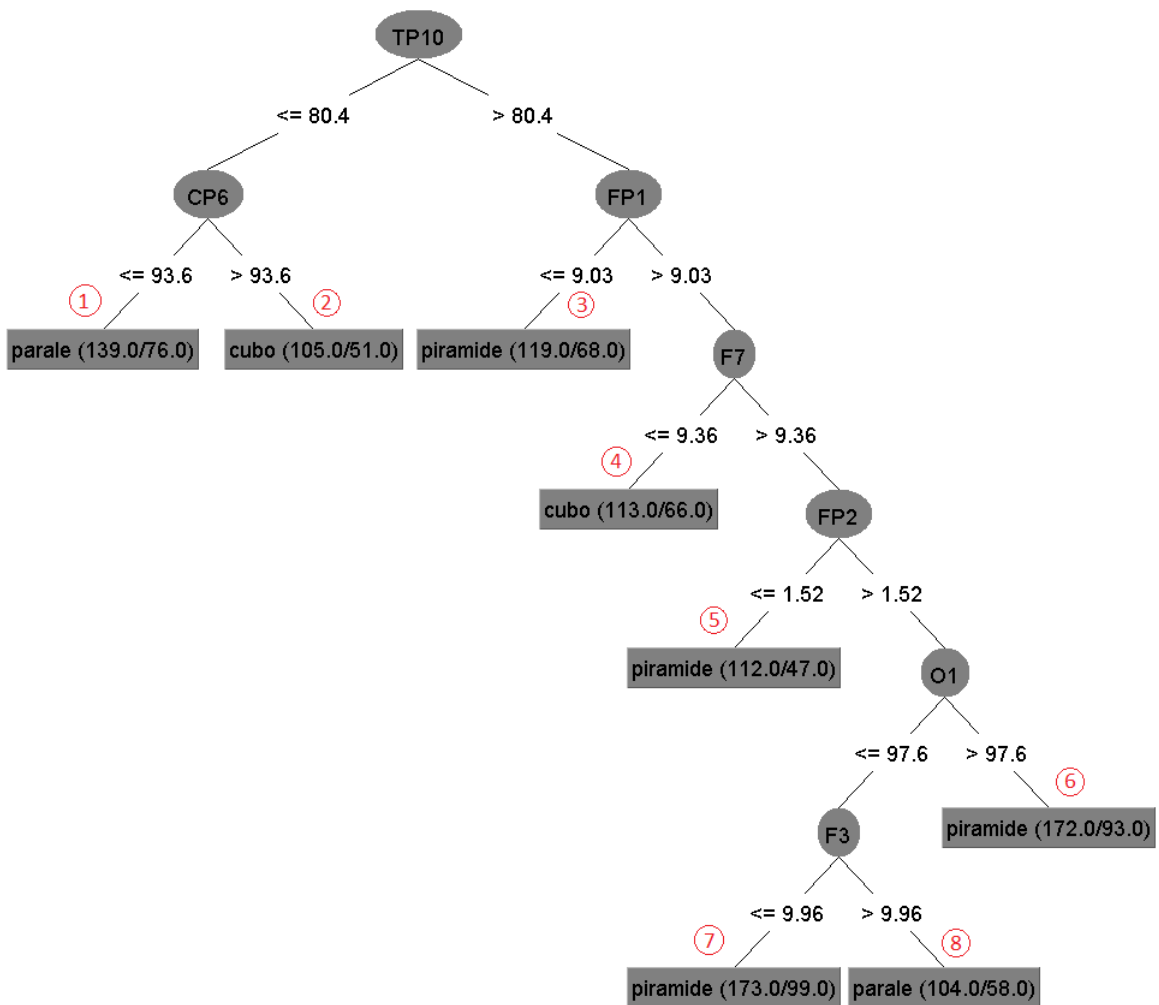


Figura 30: Árvore gerada a partir do algoritmo J48 - Sujeito 1. Os números circulados em vermelho representam os possíveis caminhos para a classificação de cada tarefa.

Através do modelo gerado (Figura 30), podemos verificar que o sujeito 1 apresentou as seguintes caminhos:

Tabela 14: Caminhos apresentados na árvore gerada para a classificação das tarefas - Sujeito 1

Caminho	Canais	Classe
1	TP10, CP6	Paralelogramo
2	TP10,CP6	Cubo
3	TP10, FP1	Pirâmide
4	TP10, FP1, F7	Cubo
5	TP10, FP1, F7, FP2	Pirâmide
6	TP10, FP1, F7, FP2,O1	Pirâmide
7	TP10, FP1, F7, FP2,O1,F3	Pirâmide
8	TP10, FP1, F7, FP2,O1,F3	Paralelogramo

Na Tabela 14 os caminhos 6,7 e 8 mostram que o sujeito 1, vidente, apresentou atividade relevante no canal O1, que pertence ao lobo occipital, para fazer o reconhecimento dos objetos que são respectivamente: Pirâmide, Paralelogramo e Pirâmide.

5.5.1.2 Sujeito 2 - Vidente

Os dados utilizados para gerar o modelo do sujeito 2 apresentam 1037 instâncias, sendo 442 para cubo, 509 para o paralelogramo e 454 para a pirâmide (31). A árvore ilustrada na Figura 32 foi executada com o algoritmo J48 e refere-se ao um vidente. Os dados são referentes ao teste 7 (seção 5.5), com os maiores valores dos canais em uma janela de 100 instâncias. Utilizando a configuração de números mínimos por objetos, na ferramenta Weka, de 10% apresentou uma árvore de tamanho 11 e taxa de acerto de 44.19%.

Selected attribute

Name: class
Missing: 0 (0%)
Distinct: 3
Type: Nominal
Unique: 0 (0%)

No.	Label	Count	Weight
1	cubo	442	442.0
2	parale	509	509.0
3	piramide	454	454.0

Class: class (Nom) Visualize All




Figura 31: Número de instâncias por classe - Sujeito 2. No gráfico de barras o eixo x quando selecionado mostra o valor do atributo escolhido; eixo Y apresenta o número de instâncias de cada classe. (1) representa o número de instâncias da classe cubo; (2) o número de instâncias da classe paralelogramo; (3) número de instâncias da classe pirâmide.

Na Figura 32 observa-se que os canais que apresentaram atividade relevante foram: F3, OZ, T7, FT9 e TP9. O lobo frontal F3 e FT9, responsável pelas funções cognitivas e raciocínio; T7 e TP9 o lobo temporal, é responsável pela percepção de movimentos biológicos e o lobo occipital, canal OZ que envolve a percepção visual, bem como o reconhecimento de objetos.

