

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

FACULDADE DE ENGENHARIA ELÉTRICA

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

ÊNFASE: PROCESSAMENTO DIGITAL DE SINAIS

**Aprendizado de máquina como ferramenta
para o prognóstico de pacientes em coma usando
sinais eletroencefalográficos no espectro de 1 a
100 Hz**

CAMILA DAVI RAMOS

ORIENTADOR: PROF. PhD. JOÃO-BATISTA DESTRO-FILHO

Uberlândia – MG
Janeiro, 2022.

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

FACULDADE DE ENGENHARIA ELÉTRICA

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

ÊNFASE: PROCESSAMENTO DIGITAL DE SINAIS

**Aprendizado de máquina como ferramenta
para o prognóstico de pacientes em coma usando
sinais eletroencefalográficos no espectro de 1 a
100 Hz**

CAMILA DAVI RAMOS

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Uberlândia, como parte dos requisitos para a obtenção do título de Doutor em Ciência, área de concentração: Processamento Digital de Sinais.
Orientador: Prof. PhD João Batista Destro Filho

Uberlândia – MG
Janeiro, 2022.

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU
com dados informados pelo(a) próprio(a) autor(a).

R175
2022

Ramos, Camila Davi, 1991-

Aprendizado de máquina como ferramenta para o
prognóstico de pacientes em coma usando sinais
eletroencefalográficos no espectro de 1 a 100 Hz
[recurso eletrônico] / Camila Davi Ramos. - 2022.

Orientador: João Batista Destro Filho.

Tese (Doutorado) - Universidade Federal de Uberlândia,
Pós-graduação em Engenharia Elétrica.

Modo de acesso: Internet.

Disponível em: <http://doi.org/10.14393/ufu.te.2022.57>

Inclui bibliografia.

Inclui ilustrações.

1. Engenharia elétrica. I. Destro Filho, João Batista
, 1970-, (Orient.). II. Universidade Federal de
Uberlândia. Pós-graduação em Engenharia Elétrica. III.
Título.

CDU: 621.3

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:

Gizele Cristine Nunes do Couto - CRB6/2091



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
 Coordenação do Programa de Pós-Graduação em Engenharia Elétrica
 Av. João Naves de Ávila, 2121, Bloco 3N - Bairro Santa Mônica, Uberlândia-MG, CEP 38400-902
 Telefone: (34) 3239-4707 - www.posgrad.feelt.ufu.br - copel@ufu.br



ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Engenharia Elétrica				
Defesa de:	Tese de Doutorado, 295, PPGEELT				
Data:	Vinte de janeiro de dois mil e vinte e dois	Hora de início:	13:00	Hora de encerramento:	17:30
Matrícula do Discente:	11723EEL008				
Nome do Discente:	Camila Davi Ramos				
Título do Trabalho:	Aprendizado de máquina como ferramenta para o prognóstico de pacientes em coma usando sinais eletroencefalográficos no espectro de 1 a 100 Hz				
Área de concentração:	Processamento da informação				
Linha de pesquisa:	Engenharia biomédica				
Projeto de Pesquisa de vinculação:	Título do projeto: Estudo do efeito da estimulação musical baseada em eletroencefalografia (EEG). Agência financiadora: Não Há. Número do processo na agência financiadora: Não Há. Projeto de pesquisa avaliado e oficialmente aprovado pelo Comitê de Ética /UFU, protocolo 2.570.022, do 28/03/2018. Vigência do projeto: 2018 a 2021				

Reuniu-se por meio de videoconferência, a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Engenharia Elétrica, assim composta: Professores Doutores: Jose Hiroki Saito - UNIFACCAMP; Murillo Guimarães Carneiro - FACOM/UFU; Aurélia Aparecida de Araújo Rodrigues - FAMAT/UFU; Marcos Campos - HC/UFU; Eduardo Jorge Custódio da Silva - UERJ; João Batista Destro Filho - FEELT/UFU, orientador(a) do(a) candidato(a).

Iniciando os trabalhos o(a) presidente da mesa, Dr(a). João Batista Destro Filho, apresentou a Comissão Examinadora e o candidato(a), agradeceu a presença do público, e concedeu ao Discente a palavra para a exposição do seu trabalho. A duração da apresentação do Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir o senhor(a) presidente concedeu a palavra, pela ordem sucessivamente, aos(às) examinadores(as), que passaram a arguir o(a) candidato(a). Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o(a) candidato(a):

Aprovado(a).

Esta defesa faz parte dos requisitos necessários à obtenção do título de Doutor.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **João Batista Destro Filho, Professor(a) do Magistério Superior**, em 20/01/2022, às 17:31, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Jose Hiroki Saito, Usuário Externo**, em 20/01/2022, às 17:32, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Eduardo Jorge Custodio da Silva, Usuário Externo**, em 20/01/2022, às 17:36, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Murillo Guimarães Carneiro, Professor(a) do Magistério Superior**, em 20/01/2022, às 17:36, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Aurelia Aparecida de Araújo Rodrigues, Professor(a) do Magistério Superior**, em 20/01/2022, às 17:36, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Marcos Campos, Médico(a)**, em 25/01/2022, às 09:59, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **3313313** e o código CRC **5A02D2F6**.

“A cegueira também é isto, viver num mundo onde se tenha acabado a esperança.”

(José Saramago)

AGRADECIMENTO

Em primeiro lugar agradeço a Deus pela oportunidade de conseguir realizar essa pesquisa de doutorado, em sequência a dissertação de mestrado, com saúde e determinação mesmo em condições adversas presentes na etapa final e muito importante desse trabalho.

Agradeço aos meus pais, Weliton e Emília, irmã, Bruna e esposo, Cláudio, pelo apoio incondicional em todas as etapas desse processo.

Agradeço ao meu orientador, João Batista Destro Filho, a confiança em mim na execução dessa dissertação que é parte de um projeto de pesquisa de muitos anos.

Agradeço a equipe multidisciplinar que realiza a pesquisa em conjunto com o professor João Destro, principalmente os médicos neurologistas Marcos Campos e Paulo Bettero, os estudantes de mestrado e iniciação científica e os profissionais que atuam nos setores de neurologia e Unidade de Terapia Intensiva do Hospital de Clínicas da Universidade Federal de Uberlândia.

Agradeço ainda aos professores Aurélia Aparecida e Murillo Carneiro por todo apoio na parte metodológica com o processamento dos dados e análise estatística.

RESUMO

Sabe-se que o sinal eletroencefalográfico é relativamente simples em termos de aquisição. Bastante utilizado em Unidades de Terapia Intensiva, o acompanhamento neurológico de pacientes clinicamente comatosos por meio desse sinal tem sido constatado pela literatura internacional como um dos elementos que auxiliam o prognóstico do paciente em coma. Esta última pode desdobrar em dois desfechos ao paciente conforme o nível de consciência medido: bom ou ruim. O desfecho ruim pode ser o óbito por causas clínicas ou ainda referente à morte encefálica. Conseguir distinguir o desfecho do paciente comatoso utilizando ferramentas do sinal eletroencefalográfico em frequências de 1 a 100 Hz a partir de modelos matemáticos é o objetivo central desse estudo. Registros de EEG de pacientes comatosos foram considerados nessa pesquisa sendo divididos em três desfechos possíveis. Nesse contexto a metodologia desse estudo aborda cálculos quantitativos do sinal EEG desses pacientes, tanto no domínio do tempo quanto no domínio da frequência, levando em consideração para este último, duas faixas distintas de análises: a primeira considerando o sinal clínico, de 1 a 30 Hz; a segunda considerando o espectro de 1 a 100 Hz. Além dessas informações quantitativas, dados como o nível de consciência do paciente durante a realização do exame e a etiologia do coma foram considerados como variáveis de entradas, combinadas entre si, para gerar modelos prognósticos a partir de ferramentas de aprendizado de máquina. Destaca-se que os critérios habituais para elaboração desses modelos foram seguidos de maneira rigorosa ou seja, os dados foram segmentados em dados de treino e dados de teste, houve ainda validação cruzada com cinco pastas bem como a ferramenta de hold out executada cinco vezes. Isso resultou em diversas matrizes de confusão a partir das quais, calculou-se as principais medidas de desempenho vistas na literatura: acurácia, sensibilidade e especificidade. Foi calculada ainda a medida F-escore macro como diferencial, uma vez que não foi evidenciado na literatura nenhum estudo com essa medida. Os classificadores binários considerados na criação dos modelos foram regressão logística, máquina de vetor suporte e k-vizinhos mais próximos. Os resultados encontrados nesse estudo demonstram que o sinal eletroencefalográfico medido em pacientes comatosos tem potencial para ser utilizado como atributo de modelos prognósticos do coma. O melhor valor médio de acurácia aqui obtido foi igual a 0,80, diferenciando pacientes com desfecho de óbito clínico de pacientes em óbito por morte encefálica; sendo que, independentemente do grupamento considerado, a acurácia média foi de 0,68. Observou-se ainda que, em algumas situações, inserir análise dos ritmos gama e supergama provoca melhoria de desempenho dos modelos prognósticos, particularmente quando consideradas as classes ativo e óbito por morte encefálica.

Palavras-chave: Eletroencefalografia. Quantificação. Processamento digital de sinais. Prognóstico do coma. Classificação. Aprendizado de máquina.

ABSTRACT

The electroencephalographic signal is relatively simple in terms of acquisition. Widely used in Intensive Care Units, the neurological monitoring of clinically comatose patients through this sign has been found in the international literature as a helpful exam to the prognosis of patients in coma. The latter can infer two outcomes for the patient according to the level of consciousness measured: good or bad. The poor outcome can be death from clinical causes or even related to brain death. Being able to distinguish the outcome of the comatose patient using tools of the electroencephalographic signal at frequencies from 1 to 100 Hz from mathematical models is the main objective of this study. EEG records of comatose patients were considered in this research and divided into three possible outcomes. In this context, the methodology of this study addresses quantitative calculations of the EEG signal of these patients, both in the time domain and in the frequency domain, taking into account for the latter two distinct ranges of analysis: the first considering the clinical signal, from 1 to 30 Hz; the second considering the spectrum from 1 to 100 Hz. In addition to this quantitative information, data such as the patient's level of consciousness during the examination and the etiology of the coma were considered as input variables, combined, to generate prognostic models from machine learning tools. We used the data segmented into training and test data. Also, we used cross-validation with five folds, as well as the hold out tool executed five times. Then, we obtained several confusion matrices and the main performance measures were calculated: accuracy, sensitivity, and specificity. The macro F-score measure was also calculated as a differential since no study with this measure was found in the literature. The binary classifiers considered in the creation of the models were logistic regression, support vector machine, and k-nearest neighbors. The results found in this study demonstrate that the electroencephalographic signal measured in comatose patients has the potential to be used as an attribute for prognostic models of coma. The best mean accuracy value obtained here was equal to 0.80, differentiating patients with clinical death outcomes from patients with death due to brain death; and, regardless of the data set considered, the mean accuracy was 0.68. It was also observed that, in some situations, inserting analysis of gamma and super gamma rhythms improves the performance of prognostic models, particularly when considering the active and death classes due to brain death.

Keywords: Electroencephalography. Quantification. Digital signal processing. Prognosis of the coma. Classification. Machine learning.

LISTA DE FIGURAS

Figura 1 Sistema 10-20 de colocação de eletrodos.	2-23
Figura 2 Exemplo de matriz de confusão. Fonte: Retirada de TAN et al., 2018, 296.	36
Figura 3 Fluxograma do refinamento das buscas bibliográficas. Fonte: Elaborado pela autora.	43
Figura 4 Ilustração da metodologia para criação dos modelos prognósticos.	70
Figura 5 Valores obtidos nas medidas de desempenho conforme o tipo de modelo testado. ..	89
Figura 6 Comportamento estatístico dos modelos considerando as combinações de atributos.	90
Figura 7 Valores obtidos nas medidas de desempenho conforme o tipo de modelo testado, análise 1 – 100 Hz. Fonte: autoria própria.	110
Figura 8 Comportamento estatístico dos modelos considerando as combinações de atributos, análise 1 – 100 Hz. Fonte: autoria própria.	111
Figura 9 Medidas de desempenho gerais do grupamento A (ativo x OC) nas situações de baixa frequência (barras 1, 3, 5, 7 e 9) versus alta frequência (barras 2, 4, 6, 8 e 10). a) Valores de acurácia. b) Valores de F-macro.	116
Figura 10 Medidas de desempenho gerais do grupamento B (ativo x OME) nas situações de baixa frequência (barras 1, 3, 5, 7 e 9) versus alta frequência (barras 2, 4, 6, 8 e 10). a) Valores de acurácia. b) Valores de F-macro.	117
Figura 11 Medidas de desempenho gerais do grupamento C (OC x OME) nas situações de baixa frequência (barras 1, 3, 5, 7 e 9) versus alta frequência (barras 2, 4, 6, 8 e 10). a) Valores de acurácia. b) Valores de F-macro.	118

LISTA DE TABELAS

Tabela 1 Informações iniciais: objetivos e etiologia do coma por estudo analisado, parte A.	47
Tabela 2 Informações iniciais: objetivos e etiologia do coma por estudo analisado, parte B.	48
Tabela 3 População de estudo, capitação e pré-processamento do sinal EEG, parte A.	49
Tabela 4 População de estudo, capitação e pré-processamento do sinal EEG, parte B.	50
Tabela 5 Quantificação EEG e Ferramenta de Machine Learning (ML), parte A.	51
Tabela 6 Quantificação EEG e Ferramenta de Machine Learning (ML), parte B.	52
Tabela 7 Medidas de desempenho: valores obtidos, valor médio e desvio padrão finais.	53
Tabela 8 Valores médios de medidas de desempenho obtidos na literatura.	53
Tabela 9 Total de atributos de entrada por quantificador.	64
Tabela 10 Quantitativo de registros EEG considerando etiologia e desfecho dos pacientes, EEG 1 – 30 Hz.	68
Tabela 11 Atributos de entrada adotados nas matrizes utilizadas para modelos prognósticos	69
Tabela 12 Quantitativo de dados de treino e dados de teste, EEG 1 – 30 Hz.	69
Tabela 13 Valores de Acurácia treino, grupamento A, EEG 1 – 30 Hz.	72
Tabela 14 Valores de F-macro treino, grupamento A, EEG 1 – 30 Hz.	73
Tabela 15 Valores de Acurácia teste, grupamento A, EEG 1 – 30 Hz.	75
Tabela 16 Valores de Sensibilidade teste, grupamento A, EEG 1 – 30 Hz.	76
Tabela 17 Valores de Especificidade teste, grupamento A, EEG 1 – 30 Hz.	77
Tabela 18 Valores de F-macro teste, grupamento A, EEG 1 – 30 Hz.	77
Tabela 19 Valores de Acurácia treino, grupamento B, EEG 1 – 30 Hz.	78
Tabela 20 Valores de F-macro treino, grupamento B, EEG 1 – 30 Hz.	79
Tabela 21 Valores de acurácia teste, grupamento B, EEG 1 – 30 Hz.	81
Tabela 22 Valores de sensibilidade teste, grupamento B, EEG 1 – 30 Hz.	82
Tabela 23 Valores de especificidade teste, grupamento B, EEG 1 – 30 Hz.	82
Tabela 24 Valores de F-macro teste, grupamento B, EEG 1 – 30 Hz.	83
Tabela 25 Valores de acurácia treino, grupamento C, EEG 1 – 30 Hz.	83
Tabela 26 Valores de F-macro treino, grupamento C, EEG 1 – 30 Hz.	85
Tabela 27 Valores de acurácia teste, grupamento C, EEG 1 – 30 Hz.	87
Tabela 28 Valores de sensibilidade teste, grupamento C, EEG 1 – 30 Hz.	87

Tabela 29 Valores de especificidade teste, grupamento C, EEG 1 – 30 Hz.	88
Tabela 30 Valores de F-macro teste, grupamento C, EEG 1 – 30 Hz.....	88
Tabela 31 Quantitativo de registros EEG considerando etiologia e desfecho dos pacientes, análise 1 – 100 Hz.....	92
Tabela 32 Atributos de entrada adotados nas matrizes utilizadas para modelos prognósticos, análise 1 – 100 Hz.....	92
Tabela 33 Quantitativo de dados de treino e dados de teste, análise 1 – 100 Hz.....	93
Tabela 34 Valores de Acurácia treino, grupamento A, análise 1 – 100 Hz.	94
Tabela 35 Valores de F-macro treino, grupamento A, análise 1 – 100 Hz.	96
Tabela 36 Valores de Acurácia teste, grupamento A, análise 1 – 100 Hz.	98
Tabela 37 Valores de Sensibilidade teste, grupamento A, análise 1 – 100 Hz.....	98
Tabela 38 Valores de Especificidade teste, grupamento A, análise 1 – 100 Hz.....	99
Tabela 39 Valores de F-macro teste, grupamento A, análise 1 – 100 Hz.....	99
Tabela 40 Valores de Acurácia treino, grupamento B, análise 1 – 100 Hz.	100
Tabela 41 Valores de F-macro treino, grupamento B, análise 1 – 100 Hz.	101
Tabela 42 Valores de acurácia teste, grupamento B, análise 1 – 100 Hz.	103
Tabela 43 Valores de sensibilidade teste, grupamento B, análise 1 – 100 Hz.	103
Tabela 44 Valores de especificidade teste, grupamento B, análise 1 – 100 Hz.....	104
Tabela 45 Valores de F-macro teste, grupamento B, análise 1 – 100 Hz.....	104
Tabela 46 Valores de acurácia treino, grupamento C, análise 1 – 100 Hz.	105
Tabela 47 Valores de acurácia treino, grupamento C, análise 1 – 100 Hz.	106
Tabela 48 Valores de acurácia teste, grupamento C, análise 1 – 100 Hz.	108
Tabela 49 Valores de sensibilidade teste, grupamento C, análise 1 – 100 Hz.	108
Tabela 50 Valores de especificidade teste, grupamento C, análise 1 – 100 Hz.....	109
Tabela 51 Valores de F-macro teste, grupamento C, análise 1 – 100 Hz.....	109
Tabela 52 Desempenho médio $\pm$ desvio padrão obtidos nos grupamento A, B e C, análise 1 – 30 Hz.....	113
Tabela 53 Desempenho médio $\pm$ desvio padrão obtidos nos grupamento A, B e C, análise 1 – 100 Hz.	113