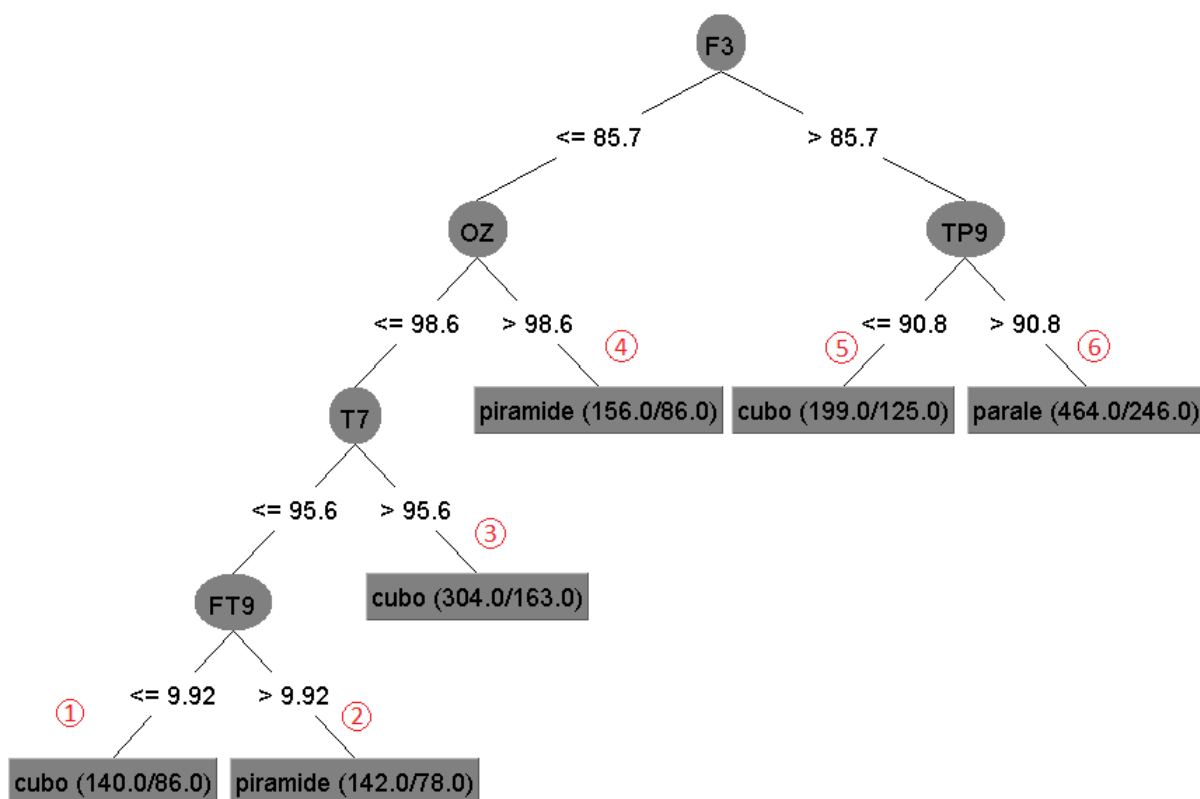


Figura 32: Árvore gerada a partir do algoritmo J48 - Sujeito 2. Os números circulados em vermelho representam os possíveis caminhos para a classificação de cada tarefa.

A árvore (Figura 32) apresenta os seguintes caminhos:

Tabela 15: Caminhos apresentados na árvore gerada para a classificação das tarefas

Caminho	Canais	Classe
1	F3, OZ, T7, FT9	Cubo
2	F3, OZ, T7, FT9	Pirâmide
3	F3, OZ, T7	Cubo
4	F3, OZ	Pirâmide
5	F3, TP9	Cubo
6	F3, TP9	Paralelogramo

Os caminhos 1,2,3 e 4 extraídos a partir da árvore representada na Figura 32 indicam que o canal OZ está presente nos caminhos que atingem as classes cubo e pirâmide, mostrando que o indivíduo 2 apresentou atividade relevante no lobo occipital durante a realização da tarefa de identificação desses objetos.

5.5.1.3 Sujeito 3 - Cego

A Figura 33 apresenta os número de instâncias por classe utilizada para executar o algoritmo J48 do sujeito 3, tendo um número total de instâncias de 1405. A Figura 34 apresenta o modelo gerado a partir de dados referentes ao teste 7 (seção 5.5). O modelo apresentou 43% de taxa de acerto para os dados com os maiores valores e janela de 100.

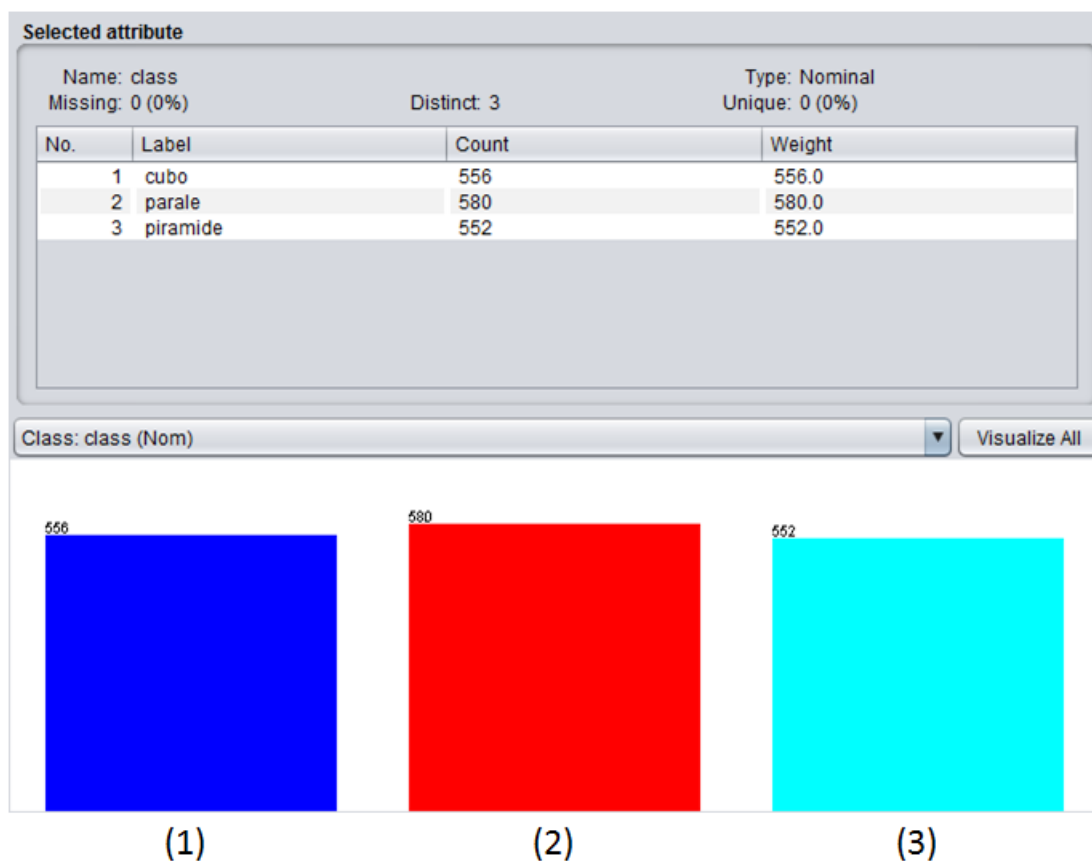


Figura 33: Número de instâncias por classe - Sujeito 3. No gráfico de barras o eixo x quando selecionado mostra o valor do atributo escolhido; eixo Y apresenta o número de instâncias de cada classe. (1) representa o número de instâncias da classe cubo; (2) o número de instâncias da classe paralelogramo; (3) número de instâncias da classe pirâmide.