SIGLAS E ABREVIACÕES

AT – Ativo

AUC – Area Under Curve (Área Sob a Curva)

AVE – Acidente Vascular Encefálico

CEP – Comitê de Ética em Pesquisa

CM – Coma Metabólico

COR – Coerência

CPC – Cerebral Performance Category

EEG - Eletroencefalografia

FFT – Fast Fourier Transform

FM – Frequência Mediana

FN – False Negative (Falso Negativo)

FP – False Positive (Falso Positivo)

GOS – Glasgow Outcome Scale (Escala de coma de Glasgow)

KNN – K-Nearest Neighbor (K-Vizinhos mais próximos)

LR – Logistic Regression (Regressão Logística)

ML – Machine Learning

NPV – Negative Predictive Value (Valor preditivo negativo)

OC – Óbito Clínico

OME – Óbito por Morte Encefálica

PCP – Porcentagem de Contribuição de Potência

PPV – Positive Predictive Value (Valor preditivo positivo)

ROC – Receiver Operating Characteristics

SE – Entropia Espectral

SUS – Sistema Único de Saúde

SVM – Support Vector Machine (Máquina Vetor Suporte)

TCE – Traumatismo Crânio-encefálico

TN – True Negative (Verdadeiro Negativo)

TP – True Positive (Verdadeiro Positivo)

UFU – Universidade Federal de Uberlândia

UTI – Unidade de Terapia Intensiva

VPC – Variação da Potência Cerebral

SUMÁRIO

CAPÍTULO 1 - APRESENTAÇÃO	1-15
1.1 Introdução	1-15
1.2 Justificativa.....	1-17
1.3 Objetivos	1-18
1.4 Principais Contribuições.....	1-19
1.5 Organização do Trabalho.....	1-20
CAPÍTULO 2 - ELETROENCEFALOGRAFIA: PRINCIPAIS ABORDAGENS	2-21
2.1 Considerações Iniciais.....	2-21
2.2 História do EEG	2-22
2.3 Características do sinal EEG	2-24
2.4 Coma e o sinal EEG.....	2-27
2.4.1 Escalas de Coma.....	2-29
CAPÍTULO 3 - APRENDIZADO DE MÁQUINA (MACHINE LEARNING – ML)	30
3.1 Introdução	30
3.2 Dados.....	31
3.3 Classificadores	32
3.3.1 Máquina Vetor Suporte (SVM)	33
3.3.2 Regressão Logística (LR)	34
3.3.3 K-Nearest Neighbor (KNN)	34
3.4 Desempenho de um classificador.....	35
CAPÍTULO 4 - REVISÃO DA LITERATURA: SINAIS EEG E FERRAMENTAS DE APRENDIZADO DE MÁQUINA	39
4.1 Introdução	39
4.2 Metodologia.....	40
4.2.1 Método de busca e grupos de palavras chave	41
4.2.2 Refinamento Crítico: critérios de inclusão	41
4.2.3 Levantamento de informações	42
4.2.4 Análise dos resultados	43

4.3 Resultados	43
4.4 Discussão	53
CAPÍTULO 5 - MATERIAIS E MÉTODOS.....	56
5.1 Introdução	56
5.2 Bases de Dados EEG	57
5.2.1 Grupo Frequências Clínicas: 1 – 30 Hz	57
5.2.2 Grupo Altas Frequências: 1 – 100 Hz.....	59
5.3 Avaliação dos sinais EEG e definição de trechos de interesse	59
5.4 Categorias de desfechos: Favorável versus Desfavorável	59
5.5 Quantificação do sinal EEG	60
5.5.1 Quantificador Porcentagem de Contribuição de Potência (PCP)	60
5.5.2 Quantificador Variação da Potência Cerebral (VPC)	61
5.5.3 Quantificador Frequência Mediana (FM)	61
5.5.4 Quantificador Coerência (COR)	62
5.5.5 Quantificador Entropia Espectral (SE)	62
5.5.6 Quantificador Assimetria	63
5.5.7 Quantificador Curtose	63
5.6 Organização dos atributos quantitativos de entrada.....	64
5.7 Organização dos atributos qualitativos de entrada	64
5.8 Dados de treino e dados de teste	65
5.9 Modelos Prognósticos	65
5.10 Medidas de Desempenho e Análise estatística	66
CAPÍTULO 6 - ANÁLISE RITMOS CLÍNICOS	67
6.1 Introdução	67
6.2 Metodologia.....	68
6.2.1 Sinais EEG: Grupos do estudo.....	68
6.2.2 Pré-processamento e preparação das Matrizes de Atributos	68
6.2.3 Dados Treino e Teste.....	69
6.2.4 Modelos Prognósticos e Medidas de Desempenho Treino: Ritmos Clínicos	69
6.2.5 Análise Estatística e Definição dos Melhores Modelos.....	71
6.3 Resultados	71
6.3.1 Grupamento A: Ativo x Óbito Clínico.....	71

6.3.2 Grupamento B: Ativo x Óbito por Morte Encefálica	77
6.3.3 Grupamento C: Óbito Clínico x Óbito por Morte Encefálica	83
6.4 Discussão	88
CAPÍTULO 7 - ANÁLISE RITMOS CLÍNICOS E RITMOS RÁPIDOS	91
7.1 Introdução	91
7.2 Metodologia.....	91
7.2.1 Sinais EEG: Grupos do estudo.....	92
7.2.2 Pré-processamento e preparação das Matrizes de Atributos	92
7.2.3 Dados Treino e Teste.....	93
7.2.4 Modelos Prognósticos e Medidas de Desempenho Treino: Ritmos Clínicos	93
7.2.5 Análise Estatística e Definição dos Melhores Modelos.....	93
7.3 Resultados	94
7.3.1 Grupamento A: Ativo x Óbito Clínico.....	94
7.3.2 Grupamento B: Ativo x Óbito por Morte Encefálica	99
7.3.3 Grupamento C: Óbito Clínico x Óbito por Morte Encefálica	104
7.4 Discussão	109
CAPÍTULO 8 - COMPARAÇÕES ESTATÍSTICAS: ANALISAR SINAL EEG DE 1 – 100 HZ PRODUZ MELHORA NOS RESULTADOS?	112
8.1 Introdução	112
8.2 Comparação para o grupamento A: Ativo x OC	114
8.3 Comparação para o grupamento B: Ativo x OME	116
8.4 Comparação para o grupamento C: OC x OME.....	118
8.5 Conclusão.....	119
CAPÍTULO 9 - CONCLUSÃO, CONTRIBUIÇÕES, TRABALHOS FUTUROS.....	120
9.1 Conclusão Final.....	120
9.2 Contribuições da autora.....	123
9.3 Trabalhos Futuros.....	123
REFERÊNCIAS.....	125

Capítulo 1

APRESENTAÇÃO

Esse capítulo abordará aspectos introdutórios do trabalho desenvolvido entre 2017/2 e 2021/2, como objeto de estudo para obtenção do título de doutora em Ciência.

1.1 Introdução

O eletroencefalograma (EEG) mede a atividade elétrica do cérebro em diversos locais do córtex cerebral (FREEMAN; QUIROGA, 2013), e o sinal neurológico captado pode ser analisado sob diversos aspectos como visuais, ou seja, morfológicos, e ainda quantitativos, levando em consideração a análise no domínio do tempo, no domínio da frequência ou em ambos simultaneamente (SÖRNMO; LAGUNA, 2005). O EEG tem como principal objetivo a monitorização da atividade cortical, seja de pacientes que se encontram em supervisão médica em unidades de terapia intensivas (UTI), seja em tratamentos ambulatoriais de rotina (NUNEZ; SRINIVASAN, 2005).