Os canais existentes na árvore e suas respectivas áreas cerebrais são: TP9 e T7, lobo temporal; FZ e F7, lobo frontal e CP6, lobo parietal. A análise feita através da Tabela 7, mostra que as funções envolvidas para o reconhecimento do objeto foram principalmente: percepção de movimentos biológicos (lobo temporal, TP9 e T7); sensação tátil (lobo parietal, CP6); e a área frontal (FZ, F7) responsável pela tomada de decisão e planejamento dos movimentos.

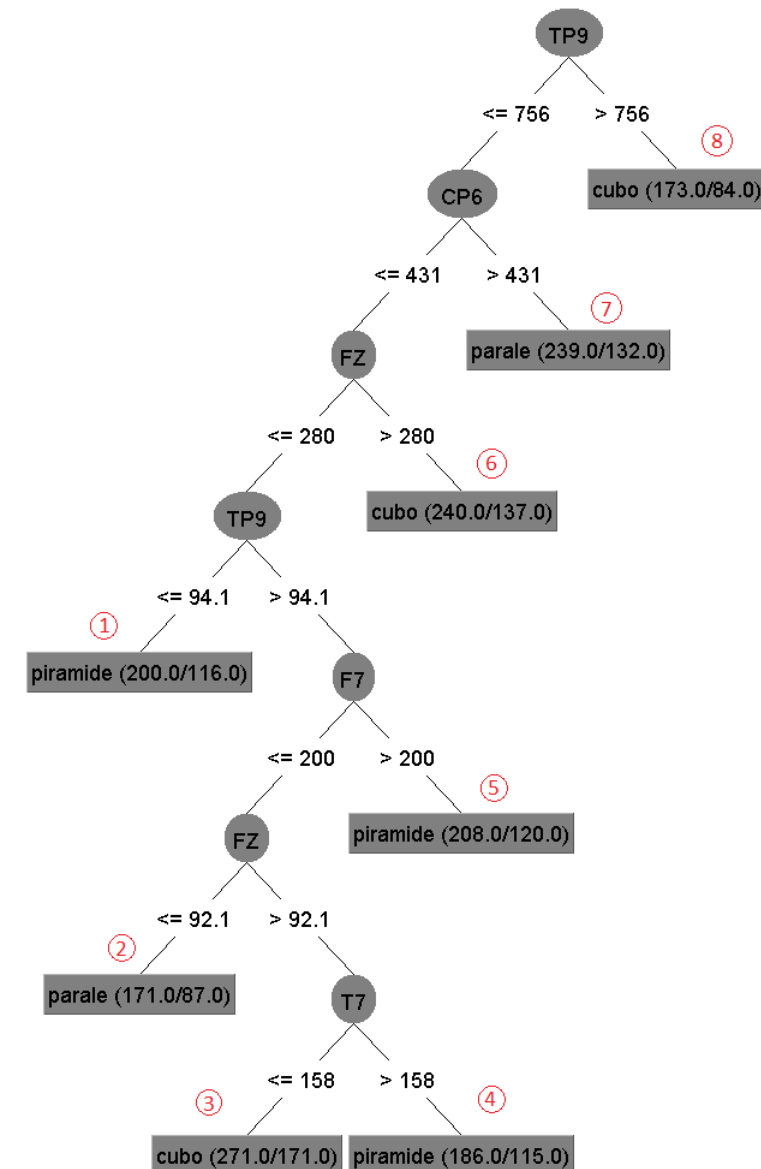


Figura 34: Árvore gerada a partir do algoritmo J48 - Sujeito 3. No gráfico de barras o eixo x quando selecionado mostra o valor do atributo escolhido; eixo Y apresenta o número de instâncias de cada classe. (1) representa o número de instâncias da classe cubo; (2) o número de instâncias da classe paralelogramo; (3) número de instâncias da classe pirâmide.

Os caminhos indicados a partir do modelo representado na Figura 34 são:

Tabela 16: Caminhos apresentados na árvore gerada para a classificação das tarefas

Caminho	Canais	Classe
1	TP9, CP6, FZ, TP9	Pirâmide
2	TP9, CP6, FZ, TP9, F7, FZ	Paralelogramo
3	TP9, CP6, FZ, TP9, F7, FZ, T7	Cubo
4	TP9, CP6, FZ, TP9, F7, FZ, T7	Pirâmide
5	TP9, CP6, FZ, TP9, F7	Pirâmide
6	TP9, CP6, FZ	Cubo
7	TP9, CP6	Paralelogramo
8	TP9	Cubo

Os caminhos mostrados através do modelo gerado para o sujeito 3, que é cego, não apresentaram atividade relevante na área occipital, pois os canais O1, OZ e O2 não foram apresentados no modelo para a classificação dos objetos. Entretanto, apresentou atividade relevante no lobo parietal (CP6) nos caminhos 1,2,3,4 e 5.

5.5.1.4 Sujeito 4 - Cego

A Figura 35 mostra o número de instâncias de cada classe dos dados utilizados para gerar a árvore do sujeito 4, com o algoritmo J48. Pode-se observar que o sujeito apresentou um número de instâncias significativamente maior para o objeto paralelogramo, com total de 934 instâncias. A diferença no número de instâncias ocorreu pelo fato do sujeito levar mais tempo para identificar o objeto paralelogramo. O modelo representado na Figura 36, gerou um modelo com 45% de taxa de acerto, utilizando os maiores valores em uma janela de 50 instâncias.

Selected attribute

Name: class
Missing: 0 (0%)

Distinct: 3

Type: Nominal
Unique: 0 (0%)

No.	Label	Count	Weight
1	cubo	480	480.0
2	parale	934	934.0
3	piramide	759	759.0

Class: class (Nom) Visualize All




Figura 35: Número de instâncias por classe - Sujeito 4. No gráfico de barras o eixo x quando selecionado mostra o valor do atributo escolhido; eixo Y apresenta o número de instâncias de cada classe. (1) representa o número de instâncias da classe cubo; (2) o número de instâncias da classe paralelogramo; (3) número de instâncias da classe pirâmide.