Uma das características mais relevantes do traçado EEG é sua irregularidade com relação a morfologia das ondas mensuradas (DAUBE; RUBIN, 2009). Contudo, alguns padrões relacionados ao funcionamento cerebral em indivíduos sem doença neurológica prévia são bem definidos na literatura, assim como comportamentos associados a epilepsia (SCHOMER; SILVA, 2011). Em (RAMOS, 2017) 101 registros EEG de voluntários saudáveis foram avaliados sob três aspectos quantitativos no domínio da frequência, o que foi possível constatar que, em condições de repouso e olhos fechados, a presença do ritmo alfa na região occipital é elevada. Esse comportamento também foi demonstrado em (DE PESTERS et al., 2016). O estudo de (ANGHINAH et al., 1998) demonstrou ainda que em condições de normalidade

neurológica, o ritmo delta está presente de forma significativa nas regiões frontais do escalpo. O conhecimento de padrões cerebrais normais auxilia médicos neurologistas e intensivistas na detecção de patologias cerebrais e distúrbios de consciência, como o estado de coma (LAMBLIN; WALLS ESQUIVEL; ANDRÉ, 2013). O atendimento e tratamento de pacientes com estados neurológicos críticos são sustentados pelos diagnósticos clínicos fornecidos aos profissionais da saúde por meio de diversos exames, como o EEG (GASPARD et al., 2014; HERMAN et al., 2015).

Foi comprovado que o EEG gravado sobre o couro cabeludo humano capta altas frequências, proporcionando de forma não invasiva obtenção da atividade elétrica cortical, ou seja, esta não pode ser considerada apenas artefato a ser descartado (TELENCZUK et al., 2011). Acredita-se que muitas manifestações fisiológicas e patológicas estejam ligadas as oscilações de alta frequência e distinguir, quando estas são normais ou patológicas, pode servir como um bom indicador da epilepsia por exemplo (ENGEL; SILVA, 2012). Enquanto as oscilações de baixa frequência são associadas com funções inibidoras, as oscilações gama refletem a ativação cortical e, dependendo da região, são relacionadas com o processamento de informação, percepção de consciência e manutenção da memória (FREEMAN; QUIROGA, 2013; HERRMANN et al., 2016).

Pacientes criticamente acometidos são susceptíveis a severos transtornos neurológicos, dentre eles as isquemias, convulsões, edemas e o aumento da pressão intracraniana (PUGGINA et al., 2005). Caso tais acometimentos não sejam tratados de maneira eficaz, danos neurológicos podem acometer o paciente de forma contínua e sem chances de melhora (HERMAN et al., 2015). O monitoramento da atividade cerebral de pacientes na UTI por meio do exame do EEG possibilita a visualização de alterações imperceptíveis na atividade cerebral que são diferentes daquelas consideradas normais (EBERSOLE; PEDLEY, 2003; SCHOMER; SILVA, 2011), como no estado epiléptico não-convulsivo, permitindo assim, intervenções médicas rápidas, o que pode aprimorar o tratamento destes pacientes (CAVALCANTI et al., 2016; VESPA, 2005).

Algumas condições do traçado EEG na situação de coma podem ser associadas a possíveis desfechos, como mostrado em (HOFMEIJER; TJEPKEMA-CLOOSTERMANS; VAN PUTTEN, 2014), em que, para pacientes comatosos, sincronias associadas ao evento surto-supressão foram associadas ao desfecho de morte. Ademais, o coma pode resultar em diversos desfechos, tanto positivos, como melhora do quadro do paciente, quanto negativos, como morte. A pesquisa realizada por (RUIJTER et al., 2018) analisou a amplitude do EEG para a previsão do desfecho de pacientes comatosos após parada cardíaca e relacionou a

amplitude entre surtos e supressões como preditores do resultado do coma pós-anóxico. No estudo realizado por (NENADOVIC, 2013) os pesquisadores correlacionaram que a antecipação da recuperação dos sinais EEG característicos, juntamente com o aparecimento tardio da atividade epileptiforme, estão altamente associados a pacientes que apresentam bons desfechos após o coma.

A hipótese central da presente pesquisa é que unindo a quantificação do sinal EEG habitual, ou seja, ritmos clínicos (delta a beta) à quantificação desse sinal em frequências elevadas, até cerca de 100 Hz (supergama), modelos prognósticos utilizando aprendizado de máquina sejam capazes de prever o desfecho do paciente comatoso. A previsão do desfecho de óbito por morte encefálica também será aqui estudada e ainda a investigação da diferença de desempenho obtido em modelos matemáticos com e sem a presença dos ritmos rápidos gama e supergama.

1.2 Justificativa

Com o avanço tecnológico principalmente dos equipamentos médicos de assistência às análises clínicas, a observação do traçado EEG foi cada vez menos utilizada, sendo substituído por tecnologias que utilizam imagens como tomografias e ressonância magnética. Contudo, principalmente em ambientes de UTI, em que o paciente na maioria das situações encontra-se conectado a diversos tipos de equipamentos, como monitores cardíacos, bombas de infusão, entre outros, o exame clínico de EEG ainda é bastante utilizado no contexto Sistema Único de Saúde (SUS). A análise clínica do sinal EEG, na maioria das situações, acontece de maneira predominantemente subjetiva pelos médicos neurologistas treinados para interpretação de ondas baseados na literatura. No contexto atual do desenvolvimento tecnológico de ferramentas matemáticas e informáticas aplicadas no processamento de dados biomédicos pode auxiliar neurologistas, principalmente quando se leva em consideração que as tomadas de decisões dentro de hospitais, em especial em UTI em relação ao futuro do paciente comatoso, são sérias e podem influenciar no prognóstico desse indivíduo.

Sabe-se que um ambiente de UTI exige diversos profissionais bem como diferentes tipos de equipamentos uma vez que são admitidos pacientes com variados diagnósticos e tratamentos. Conclui-se portanto que o custo de um paciente mantido nesse ambiente é elevado e, quanto

mais tempo o paciente permanece nesse lugar, mais dispendioso torna-se essa estadia. O auxílio ao diagnóstico e prognóstico de pacientes comatosos a partir de ferramentas matemáticas de análise do sinal EEG pode contribuir para tomadas de decisão bem como tratamentos desse paciente neurologicamente acometido dentro da UTI.

A morte encefálica é um dos possíveis desfechos ou prognósticos de um paciente em estado de coma e quando detectada em tempo hábil a doação de órgãos pode se tornar viável. Contudo, por falta de informações e desconhecimento principalmente dos familiares, a doação de órgãos ainda é limitada. O que separa o estado de coma grave do diagnóstico de morte encefálica é a irreversibilidade do último. Sistemas inteligentes capazes de prever a morte cerebral em um paciente comatoso podem contribuir não somente nas tomadas de decisões internas da UTI, bem como no aumento de número das doações de órgãos uma vez que o tempo necessário para efetivar e concretizar a doação pode ser maior e melhor aproveitado.

Infelizmente o acompanhamento neurológico por meio da captação do sinal EEG de forma constante, como acontece em regiões de situação economicamente melhores que o Brasil, ainda não é uma realidade, sendo necessário portanto trabalhar com sinais EEG coletados ao longo de no máximo uma hora. Sendo assim, ao incorporar ferramentas de aprendizado de máquina e inteligência artificial às análises padrões de sinais EEG podem resultar em resultados satisfatórios em relação ao prognóstico do paciente comatoso em ambiente de UTI, como verificado na literatura. Mais ainda, analisar esses sinais EEG em frequências altas, o que não é corriqueiro na clínica neurológica, pode aumentar os desempenhos obtidos nas ferramentas tecnológicas e contribuir ainda mais nas decisões referentes a esses pacientes.

1.3 Objetivos

O objetivo central dessa pesquisa é verificar a contribuição dos ritmos rápidos de EEG, gama e supergama, no prognóstico do paciente comatoso a partir de modelos matemáticos elaborados utilizando ferramentas de aprendizado de máquina.

Como objetivos secundários, tem-se:

- Revisão da literatura com levantamento sistemático a respeito de tecnologias de aprendizado de máquina aplicadas no prognóstico do paciente comatoso a partir de informações quantitativas do sinal EEG desse paciente.

- Organização de base de dados EEG de pacientes comatosos, coletando sinais EEG e informações clínicas dos pacientes, tais como: idade, sexo, etiologia do coma, tempo de internação na UTI, desfecho do paciente, escala natural do coma, escala de sedação do coma, entre outros.
- Estudo e aplicação de técnicas de aprendizado de máquina a fim de criar modelos prognósticos para serem testados e avaliados.

1.4 Principais Contribuições

A análise do sinal EEG quantitativo realizado em pacientes criticamente acometidos, seja em estado comatoso ou desordem de consciência tem sido abordado na literatura com níveis de desempenho de modelos prognósticos consideravelmente elevados. Ou seja, é sabido que, por meio desses sinais medidos em situações de baixo ou nenhum sinal de consciência é possível traçar o prognóstico do paciente, principalmente quando o motivo desse desnível tenha sido relacionado à parada cardiorrespiratória. Contudo, esse tipo de análise considerando outras etiologias do coma, por exemplo TCE ou AVE, não é muito abordado na literatura.

Ainda considerando o que já se sabe sobre a contribuição dos sinais EEG para o prognóstico do coma, nota-se que os desfechos dos pacientes analisados na maioria das situações envolvem duas classes: o bom desfecho e o mau desfecho. Para tais condições o paciente é analisado em relação às categorias de recuperação cerebral, essas já fixadas na neurologia clínica. Porém, situações de morte encefálica não são abordadas em nenhum estudo literário encontrado nesse trabalho. Sendo assim, a primeira contribuição do presente estudo para a literatura é a abordagem desse “terceiro” desfecho possível de um paciente comatoso.

Ademais, é sabido que os ritmos cerebrais delta e beta tem suas contribuições nas interpretações do traçado EEG, já fixadas em obras literárias clássicas a respeito desse sinal. Contudo, as análises de ritmos gama e supergama relacionadas a pacientes comatosos e relatadas na literatura são escassas. Outra contribuição fundamental desse trabalho é averiguar se há associação entre o aumento da precisão de previsão do coma quando são acrescidas informações dos ritmos gama e supergama na análise do sinal EEG.

1.5 Organização do Trabalho

Esse documento contém nove (9) capítulos, cada um contemplando uma questão inerente a realização do presente estudo. No atual capítulo, Capítulo 1, tem-se a apresentação do trabalho com aspectos gerais, justificativa, objetivo e principais contribuições dessa tese. No “Capítulo 2 - Eletroencefalografia: Principais abordagens” há a elucidação ao universo da eletroencefalografia, desde definições importantes até aplicações diversas desse sinal no cotidiano médico, principalmente em ambientes de Unidades de Terapia Intensiva (UTIs). No “Capítulo 3 - Aprendizado de Máquina” são abordados temas relacionados as técnicas de aprendizado de máquina de forma abrangente desde a definição de classes até a avaliação de modelos preditivos. Já o “Capítulo 4 - Revisão de Literatura: Sinais EEG e Ferramentas de aprendizado de máquina” é uma breve revisão da literatura contendo os principais estudos que abordaram prognóstico de pacientes comatosos a partir de sinais EEG utilizando ferramentas de aprendizado de máquina. No “Capítulo 5 - Metodologia” tem-se a metodologia geral aplicada na realização do trabalho para fundamentação dos Capítulos 6, 7 e 8. No “Capítulo 6 - Análise de Ritmos Clínicos” estão demonstrados os resultados obtidos a partir de sinais analisados em frequências de 1 a 30 Hz, ou seja, considerando os ritmos delta, teta, alfa e beta. No “Capítulo 7 - Análise de Ritmos Clínicos e Ritmos Rápidos” são demonstrados os resultados obtidos a partir de sinais analisados em frequências de 1 a 100 Hz, ou seja, considerando além dos ritmos clínicos, os ritmos rápidos gama e supergama. Já o “Capítulo 8 - Comparações Estatísticas” contém as comparações estatísticas entre os resultados obtidos nas análises do sinal EEG de 1 a 30 Hz com os sinais EEG de 1 a 100 Hz. Por fim, no “Capítulo 9 - Conclusões Gerais” tem-se a síntese geral de conclusões obtidas nesse estudo, bem como objetivos futuros da pesquisa e contribuições da autora durante o desenvolvimento desse trabalho.

Capítulo 2

ELETROENCEFALOGRAFIA: PRINCIPAIS ABORDAGENS

Nesse capítulo serão introduzidos conceitos fundamentais para compreensão do sinal EEG.

2.1 Considerações Iniciais

A unidade básica do sistema nervoso é o neurônio. A excitabilidade neuronal é a habilidade do neurônio em gerar e transmitir potenciais de ação. Essa capacidade é dependente do valor de potencial da membrana que por sua vez depende da concentração de íons transmembranares e da permeabilidade iônica. Sendo assim, quando não há estímulo, o potencial de membrana do neurônio é caracterizado pela sua permeabilidade ao potássio. A maioria dos sinais de comunicação rápida no sistema nervoso é manipulada por canais de íons cuja tensão é controlada (DAUBE; RUBIN, 2009). O local de comunicação entre neurônios é conhecido como sinapse.

As informações aferentes, que chegam ao sistema nervoso central, conectam ao neurônio por meio das milhares de sinapses dispostas nos dendritos neuronais, e o sinal eferente (são os impulsos que saem do sistema nervoso central) do neurônio trafega apenas por um único axônio que apresenta diversas ramificações distintas que podem se dirigir para outras regiões do sistema nervoso ou demais partes do corpo. Sabe-se que nas sinapses a direção de propagação dos sinais é anterógrada, ou seja, do axônio de um neurônio para os dendritos de outros neurônios subsequentes (GUYTON; HALL, 2006).

O principal papel do sistema nervoso consiste em controlar as atividades do corpo, processando as informações aferentes. Contudo, cerca de 99% da informação sensorial é

descartada pelo cérebro, sendo que apenas as informações sensoriais importantes são canalizadas para regiões interativas e motoras apropriadas objetivando provocar respostas desejadas (GUYTON; HALL, 2006). O sistema nervoso é dividido em sistema nervoso central, formado pelo encéfalo e pela medula espinhal, e o sistema nervoso periférico, formado por nervos e células nervosas localizadas fora do encéfalo e medula espinhal (SÖRNMO; LAGUNA, 2005).

O córtex cerebral é a camada mais externa do cérebro, caracterizada pela presença de reentrâncias, e é formado por diferentes tipos celulares que serão responsáveis pelas diversas funções vitais, tais como: Sensação, aprendizagem e movimento voluntário (GUYTON; HALL, 2006; SÖRNMO; LAGUNA, 2005). É constituído por dois hemisférios simétricos, esquerdo e direito, e cada hemisfério é dividido em quatro lobos distintos: frontal, temporal, parietal e occipital (SÖRNMO; LAGUNA, 2005).

Os potenciais registrados no exame de EEG são advindos do córtex cerebral, onde são produzidos campos elétricos, variando ao longo do tempo, que podem ser registrados a partir da superfície do couro cabeludo. É importante salientar que o EEG tem capacidade de revelar apenas a atividade cortical à nível macroscópico, ou seja, resultado da atividade muitos neurônios, e não de apenas uma única célula (EBERSOLE; PEDLEY, 2003). Os potenciais sinápticos pós-sinápticos excitatórios (EPSPs) e pós-sinápticos inibitórios (PSPs), originários dos neurônios piramidais, são os principais campos registrados no EEG (EBERSOLE; PEDLEY, 2003). As intensidades desses potenciais EEG variam de 0 a 200 μ V, e as características dessas intensidades, como morfologia e frequência, dependem do grau de atividade no córtex cerebral. Em análise temporal o comportamento do sinal EEG não tem padrão específico, porém há momentos que características específicas podem aparecer, ocorrendo principalmente quando há presença de patologias neurológicas (GUYTON; HALL, 2006).

2.2 História do EEG

Os estudos do EEG humano tiveram início em 1924 (SCHOMER; SILVA, 2011) e foram realizados por Hans Berger, qual seguiu coletando dados e reexaminando os resultados até que em 1929 publicou "Über das Elektroenkephalogramm des Menschen". Neste, Berger relatou a presença de oscilações cerebrais de cerca de 10 ciclos por segundo, o que ele chamou

de ondas alfa, as quais foram observadas no sujeito em estado relaxado e com os olhos fechados. Percebeu ainda que ao abrir os olhos essas ondas desapareceram e as oscilações de frequências mais altas foram verificadas. Já na década de 1940 estudos sobre o sono se tornaram comuns e ao final da década os primeiros registros intracranianos em humanos foram realizados. Na década de 1950, Wilder Penfield e Herbert Jasper, da Universidade McGill, realizaram estimulação elétrica em cirurgias cerebrais abertas a fim de localizar áreas envolvidas em diferentes processos cerebrais (GUYTON; HALL, 2006).

O EEG do couro cabeludo na atualidade fornece medidas de grande escala, sendo um único eletrodo capaz de fornecer estimativas da ação sináptica de cerca de um bilhão de neurônios. As gravações EEG produzem sinais que variam de amplitude conforme o tipo de eletrodo utilizado (de superfície ou interno) além do tamanho desse eletrodo, sendo que registros intracranianos são mais fidedignos que os superficiais. É importante destacar ainda que eletrodos colocados em locais diferentes podem resultar em diferenças no comportamento do sinal registrado, variando além de amplitude a frequência (NUNEZ; SRINIVASAN, 2005).

Vários sistemas que determinam os locais de colocação dos eletrodos foram criados e têm sido utilizados ao longo dos anos. O Comitê da Federação Internacional de Sociedades de Eletroencefalografia e Neurofisiologia Clínica (IFSECN) definiu portanto, um sistema específico de colocação de eletrodos em condições normais para uso em todos os laboratórios, conhecido como sistema internacional 10-20. Nesse sistema as medições específicas dos pontos ósseos são usadas para determinar a colocação de eletrodos, sendo que a partir destes marcos anatômicos, são feitas medições específicas e, em seguida, utiliza-se 10% a 20% de uma distância especificada como intervalo de eletrodo. A Figura 1 representa o esquema de posicionamento dos eletrodos conforme o sistema 10-20 sendo que, eletrodos de número ímpar são colocados no lado esquerdo da cabeça, e eletrodos de número par, no lado direito. As letras que acompanham o número designam a área anatômica cerebral, por exemplo, "F" significa frontal (EBERSOLE; PEDLEY, 2003).