Através da árvore gerada do sujeito 4, cego congênito, observa-se atividade significativa nos canais O2 e P3. Estes canais envolvem duas grandes áreas, que é lobo occipital (O2), responsável pela capacidade visual e o lobo parietal (P3), que está empregado a função tátil.

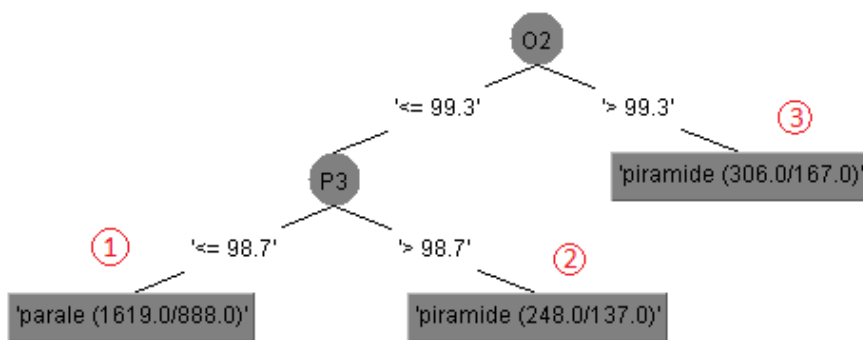


Figura 36: Árvore gerada a partir do algoritmo J48 - Sujeito 4. Os números circulos em vermelho representam os possíveis caminhos para a classificação de cada tarefa.

Os caminhos que podem ser indicados diante da árvore gerada para o sujeito (Figura 36) são:

Tabela 17: Caminhos apresentados na árvore gerada para a classificação das tarefas.

Caminho	Canais	Classe
1	O2	Pirâmide
2	O2, P3	Paralelogramo
3	O2, P3	Pirâmide

Neste caso todos os caminhos gerados apresentam atividade relevante no canal O2, que está localizado no lobo occipital e os caminhos 2 e 3 mostram atividade relevante no canal P3 do lobo parietal.

5.6 Análise e Discussão dos dados

Segundo (GARDNER, 1995) existe um sistema perceptual comum entre a modalidade tátil e visual, em que indivíduos que possuem visão normal conseguem atingir *insights* a partir de uma combinação de modalidades que são acessíveis aos cegos somente a partir da esfera tátil.

Sendo assim a hipótese deste trabalho sugere que indivíduos videntes e cegos utilizam diferentes áreas do cérebro para “visualizar” objetos espaciais. Videntes, utilizam o lobo occipital, que é responsável pela visualização, e cegos prioritariamente o lobo parietal, área responsável pela percepção tátil.

A fim de verificar a hipótese em questão foram realizados testes utilizando árvore de decisão com o algoritmo J48 no software de mineração de dados Weka. As árvores ge-

radas através da execução do algoritmo J48 não apresentaram taxas de acerto satisfatória para uma tarefa de classificação. Uma vez que o a ideia deste trabalho não é classificar os dados, é importante salientar que para a análise do estudo de caso desta dissertação a taxa de acerto foi levada em consideração para a seleção das árvores que foram apresentadas. Todavia, a taxa de acerto não foi determinante para o entendimento dos caminhos dos eletrodos, já que o intuito foi analisar visualmente as árvores geradas para verificar e compreender as atividades cerebrais durante a identificação dos objetos geométricos.

A Tabela 18 apresenta o resumo das áreas que tiveram algum canal nas ramificações das árvores geradas para cada sujeito. Com base na Tabela 18 verifica-se que os sujeitos videntes (sujeito 1 e 2) utilizaram o lobo occipital para a identificação de objetos espaciais, sugerindo que a hipótese de que videntes ativam o lobo occipital é verdadeira. Já os sujeitos cegos (sujeito 3 e 4) tiveram eletrodos que pertencem ao lobo parietal nas ramificações das árvores geradas, área que é responsável pela percepção tátil, indicando que a hipótese de que cegos utilizam o lobo parietal para identificar objeto também é verdadeira. No entanto, o sujeito 4 (cego) apresentou o canal O2 (lobo occipital) na árvore gerada. A relevância nos sinais cerebrais da área occipital pode decorrer da ideia de AMEDI et al. (2010) que o fato de que muitas vezes a ativação do córtex occipital indicou ser um reflexo dos processos de imagens visuais mentais desencadeadas por outras modalidades, ou seja, a ativação do lobo occipital durante o toque pode ser a base da plasticidade cruzada observada nos cegos congênitos.

Tabela 18: Áreas cerebral que estavam presente nos modelos de cada indivíduo. A letra X representa as áreas que apresentaram os canais nas ramificações das árvores geradas e NDA significa que a área não apresentou canais nas ramificações das árvores dos modelos gerados.

Área	Sujeito 1	Sujeito 2	Sujeito 3	Sujeito 4
Frontal	X	X	X	NDA
Temporal	X	X	X	NDA
Parietal	X	NDA	X	X
Occipital	X	X	NDA	X

Além disso, pode-se perceber que os sujeitos cegos utilizam outras habilidades além do tato para fazer o reconhecimento dos objetos, fato que vai ao encontro da afirmação de VIVEIROS (2013) que pessoas que nascem ou perdem a capacidade de enxergar utilizam de outros sentidos para compensar a ausência da visão.

Ainda que os sujeitos cegos e videntes tenham apresentado resultados positivos para a hipótese colocada neste trabalho, entende-se a necessidade de realizar inúmeros testes.

6 CONSIDERAÇÕES FINAIS

Este trabalho envolve diferentes áreas do conhecimento, como ciência da computação, neurociências e biologia.

A neurociência é o estudo científico do sistema nervoso, que abrange o seu funcionamento, desenvolvimento e estrutura. Sendo o cérebro o principal componente do sistema nervoso, é através do seu funcionamento que se exercem processos mentais como concentração, pensamento, capacidade de aprendizado e controle motor.

O EEG é baseado em registros de atividade elétrica cerebral medida na superfície do escalpo. Alterações muito pequenas na atividade elétrica dentro do cérebro são captadas pelos eletrodos (EYSENCK; KEANE, 2010). Sendo assim, esses equipamentos possuem alta resolução temporal, capaz de medir a atividade em pequenos períodos de tempo, como em milésimo de segundo. O EEG é muitas vezes utilizado com os BMI's, que são ferramentas que permitem a comunicação entre indivíduos e máquinas externas, sem que exista estímulos musculares criados pelo cérebro (MACHADO et al., 2009). Essas ferramentas permitem que se apliquem técnicas de captura de sinais cerebrais não invasivas que podem fornecer informações elétricas das regiões do cérebro (SILVEIRA, 2013). Este estudo utilizou a coleta de sinais cerebrais não invasiva, em que os dados dos sinais cerebral foram gravados, o que permitiu o tratamento e análise dos dados, como a aplicação de técnicas de árvores de decisão.