Figura 1 Sistema 10-20 de colocação de eletrodos.

Os sinais medidos frequentemente no EEG são oscilatórios e repetitivos, o que origina um tipo de ritmo específico advindo da atividade elétrica coletiva do córtex. Existe portanto vasta diversidade de ritmos EEG dependendo principalmente do estado mental do sujeito, podendo ser o grau de atenção e consciência, fatores relevantes e determinantes no comportamento do sinal (SÖRNMO; LAGUNA, 2005). Diante disso, algumas propriedades dinâmicas do EEG são difíceis ou quase impossíveis de serem vistas sem processamento dos dados, os quais fazem uso de ferramentas computacionais (NUNEZ; SRINIVASAN, 2005). Existem basicamente duas categorias gerais que envolvem os métodos de processamento do sinal EEG, métodos desenvolvidos para a análise da atividade cerebral espontânea (EEG de fundo) e o método dos potenciais cerebrais que são evocados por vários estímulos sensoriais e cognitivos (SÖRNMO; LAGUNA, 2005).

2.3 Características do sinal EEG

Afirmar que a atividade cortical de um indivíduo encontra-se “normal” não é tarefa corriqueira, embora existam parâmetros a serem analisados para viabilizar esse processo, como por exemplo os ritmos cerebrais de acordo com frequência, topografia, amplitude, reatividade, levando-se em conta o estado de consciência do indivíduo (NIEDERMEYER; SILVA, 2005). Na neurologia clínica a faixa mais importante analisada é compreendida entre 0,5Hz e 30Hz, porém para níveis de pesquisa os ritmos de maiores frequências também são importantes apesar de pouco explorados na clínica. Os ritmos de EEG são convencionalmente caracterizados pela sua gama de frequência e amplitude relativa. A amplitude do sinal está relacionada ao grau de sincronia com o qual os neurônios corticais interagem (SÖRNMO; LAGUNA, 2005). Essas diferentes oscilações foram estudadas de maneira minuciosa principalmente após a aplicação da Transformada Rápida de Fourier (FFT) em sinais EEG, descobrindo correlações entre ritmos em diferentes estados, funções e patologias cerebrais (FREEMAN; QUIROGA, 2013).

Seguindo a ordem crescente de frequência, o ritmo correspondente às mais baixas frequências é denominado ritmo Delta. Característicos dos estágios do sono profundo, variam na faixa 0,5 – 3,5Hz (FREEMAN; QUIROGA, 2013) e amplitude de onda média igual a 100 μ V. Os fatores como localização, ritmicidade e morfologia influenciam na análise desse ritmo, que pode ter características normais como ocorre no sono de ondas lentas ou características patológicas como acontece na presença de tumores cerebrais. Para que as ondas Delta

apareçam, alguns mecanismos sincronizadores podem ocorrer no sistema neuronal cortical, sugerindo que o córtex é “liberado” das atividades de ativação do tálamo e de outros centros inferiores (GUYTON; HALL, 2006).

Entre frequências de 3,5 – 7,5Hz estão presentes os ritmos Teta. Esses, também ocorrem em determinadas fases do sono (SÖRNMO; LAGUNA, 2005), têm papel importante na infância e quando presente no adulto acordado pode ser considerada anormal e relacionada a distúrbios cerebrais (FREEMAN; QUIROGA, 2013). Outra associação à esse ritmo é o seu aparecimento durante momentos de desapontamento ou frustração do indivíduo (GUYTON; HALL, 2006).

Os ritmos denominados Alfa aparecem de forma espontânea em indivíduos com olhos fechados e em estado relaxado, porém acordados. Caracterizados pela faixa de frequência entre 7,5 – 12,5 Hz, apresentam maiores amplitudes nas regiões occipitais do córtex cerebral (FREEMAN; QUIROGA, 2013; SÖRNMO; LAGUNA, 2005). Para que essas ondas ocorram deve haver conexão entre o tálamo e o córtex cerebral, sendo resultantes das oscilações espontâneas do feedback existente no sistema tálamo-cortical. Essas oscilações são as possíveis responsáveis pela periodicidade desse ritmo (GUYTON; HALL, 2006).

Entre as frequências de valores iguais a 12,5Hz e 30Hz estão os ritmos Beta, evidenciados principalmente em atividades cognitivas como cálculos matemáticos ou em situações de ativação do córtex cerebral (FREEMAN; QUIROGA, 2013). Apresentam amplitude menor comparados ao ritmo Alfa e tem proeminência principalmente nas regiões centrais e frontais do couro cabeludo (FREEMAN; QUIROGA, 2013; SÖRNMO; LAGUNA, 2005).

Os ritmos Gama, que estão relacionados a estados de processamento da informação no córtex cerebral, estão presentes na faixa de 30 – 80Hz (FREEMAN; QUIROGA, 2013). Alguns estudos relacionam esse ritmo com diferentes processos cognitivos como audição, percepção visual, percepção olfativa e também com a atenção. Já os ritmos Supergama, caracterizados por frequências maiores que 80Hz, estão associados principalmente com patologias neurológicas como por exemplo a epilepsia. Para alguns autores as Oscilações de Alta Frequência (OAFs) variam entre 100 e 500 Hz (LÉVESQUE et al., 2011), sendo as que variam entre 250Hz e 500Hz denominadas *fast ripples* (FR), as quais têm sido associadas à epileptogênese (URRESTARAZU et al., 2007). As oscilações gama estão proximamente relacionadas com processamento de informação, manutenção da memória, e do estado de consciência dependendo da região cortical em que são encontradas (HERRMANN et al., 2016). As OAFs aparecem em um cérebro normal quando está relacionada à sincronização e a memória, e podem servir como

biomarcadores de condições anormais como a epilepsia em caso de cérebros não normais. Como apontado em (PACHORI; BAJAJ, 2011), estudos mostram que frequências acima de 100 Hz caracterizam o comportamento de estruturas epiléticas em pacientes acometidos com essa patologia, já as frequências entre 100-200 Hz estão relacionadas com o processamento fisiológico da memória.

A captação da atividade elétrica cortical está sujeita a interferências (artefatos) provenientes de outras formas da atividade elétrica, que podem dificultar a visualização do traçado e até interferir no diagnóstico clínico do sinal (MONTENEGRO et al., 2011). Logo, o EEG é um método de monitorização eletrofisiológica bastante utilizado em pacientes acometidos por patologias neurológicas principalmente em ambientes de UTI (VESPA, 2005). O estudo de (LUCA. et al., 2010) sugere que o EEG de superfície é constantemente contaminado por artefatos que podem estar relacionados aos estágios de amplificação do sinal ou quaisquer interferências advindas de outras fontes. Um dos possíveis motivos pela contaminação desse sinal é sua baixa amplitude e para um pesquisador inexperiente nessa área os artefatos podem até parecer atividade cerebral real (FREEMAN; QUIROGA, 2013). Um fator agravante dessa situação é que ambientes hospitalares, principalmente UTI, apresentam vários equipamentos funcionando simultaneamente como aspiradores, monitores cardíacos e ventiladores mecânicos (PEREIRA; TOLEDO; GUILHERME, 2003).

Os artefatos são comumente divididos em dois grupos: Intrínsecos (fisiológicos), gerados pelo corpo do próprio indivíduo submetido ao registro (YOUNG et al., 2002); Extrínsecos (não fisiológicos), produzidos por fontes externas ao corpo desse indivíduo. Em (WHITE; VAN COTT, 2010) são citados pelo menos onze tipos diferentes de artefatos presentes em registros EEG realizados em ambientes de UTI. Esses artefatos também podem ser observados em outros tipos de registros EEG, como clínicos ou para pesquisas. O primeiro tipo trata-se do artefato provocado pelos movimentos musculares e involuntários do corpo. As principais atividades musculares que afetam o sinal EEG são advindos do escalpo, face, mandíbula e pescoço. Geralmente são vistos quando o indivíduo sob registro EEG encontra-se acordado. Ainda em (WHITE; VAN COTT, 2010) outro tipo de artefato citado são os sinais eletrocardiográficos (ECG) que aparecem principalmente nos eletrodos auriculares, usados como referência em uma gravação EEG que segue o sistema 10-20. Algumas sugestões para minimizar esse artefato é a mudança de posição dos eletrodos biauriculares e também a gravação do próprio ECG simultâneo ao registro EEG. Os artefatos provocados pela presença do marca-passo também representam um tipo de artefato intrínseco o qual pode ser causado por

estímulos elétricos provocando no traçado repetições de *spikes*. Esse tipo de artefato pode ocasionar má interpretação dos dados EEG uma vez que se parecem à descargas epiléticas.