As ADs consistem em classificadores que apresentam uma estrutura de árvore condicional, em que cada nó especifica um teste que irá ser realizado em um único atributo, são utilizadas como ferramentas de classificação e previsão de dados. As ADs geram regras que explicam o comportamento dos dados e um modelo de classificação (SILVEIRA, 2013). Além disso geram modelos fáceis de entender e interpretar.

Este trabalho teve como objetivo apresentar uma metodologia para o uso de árvores de decisão como meio de compreender a atividade cerebral a partir de um estudo de caso com o reconhecimento de objetos espaciais.

Os passos da metodologia proposta foram aplicados no estudo de caso, que analisou sinais EEG de indivíduos cegos e videntes com o algoritmo J48. A metodologia mostrou-se viável, pois uma vez seguindo as etapas propostas, ao final do estudo de caso, foram

gerados modelos de árvores de decisão que permitiram sugerir que a hipótese é verdadeira. A aplicação da técnica de árvore de decisão mostrou-se cabível para análise dos sinais EEG, indicando os canais com atividade relevante para o processo de identificação dos objetos.

Retomando a hipótese de que videntes e cegos utilizam áreas diferentes do cérebro para “visualizar” objetos espaciais. Em videntes, prioritariamente o lobo occipital é ativado e em cegos, prioritariamente, o lobo parietal é ativado. Sugere-se a confirmação desta hipótese para os sujeitos videntes que indicaram atividade significativa no lobo occipital e os cegos que apresentaram atividade relevante no lobo parietal.

Através das análises dos modelos gerados neste trabalho, foi possível constatar que um dos sujeitos cegos apresentou atividade relevante no lobo occipital, assim como os videntes apresentaram atividade relevante na área parietal, indicando uma semelhança entre as atividades cerebrais dos sujeitos. Entretanto, uma vez que foram encontradas semelhanças e diferenças entre as árvores geradas para cada sujeito, que pode ser explicado com base na afirmação de SILVEIRA (2013) e na neurociências (LENT, 2008), o cérebro desempenha determinadas funções em regiões específicas para todos os seres humanos, mas também, cada sujeito pode executar uma mesma tarefa de maneira própria. Ao manipular um objeto com as mãos, por exemplo, os indivíduos podem imaginar os objetos ou também apresentar estímulos nas áreas responsáveis pela execução motora, o que pode resultar em muitos sinais em áreas cerebrais diferentes.

Neste contexto surgem os questionamentos: cegos congênitos realmente apresentam atividade significante no lobo occipital? O lobo occipital apresentará atividade significativa durante uma tarefa de imaginação de objetos espaciais? Será possível encontrar algum padrão entre os caminhos apresentados pelas árvores geradas dos sujeitos? Com isso, entende-se que este estudo é inicial e a necessidade de realizar um número maior de testes.

Além disso, entende-se a necessidade de levar em consideração o problema de condução de volume, através da aplicação de técnicas de separação cega de fontes, que trata basicamente em recuperar o conjunto de sinais (fontes) a partir da observação (feita através dos eletrodos) que são misturas desconhecidas de sinais, ou seja, os sinais elétricos dos canais podem interferir um nos outros (LEITE, 2004). Em busca de aprimorar este trabalho, baseado nas questões levantadas, vislumbra-se como trabalhos futuros:

- Realizar teste com um número maior de indivíduos, a fim de obter maior precisão nos resultados;
- Aplicar a metodologia proposta com um protocolo diferente, neste caso outras atividades que não envolvam somente a manipulação de objetos geométricos;
- Diferentes parâmetros utilizando ADs;

- Utilizar outros softwares para aquisição dos sinais cerebrais;
- Utilizar outras técnicas de mineração de dados;
- Aplicar técnica de separação cega de fontes;
- Aplicar técnicas de visão computacional.

Como resultados destacam-se as publicação dos seguintes trabalhos:

- Discovering Patterns In Brain Signals Using Decision Trees. Computational Intelligence and Neuroscience, 2016, p. 1-10. DOI: 10.1155/2016/6391807
- Using Decision Trees to Analyse Brain Signals in Spacial Activities. Brain Informatics and Health - LNAI 9919, 1ed.Berlin / Alemanha: Springer, 2016, p. 377-385. DOI: 10.1007/978-3-319-47103-7_37

REFERÊNCIAS

ADAMATTI, D. F.; SILVEIRA, J.; CARVALHO, F. Analyzing brain signals using decision trees: an approach based on neuroscience. **Revista Eletrônica Argentina-Brasil de Tecnologias da Informação e da Comunicação**, [S.l.], v.1, n.5, 2016.

ALENCAR, A. B. **Mineração e visualização de coleções de séries temporais**. 2007. Dissertação (Mestrado em Ciência da Computação) — Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo.

ALMEIDA, M. E. B. de. **ProInfo: Informática e formação de professores**. [S.l.]: Ministério da Educação, Secretaria de Educação a Distância, 2000.

ALVARENGA, M. T. **Utilização da ferramenta j48 para descoberta do conhecimento em bases de dados fitossanitários, climáticos e espectrais**. 2015. Dissertação (Mestrado em Ciência da Computação) — Universidade Federal de Lavras.

AMEDI, A.; RAZ, N.; AZULAY, H.; MALACH, R.; ZOHARY, E. Cortical activity during tactile exploration of objects in blind and sighted humans. **Restorative neurology and neuroscience**, [S.l.], v.28, n.2, p.143–156, 2010.

AMO, S. de. Técnicas de mineração de dados. **Jornada de Atualização em Informática**, [S.l.], 2004.

BASTOS, N. S.; ADAMATTI, D. F.; CARVALHO, F. A. de. Development of logic skills in high school students: a proposal based on neuroscience. **Brazilian Journal of Computers in Education**, [S.l.], v.24, n.01, p.53, 2016.

BRASIL. **Subsídios para a Organização e Funcionamento de serviços de educação especial**. [S.l.]: , Ministério da Educação e do Desporto, Secretária de Educação Especial, 1995.

BÜCHEL, C.; PRICE, C.; FRACKOWIAK, R.; FRISTON, K. Different activation patterns in the occipital cortex of late and congenitally blind subjects. **NeuroImage**, [S.l.], v.5, n.4 PART, p.S20, 1997.

BURTON, H.; SNYDER, A.; DIAMOND, J.; RAICHLE, M. Adaptive changes in early and late blind: a fMRI study of verb generation to heard nouns. **Journal of Neurophysiology**, [S.l.], v.88, n.6, p.3359–3371, 2002.

CAMILO, C. O.; SILVA, J. C. d. Mineração de dados: Conceitos, tarefas, métodos e ferramentas. **Goiânia: Universidade Federal de Goiás**, [S.l.], 2009.

CAPELA, N. F.; GEORGIEVA, P. Aplicação de técnicas de aprendizagem automática para classificação de emoções humanas com sinais de EEG. **Eletrônica e Telecomunicações**, [S.l.], v.5, n.4, p.391–399, 2012.

CASTANHEIRA, L. G. Aplicação de técnicas de mineração de dados em problemas de classificação de padrões. **Belo Horizonte: UFMG**, [S.l.], 2008.

COHEN, L. G.; CELNIK, P.; PASCUAL-LEONE, A.; CORWELL, B.; FAIZ, L.; DAMBROSIA, J.; HONDA, M.; SADATO, N.; GERLOFF, C.; CATALÁ, M. D. et al. Functional relevance of cross-modal plasticity in blind humans. **Nature**, [S.l.], v.389, n.6647, p.180–183, 1997.

COSENZA, R.; GUERRA, L. **Neurociência e Educação**. Artmed.ed. [S.l.: s.n.], 2011.

DAMASCENO, M. Introdução a Mineração de Dados Utilizando o Weka. **Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Norte**, [S.l.], 2005.

DEVÊZA, C. H. **Minerando Padrões Sequenciais para Base de Dados de Lojas Virtuais**. Monografia (Curso de Bacharelado em Ciência da Computação), UFOP (Universidade Federal de Ouro Preto).

EYSENCK, M. W.; KEANE, M. T. **Manual de psicologia cognitiva**. [S.l.]: Artmed, 2010.

EYZAGUIRRE, C. **Fisiologia do sistema nervoso**. [S.l.]: RJ: Guanabara Koogan, 1977.

FAYYAD, U.; PIATETSKY-SHAPIRO, G.; SMYTH, P. From data mining to knowledge discovery in databases. **AI magazine**, [S.l.], v.17, n.3, p.37, 1996.

GARCIA, S. C. **O uso de árvores de decisão na descoberta de conhecimento na área da saúde**. 2003. Tese (Doutorado em Ciência da Computação) — UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL.

GARDNER, H. **Inteligências múltiplas**. [S.l.]: Porto Alegre: Artes Médicas, 1995.

GAZZANIGA, M. S.; HEATHERTON, T. F.; VERONESE, M. A. V. **Ciência psicológica: mente, cérebro e comportamento**. [S.l.]: Artmed, 2005.

GIL, M. Cadernos da TV Escola–Deficiência Visual. , [S.l.], 2000. Ministério da Educação – Secretária de Educação a Distância. <http://portal.mec.gov.br/seed/arquivos/pdf/deficienciavisual.pdf>.

ISHFAQUE, A.; AWAN, A. J.; RASHID, N.; IQBAL, J. Evaluation of ANN, LDA and Decision trees for EEG based Brain Computer Interface. In: IEEE 9TH INTERNATIONAL CONFERENCE ON EMERGING TECHNOLOGIES (ICET), 2013., 2013. **Anais...** [S.l.: s.n.], 2013. p.1–6.

KASTRUP, V. A invenção na ponta dos dedos: a reversão da atenção em pessoas com deficiência visual. **Psicologia em Revista**, [S.l.], v.13, n.1, p.69–90, 2007.

KUGLER, M. **Uma Contribuição ao Desenvolvimento de Interfaces Cérebro-computador Utilizando Potenciais Visualmente Evocados**. 2003. Tese (Doutorado em Ciência da Computação) — Centro Federal de Educação Tecnológica do Paraná, Curitiba.

LEITE, V. C. M. N. **Separação Cega de Sinais: Análise Comparativa entre Algoritmos**. 2004. Tese (Doutorado em Ciência da Computação) — UNIVERSIDADE FEDERAL DE ITAJUBÁ.

LENT, R. **Cem bilhões de neurônios: conceitos fundamentais de neurociência**. [S.l.]: Atheneu, 2004.

LENT, R. **Neurociência da mente e do comportamento**. [S.l.: s.n.], 2008.

LIBRELOTTO, S. R.; MOZZAQUATRO, P. M. Análise dos Algoritmos de Mineração J48 e Apriori Aplicados na Detecção de Indicadores da Qualidade de Vida e Saúde. **Revista Interdisciplinar de Ensino, Pesquisa e Extensão**, [S.l.], v.1, n.1, 2014.

LOCH, R. E. N. Cartografia tátil: mapas para deficientes visuais. **Portal de Cartografia das Geociências**, [S.l.], v.1, n.1, p.36–58, 2008.

LUCAS, A. d. M. **Utilização de técnicas de mineração de dados considerando aspectos temporais**. 2002. Tese (Doutorado em Ciência da Computação) — UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL.

MACHADO, S.; CUNHA, M.; VELASQUES, B.; MINC, D.; HUGO, V.; BASTOS, H. B.; CAGY, M.; PIEDADE, R.; RIBEIRO, P. Interface cérebro-computador: novas perspectivas para a reabilitação. **Revista Neurociências**, [S.l.], v.17, n.4, p.329–335, 2009.

MASINI, E. F. S. A educação do portador de deficiência visual: as perspectivas do vidente e do não vidente. **Aberto**, [S.l.], p.61–76, 1994.

OLIVEIRA, I.; CARRIÇO, L.; GUIMARÃES, N.; CHAMBEL, T.; TEIXEIRA, C. **Interfaces Computador-Cérebro: Extração e Processamento de Características de Electroencefalogramas**. [S.l.]: Department of Informatics, University of Lisbon, 2008.

PRADA, B. M. L. **Interface cérebro-computador não invasiva baseada em OpenVibe**. 2010. Dissertação (Mestrado em Ciência da Computação) — Universidade de Aveiro.

PURVES, D.; AUGUSTINE, G. J.; FITZPATRICK, D.; KATZ, L. C.; LAMANTIA, A. S.; MCNAMARA, J. O. **Invitación a la Neurociência**. [S.l.]: Editorial Médica Panamericana SA, 2001.

RABÊLLO, R. S. **Teatro-Educação: uma experiência com jovens cegos**. [S.l.]: EDUFBA, 2011. Salvador - Bahia.

RANGEL, M. L.; DAMASCENO, L. A.; SANTOS FILHO, C. A. I. d.; OLIVEIRA, F. S. d.; JAZENKO, F.; GAWRYSZEWSKI, L. G.; PEREIRA, A. Deficiência visual e plasticidade no cérebro humano. **Psicología: teoria e prática**, [S.l.], v.12, n.1, p.197–207, 2010.

SÁ, E. D. de; CAMPOS, I. M. de; SILVA, M. B. C. **Atendimento educacional especializado: deficiência visual**. [S.l.]: MEC, SEESP, 2007.