Em (SCHOMER; SILVA, 2011) um exemplo de artefato não-fisiológico, os ruídos de eletrodos, são comuns e fáceis de serem detectados pois uma forma de onda incomum restrita a um único eletrodo possivelmente é resultante desse tipo de ruído. Para tentar solucionar possíveis problemas de artefatos dessa natureza basta adicionar outro eletrodo perto do eletrodo ruidoso afim de averiguar se há contaminação do sinal EEG. Uma causa comum do surgimento desse ruído é a possível secagem do gel de condutância usado no contato pele-eletrodo. Outro ruído comum ao sinal EEG é a interferência da rede elétrica (60 Hz), podendo ser reduzida por meio da blindagem dos cabos de alimentação e se possível afastar possíveis fontes geradoras desse ruído (aparelhos funcionando simultaneamente ao registro do EEG).

2.4 Coma e o sinal EEG

Uma das aplicações mais importantes do registro EEG é fornecer acompanhamento neurológico de fácil aquisição em pacientes com baixo nível de consciência (PUGGINA et al., 2005). Antes de definir o coma, é necessário explanar sobre o que é a consciência. Definida como a capacidade do indivíduo de reconhecer a si mesmo e aos estímulos do ambiente (POSNER et al., 2007), a consciência quando alterada, pode provocar comprometimento das funções mentais e cognitivas, refletindo desorientação têmporo-espacial ou ainda estado de coma profundo (ANDRADE et al., 2007). A perda de consciência é uma das manifestações clínicas mais temidas entre os médicos dos serviços de emergência (ALIREZA ALA et al., 2020).

A palavra Coma vem do grego e indica transe ou sono profundo. Pode ser o resultado de lesões cerebrais verificadas na formação reticular ascendente, bem como nos hemisférios cerebrais (HAUPT et al., 2015; TRAUB; WIJDICKS, 2016). Diversas são as etiologias do coma e os reflexos que esse coma provoca no paciente desde a permanência de olhos fechados e a incapacidade de obedecer comandos mesmo sob estímulos até, nos piores cenários, a morte.

Diversas condições clínicas podem ocasionar a perda de consciência como: eventos cardiovasculares (acidente vascular encefálico, enfarte do miocárdio); overdose de drogas; causas metabólicas (cetoacidose diabética); acidente com traumas; dentre outros (ALIREZA ALA et al., 2020). De acordo com a revisão de (SANDRONI et al., 2020) cerca de 80% dos

pacientes que são admitidos em UTI após a ressuscitação de uma parada cardíaca fora do hospital estão em coma.

Uma das etiologias do coma mais comuns no Brasil é o Trauma Crânio Encefálico (TCE) que ocasiona alta mortalidade, principalmente em indivíduos do sexo masculino (GAUDÊNCIO; LEÃO, 2013). No geral, as lesões mais graves do TCE acometem o tronco encefálico ou áreas extensas do parênquima cerebral sendo possível correlacionar a severidade do TCE com os sinais e sintomas clínicos do paciente, como a Escala de Coma de Glasgow (*Glasgow Coma Scale* - GCS). Uma lesão leve apresenta GCS maior ou igual a 13 pontos, enquanto lesões mais graves tendem a apresentar valores de GCS menores (SCHOMER; SILVA, 2011). Observando o sinal EEG em um registro pós TCE observa-se presença de ondas lentas irregulares, bem como atividade periódica lateralizada (PLEDs) na região correspondente à lesão estrutural (ENGEL-JR; PEDLEY, 2008). Há possibilidade também do surgimento de padrões surto supressão associados à situação clínica mais grave (ENGEL-JR; PEDLEY, 2008; GUYTON; HALL, 2006). Outra etiologia bastante comum em pacientes comatosos é o Acidente Vascular Encefálico (AVE). Trata-se de déficit neurológico focal ou global súbito não convulsivo que dura mais de 24 horas ou que leva à morte sem causa aparente, exceto um processo patológico dos vasos sanguíneos (OBIAKO; OPARAH; OGUNNIYI, 2011).

Quando há indícios de um despertar do paciente, porém sem consciência, trata-se do estado vegetativo. Já pacientes em estado minimamente consciente são incapazes de comunicar seus pensamentos e sentimentos, porém demonstram de alguma forma consciência de si mesmos ou do ambiente (LAUREYS; OWEN; SCHIFF, 2004). A perda total e irreversível das funções encefálicas define o quadro de morte encefálica, em situações onde não há condições para recuperação estrutural e funcional do encéfalo.

Sabe-se que alguns padrões EEG são associados ao estado de coma. Na revisão de (WILSON; NORDAL, 2013) comportamentos específicos do sinal EEG podem ser levantados como presentes em situações de coma: atividade alfa predominante na região pós-central do córtex cerebral; predominância da atividade teta reativa; atividade delta predominantemente extensa ou também de baixa amplitude, irregular e não reativa; episódios chamados “surto-supressão”, atividade epilética generalizada, atividade não reativa com baixa amplitude; ou ainda nenhuma atividade EEG visível com registro de alta sensibilidade.

Diversos estudos na literatura associaram o traçado do sinal EEG com o prognóstico do paciente em coma. Por exemplo em (JIANG et al., 2019) notou-se que o padrão de onda lenta do coma foi associado ao prognóstico do paciente. Em (GOLKOWSKI et al., 2017) pacientes

que melhoraram do estado vegetativo apresentaram potência maior na banda delta e menor potência alfa e beta do que aqueles que permaneceram nesse estado. O estudo de (MIKOLA et al., 2015) evidenciou que maiores valores de potência do sinal EEG total em bandas de frequência altas em pacientes com resultado ruim pode refletir padrões de EEG epileptiformes. Diante disso, no Capítulo 4 será apresentada uma revisão dos principais achados da literatura que associam análise do sinal EEG com prognóstico do paciente comatoso.

2.4.1 Escalas de Coma

Em ambientes de UTI alguns protocolos de sedação e tomadas de decisão por parte das equipes de profissionais são baseados em escalas de sedação que servem como avaliação da profundidade do coma (NASSAR-JUNIOR et al., 2008). Uma escala muito utilizada é a Escala de Coma de Glasgow (Glasgow Coma Scale – GCS). Nela, respostas verbais, motoras e oculares são usadas permitindo a comparação entre os pacientes ao longo do tempo de tratamento (HEALEY et al., 2003; TEASDALE; BRYAN, 1974). Variando de 3 a 15, as pontuações dessa escala indicam sinal de alerta (valores mais baixos) ou ainda nível de consciência sem alteração (igual a 15 por exemplo) (ANDRADE et al., 2007).

Outra escala utilizada em ambiente de UTI é a Escala de Agitação e Sedação de Richmon (Richmond Agitation-Sedation Scale – RASS) variando entre -1 a -5, referentes aos níveis de sedação, e +1 a +4, referente aos níveis de agitação (SESSLER et al., 2002). Por se tratar de uma escala baseada em exames físicos, essa não é capaz de medir as sutilezas num profundo nível de sedação (ANDRESEN et al., 2014).

Capítulo 3

APRENDIZADO DE MÁQUINA (MACHINE LEARNING – ML)

Nesse capítulo serão abordados tópicos que envolvem definição, execução e aplicação do aprendizado de máquina.

3.1 Introdução

O aprendizado de máquina (machine learning – ML) evolui de maneira rápida e tais avanços são catalisados por fatores como combinação de experiências, recursos e necessidade de aplicação, difundidos em diversas áreas de aplicação (KOIRALA et al., 2019). Muito do aprendizado envolve a aquisição de conceitos gerais a partir de exemplos de treinamento específicos. Aprendizado de máquina é um campo da ciência da computação que permite que algoritmos aprendam padrões em grandes conjuntos de dados complexos sem serem explicitamente programados (SENDERS et al., 2018). De modo geral, os modelos de ML podem ser supervisionados, não supervisionado, e ainda semi-supervisionados. Como mostra a revisão de (NOOR; IBRAHIM, 2020), as técnicas utilizadas em ML têm o potencial de aumentar as capacidades de uso de dados EEG para fins diagnósticos e o prognósticos.

O problema de inferir automaticamente a definição geral de algum conceito é comumente referido como aprendizado de conceito (MITCHELL, 1997). A tarefa de prever uma variável aleatória discreta Y a partir de outra variável aleatória X é conhecida por classificação, aprendizado supervisionado ou reconhecimento de padrão

(WASSERMAN, 2004). Aprendizagem supervisionada é aquela que, considerando um conjunto de entradas (medidas ou predefinidas) as saídas podem ser previstas (HASTIE; TIBSHIRANI; FRIEDMAN, 2009). No geral, a literatura nomeia as entradas como preditores, as quais também podem ser chamadas de atributos de entrada ou ainda variáveis independentes. Já as saídas são denominadas como respostas ou variáveis dependentes.