SADATO, N.; OKADA, T.; HONDA, M.; YONEKURA, Y. Critical period for cross-modal plasticity in blind humans: a functional MRI study. **Neuroimage**, [S.l.], v.16, n.2, p.389–400, 2002.

SILVEIRA, J. A. **Análise de Sinais Cerebrais Utilizando Árvores de Decisão**. 2013. Dissertação (Mestrado em Ciência da Computação) — Universidade Federal do Rio Grande.

SILVEIRA NUNES, S. da; LOMÔNACO, J. F. B. Desenvolvimento de conceitos em cegos congênitos: caminhos de aquisição do conhecimento. **Psicologia escolar e educacional**, [S.l.], v.12, n.1, p.119–138, 2008.

SILVERTHORN, D. U. **Fisiologia humana: uma abordagem integrada**. [S.l.]: Artmed, 2010.

SMITH, D. D. **Introdução á educação especial: ensinar em tempos de inclusão**. [S.l.]: Artmed, 2008.

SOCIETY, A. C. N. et al. Guideline 5: Guidelines for standard electrode position nomenclature. **American journal of electroneurodiagnostic technology**, [S.l.], v.46, n.3, p.222, 2006.

STERNBERG, R. J.; OSÓRIO, M. R. B. **Psicologia cognitiva**. [S.l.]: Cengage Learning, 2000.

TAN, P.-N.; STEINBACH, M.; KUMAR, V. et al. **Introduction to data mining**. [S.l.]: Pearson Addison Wesley Boston, 2006. v.1.

TAVARES, C.; BOZZA, D.; KONO, F. Descoberta de conhecimento aplicado a dados eleitorais. **Revista Gestão e Conhecimento**, [S.l.], v.5, n.1, p.54–94, 2007.

TEENAGERS, V. I.; SEXUALITY, p. o. Adolescentes portadores de deficiência visual: percepções sobre sexualidade. **Rev Latino-am Enfermagem**, [S.l.], v.14, n.2, p.220–6, 2006.

VALLABHANENI, A.; WANG, T.; HE, B. Brain Computer Interface. In: **Neural engineering**. [S.l.]: Springer, 2005. p.85–121.

VELLOSO, B. P.; PEREIRA, A. T. C. Sistema de monitoramento de atenção baseado em eletroencefalografia para avaliação de objetos de ensino e aprendizagem. **Nuevas Ideas en Informática Educativa TISE**, [S.l.], 2014.

VENTORINI, S. E. **A experiência como fator determinante na representação espacial do deficiente visual**. [S.l.]: Universidade Estadual Paulista (UNESP), 2007.

VIVEIROS, E. R. d. **Mindware semiótico-comunicativo**: campos conceituais no ensino de física para deficientes visuais utilizando uma interface cérebro-computador. 2013. Tese (Doutorado em Ciência da Computação) — Universidade Estadual Paulista (UNESP).

WANG, B.; WONG, C. M.; WAN, F.; MAK, P. U.; MAK, P. I.; VAI, M. I. Comparison of different classification methods for EEG-based brain computer interfaces: A case study. In: INTERNATIONAL CONFERENCE ON INFORMATION AND AUTOMATION, 2009., 2009. **Anais...** [S.l.: s.n.], 2009. p.1416–1421.

ANEXO 1

PARECER CONSUBSTANCIADO DO CEP

DADOS DO PROJETO DE PESQUISA

Título da Pesquisa: Utilização de sinais cerebrais aplicados a computação

Pesquisador: Narúsci dos Santos Bastos

Área Temática:

Versão: 2

CAAE: 45606915.8.0000.5324

Instituição Proponente: Universidade Federal do Rio Grande - FURG

Patrocinador Principal: Financiamento Próprio

DADOS DO PARECER

Número do Parecer: 1.247.981

Apresentação do Projeto:

O projeto em questão trata-se do estudo sobre sinais cerebrais e suas aplicações em computação. Ele está dividido em quatro subprojetos: i) estudo de sinais cerebrais em pessoas com deficiência visual; ii) estudo de sinais cerebrais em estudantes iniciantes e em final de curso de graduação; iii) estudo de sinais cerebrais em compras via web, também chamado de social commerce; e iv) estudo de sinais cerebrais em pessoas com medos ou

fobias. Nesse projeto, o maior objetivo é estudar o funcionamento do cérebro, fundamentado na neurociência, visando diversos aspectos (cegos, estudantes universitários, medos, compras, etc). Para este fim serão realizados estudos sobre neurociências e aplicação de técnicas de BCI (Brain Computer Interface). Como ferramenta para coleta dos sinais cerebrais é utilizado o ActChamp. Para todos os subprojetos, protocolos para coleta de dados foram definidos, com intuito de definir as situações de coleta e as hipóteses pensadas para cada caso. Espera-se, ao final dos subprojetos, que uma melhor compreensão das regiões cerebrais possa ser tida.

Objetivo da Pesquisa:

Objetivo Primário:

Investigar as regiões cerebrais durante a realização de atividades específicas, sob a luz da neurociências.

Endereço: Rua Visconde Paranaguá, 112/Hospital Universitário

Bairro: Campus Saúde

CEP: 96.201-900

UF: RS

Município: RIO GRANDE

Telefone: (53)3237-4652

Fax: (53)3233-6822

E-mail: cepas@furg.br

Continuação do Parecer: 1.247.981

Objetivo Secundário:

PROJETO 1: Identificar através de coleta de sinais cerebrais quais áreas do cérebro responde a determinados estímulos.

PROJETO 2: Estudantes Universitários : Estudar como funciona o cérebro e suas divisões para entendimento das capacidades cognitivas.

PROJETO 3: Extrair, analisar e reportar os indicadores cognitivos utilizados pelos usuários de e-commerce na tomada de decisão ao comprar um produto, frente a influência das redes sociais.

PROJETO 4: Investigar quais os sinais cerebrais que são produzidos quando o sujeito é afetado pelo medo com o auxílio da realidade virtual.

Avaliação dos Riscos e Benefícios:

Riscos:

Com relação aos riscos, a utilização do aparelho para coleta de sinais cerebrais não apresenta nenhum tipo de constrangimento ou desconforto aos participantes.

Benefícios:

Os benefícios advindos da participação dos sujeitos são de que esta pesquisa tem por maior finalidade compreender a influencia das atividades experimentais na pesquisa e, reconhecendo que pesquisas podem originar intervenções, acredita-se que os resultados possam apresentados no trabalho, juntamente com os resultados alcançados na pesquisa teórica advinda da articulação entre a educação, poderão gerar argumentos para repensar do fazer docente.

Comentários e Considerações sobre a Pesquisa:

A pesquisa é relevante do ponto de vista científico, é preciso considerar, no entanto que alguns fatos não foram considerados.

Considerações sobre os Termos de apresentação obrigatória:

Abaixo.

Recomendações:

Abaixo.

Conclusões ou Pendências e Lista de Inadequações:

Abaixo.

Considerações Finais a critério do CEP:

PARECER Nº 130/2015

Endereço: Rua Visconde Paranaguá,112/Hospital Universitári

Bairro: Campus Saúde

CEP: 96.201-900

UF: RS

Município: RIO GRANDE

Telefone: (53)3237-4652

Fax: (53)3233-6822

E-mail: cepas@furg.br

Continuação do Parecer: 1.247.981

CEPAS 76/2015

CAAE: 45606915.8.0000.5324

Processo: 23116.005346/2015-97

Título da Pesquisa: Utilização de sinais cerebrais aplicados a computação

Pesquisador Responsável: Narúsci dos Santos Bastos

PARECER DO CEPAS:

O Comitê considerou tratar-se de um projeto relevante, justificando seu desenvolvimento, mas, analisando sob o ponto de vista ético, considerou-o PENDENTE, devendo o responsável responder sobre:

1. É necessário a apresentação dos projetos individualmente, com suas especificidades e caracterização metodológica para cada um;
2. Apresentar os Termos de Consentimento Livre e Esclarecido impressos e individuais, para cada projeto;
3. Apresentar avaliação de Riscos e Benefícios nos Termos de Consentimento Livre e Esclarecido individuais e nas Metodologias dos projetos, explicando as medidas a serem tomadas e as soluções propostas, mesmo que a pesquisa envolva riscos mínimos, como por exemplo, algum tipo de constrangimento, desconforto ou mal-estar;
4. Apresentar na Metodologia, a descrição, mesmo que sucinta, do aparelho que será utilizado na pesquisa e seu funcionamento;
5. Especificar no delineamento das pesquisas a forma como a análise sensorial será obtida.

Rio Grande, RS, 22 de setembro de 2015.

Prof.^a Eli Sinnott Silva

Coordenadora do CEPAS/FURG

Endereço: Rua Visconde Paranaguá, 112/Hospital Universitário

Bairro: Campus Saúde

CEP: 96.201-900

UF: RS

Município: RIO GRANDE

Telefone: (53)3237-4652

Fax: (53)3233-6822

E-mail: cepas@furg.br

Continuação do Parecer: 1.247.981

Este parecer foi elaborado baseado nos documentos abaixo relacionados:

Tipo Documento	Arquivo	Postagem	Autor	Situação
Informações Básicas do Projeto	PB_INFORMAÇÕES_BÁSICAS_DO_PROJETO_509062.pdf	28/05/2015 16:44:07		Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	TCLE_subprojeto1.pdf	05/08/2015 15:41:47		Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	TCLE_subprojeto2.pdf	05/08/2015 15:42:04		Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	TCLE_subprojeto3.pdf	05/08/2015 15:42:16		Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	TCLE_subprojeto4.pdf	05/08/2015 15:42:32		Aceito
Outros	declaracao_publicos.pdf	05/08/2015 15:43:00		Aceito
Projeto Detalhado / Brochura Investigador	Projeto_CEPAS_novaVersao_Agosto.pdf	05/08/2015 15:43:29		Aceito
Folha de Rosto	HP0005.pdf	10/08/2015 14:38:34		Aceito
Informações Básicas do Projeto	PB_INFORMAÇÕES_BÁSICAS_DO_PROJETO_509062.pdf	10/08/2015 14:39:07		Aceito

Situação do Parecer:

Pendente

Necessita Apreciação da CONEP:

Não

RIO GRANDE, 28 de Setembro de 2015

**Assinado por:
Eli Sinnott Silva
(Coordenador)**

Endereço: Rua Visconde Paranaguá, 112/Hospital Universitário
Bairro: Campus Saúde **CEP:** 96.201-900
UF: RS **Município:** RIO GRANDE
Telefone: (53)3237-4652 **Fax:** (53)3233-6822 **E-mail:** cepas@furg.br

ANEXO 2

TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO AO DEFICIENTE VISUAL

Título do Projeto: Estudo sobre as regiões cerebrais utilizadas em atividades espaciais em estudantes cegos, utilizando sinais cerebrais com técnicas de mineração de dados

Colaborador voluntário: _____ RG: _____

Você está sendo convidado (a) a participar do projeto de pesquisa “Estudo sobre as regiões cerebrais utilizadas em atividades espaciais em estudantes cegos, utilizando sinais cerebrais com técnicas de mineração de dados”, de responsabilidade da pesquisadora Narúsci dos Santos Bastos. Você foi selecionado(a) por ser deficiente visual e maior de idade. A sua participação não é obrigatória e a qualquer momento você pode desistir de participar e retirar seu consentimento. Uma possível recusa não trará nenhum prejuízo em sua relação com o pesquisador ou com a instituição.

O objetivo deste estudo é identificar através da coleta de sinais cerebrais quais áreas do cérebro responde a determinados estímulos.

A participação nesta pesquisa será voluntária e consistirá em realizar uma atividade experimental e baseada em estímulos não invasivos, determinados pelos pesquisadores. Cabe destacar que a técnica de captura de imagens utilizada nesta pesquisa é também de caráter não invasivo.

Os benefícios relacionados com a participação não são diretos aos envolvidos, mas permite um melhor entendimento da atividade cerebral, possibilitando o desenvolvimento de equipamentos para pessoas com deficiências físicas num futuro próximo.

As informações obtidas através dessa pesquisa serão confidenciais e asseguramos o sigilo sobre sua participação. Os dados não serão divulgados de forma a possibilitar sua identificação, e caso seja necessário utilizar o nome será na forma de suas iniciais ou utilizando outro identificador, como nome de flores, por exemplo.

Você receberá uma cópia deste termo onde consta o telefone e o endereço institucional dos pesquisadores principais e do CEP, podendo tirar suas dúvidas sobre o projeto e sua participação, agora ou a qualquer momento.

Assinatura da pesquisadora

Eu, _____, RG nº _____ declaro ter sido informado e concordo com a minha participação, como voluntário, no projeto de pesquisa acima descrito.
Rio Grande, ____ de _____ de _____.

Responsável por obter o consentimento(assinatura e RG)

Testemunha (assinatura e RG)

Testemunha(assinatura e RG)

Pesquisadora : Narúsci dos Santos Bastos
Endereço Institucional: Universidade Federal do Rio Grande
Centro de Ciências Computacionais
Av. Itália, Km 8 - Campus Carreiros - Rio Grande - RS - BRASIL - 96201900 Telefone: +55 53 99953558
Email: nanahbastos@yahoo.com.br
Orientadora Profª Drª Diana Francisca Adamatti
Orientador Profº Drº Cleo Zanella Billa