Um modelo de classificação é uma representação abstrata da relação entre o conjunto de atributos e a respectiva classe de saída. O modelo pode ser representado por várias formas, seja como uma árvore, uma tabela de probabilidade ou ainda um vetor de parâmetros de valor real (TAN et al., 2018). Nesse capítulo serão abordados os principais conceitos relacionados à aprendizagem de máquina utilizados no desenvolvimento desse projeto, além de associações dessas técnicas com o processamento de dados biomédicos, como o EEG.

3.2 Dados

Existem diversas maneiras para representação de dados, podendo esses ser qualitativos ou quantitativos. Os conjuntos de dados podem ter ainda características especiais, como por exemplo dados que contêm séries temporais ou informações no domínio da frequência (TAN et al., 2018). Na prática, os dados podem apresentar comportamentos imperfeitos e algumas técnicas de mineração de dados conseguem trabalhar com tais dados.

Ressalta-se que, como mostrado na literatura clássica, (SÖRNMO; LAGUNA, 2005), o sinal EEG é complexo, podendo ser analisado tanto no domínio do tempo e da frequência, de maneira isolada, quanto no domínio tempo-frequência. As ferramentas mais consagradas de análise do EEG no domínio da frequência envolvem o cálculo da densidade espectral de potência (FREEMAN; QUIROGA, 2013). O método mais apropriado no processamento dos sinais cerebrais é a análise tempo-frequência (BUZSAKI, 2009). Nesse domínio o dado é descrito em todas as frequências em função do tempo repartindo o sinal EEG em várias épocas curtas e calculando a densidade espectral de potência para cada época (SÖRNMO; LAGUNA, 2005).

Um conjunto de dados utilizados em ML pode ser chamado de grupamento. Os grupamentos são descritos por uma série de atributos que capturam as características básicas de um objeto, no caso do sinal EEG podendo ser a potência espectral, a simetria cortical direita-esquerda, entropia temporal, dentre outras medidas quantitativas. No geral, em um grupamento, os objetos são registros (ou linhas) do arquivo e cada campo (ou coluna) corresponde a um atributo (TAN et al., 2018).

É importante destacar que existem alguns passos para adequar os dados coletados à realidade da mineração e processamento dos mesmos. Esses passos são chamados de pré-processamento dos dados e pode consistir em: agregação; amostragem; redução de dimensionalidade; seleção de subconjuntos; discretização e binarização; transformação de variável. O objetivo do pré-processamento é melhorar a análise de mineração de dados em relação ao tempo, custo e qualidade. Considerando os dados de EEG, como técnica do pré-processamento, o agrupamento de informações conforme região cerebral é utilizado, dispondo de ferramentas estatísticas como medidas de média, mediana e desvio padrão.

Considerando a técnica de transformação de variável, comumente utilizada é a padronização (ou também denominada na inteligência artificial como normalização) dos dados. Consiste em fazer com que todo um conjunto de valores tenha uma propriedade particular, por exemplo considerando medidas estatísticas (Eq. 3-1).

$$x' = \frac{x - \bar{x}}{\sigma}$$

Eq. 3-1

Onde $\bar{x}$ representa a média do conjunto de dados e σ o desvio padrão. A partir dessa transformação, cria-se uma nova variável que tem média igual 0 e desvio padrão igual a 1. Essa transformação é muitas vezes necessária para evitar que uma variável com grandes valores domine os resultados do cálculo. .

3.3 Classificadores

A classificação é a tarefa de aprender uma função alvo que mapeia cada conjunto de atributos para uma das classes existentes. Os atributos, na maioria das ocorrências, são informações discretas (TAN et al., 2018). Já em relação às classes, a condição mais fácil

em ML é quando existem apenas duas categorias de classificação, como por exemplo ‘sobreviver’ ou ‘morrer’. Nessas condições, as classes são frequentemente representadas por um único dígito binário 0 ou 1, ou ainda por -1 e 1 (HASTIE; TIBSHIRANI; FRIEDMAN, 2009).

Modelos de classificação podem servir tanto como ferramenta de distinção entre objetos quanto para predição de classes para a situação de um registro desconhecido. Entende-se modelos de classificação como uma “caixa preta” que atribui automaticamente uma classe a um registro desconhecido (TAN et al., 2018). Existem diversas técnicas de classificação que podem ser usadas na construção de modelos de classificação. As três técnicas utilizadas nesse trabalho estão descritas nos itens 3.3.1 a 3.3.3. Cada técnica emprega um algoritmo de aprendizado para identificar um modelo que melhor se ajusta ao relacionamento entre o conjunto de atributos e a classe dos dados de entrada.

3.3.1 Máquina Vetor Suporte (SVM)

A técnica chamada de máquina vetor suporte (Support Vector Machine – SVM) é um classificador binário, que consegue separar dados em duas classes. Trata-se de uma técnica com raízes na teoria do aprendizado estatístico cuja ideia central é ajustar uma função discriminante, que pode ou não ser linear, e determinar o hiperplano ótimo que maximiza a distância entre os pontos a serem classificados, fazendo com que eles possam ser separáveis (DUDA; HART; STORK, 2000). O método SVM apresenta bons resultados quando usado em dados médicos. Em casos não linearmente separáveis, à técnica da SVM pode ser aplicada a função de Kernel, a qual retorna o produto escalar das imagens de seus argumentos, possibilitando que o espaço de busca anteriormente não separável, possa se tornar linearmente separável.

Para o cálculo de SVM a função `fitsvm`, disponibilizada no software Matlab 2016Rb, fornece modelos classificatórios. Essa função tem como parâmetros de entrada as informações: função de Kernel, podendo ser linear, polinomial ou gaussiana; ordem do polinômio, quando a função de Kernel for definida como polinomial; parâmetro de escala de Kernel, podendo ser um escalar positivo pré-definido, ou, por meio de heurística, o próprio software estima esse valor; e por fim, as classes existentes, sendo -1 uma classe e +1 a outra classe. Como saída, essa função gera o classificador que, utilizando dados fornecidos, classifica-os nas classes existentes.

3.3.2 Regressão Logística (LR)

A regressão logística é um modelo de classificação, do tipo linear, utilizado em modelos de classes binárias, representada pela função sigmoide logística, como mostrado em Eq. 3-2. A função inversa, função logit, mostrada em Eq. 3-3 representa o logaritmo da razão das probabilidades para as duas classes (BISHOP, 2006). Assim, a regressão logística permite estimar a probabilidade associada à ocorrência dos eventos, com resultados variando de 0 a 1 (ou 0 a 100%).

$$\sigma(a) = \frac{1}{1 + \exp(-a)}$$

Eq. 3-2

$$a = \ln\left(\frac{\sigma}{1 - \sigma}\right)$$

Eq. 3-3

Onde: a – Função com coeficientes estimados por meio do conjunto de dados utilizando o método da máxima verossimilhança. Quando ' a ' tende a infinito, $\sigma(a)$ tende a 1. Por outro lado, quando ' a ' tende a $-\infty$, $\sigma(a)$ tende a zero.

Normalmente, para que dois grupos sejam discriminados a regra de classificação adotada é:

$\sigma(a) > 0,5$: Classe de ' a ' será 1;

$\sigma(a) < 0,5$: Classe de ' a ' será 0.

A função '`fitglm`', disponível no software Matlab 2016Rb, pode ser utilizada no cálculo de modelos com classificador LR. Com os parâmetros de entrada setados em binomial e logit, essa função produz o classificador modelado para atribuir aos dados de treino a classe 1 ou a classe 0.

3.3.3 K-Nearest Neighbor (KNN)

De modo geral, métodos de aprendizagem baseados em instância são abordagens simples, que consistem em armazenar os dados de treinamento apresentados e, diante de uma nova instância, um conjunto de instâncias semelhantes é recuperado da memória e usado para classificar essa nova instância (MITCHELL, 1997).

O algoritmo k-vizinho mais próximo (K-Nearest Neighbor – KNN) é um método que assume que todas as instâncias correspondem a pontos no espaço n -dimensional, onde

n é a quantidade de atributos (TAN et al., 2018). Os vizinhos mais próximos de uma instância são definidos em termos da medida de proximidade (distância) calculada.

A escolha de uma boa medida de proximidade é determinante para o sucesso desse algoritmo. Como exemplo de métricas tem-se: Euclidiana; Chebychev; Hamming; Mahalanobis. Cada qual dessas métricas tem uma fórmula individual para cálculo (DUDA; HART; STORK, 2000).

Para gerar o modelo a partir do classificador KNN uma função disponível no software Matlab2016Rb pode ser utilizada: `fitcknn`. Como parâmetros de entrada para essa função é indispensável fornecer os seguintes dados: tipo da métrica para cálculo da distância (podendo ser euclidiana, hamming, chebychev, entre outros); número de vizinhos; peso para os vizinhos mais próximos; e a padronização das classes, -1 ou +1. Como saída, essa função gera um modelo classificatório baseado nos parâmetros de entradas definidos, que classifica um objeto como pertencente à classe -1 ou à classe +1.

3.4 Desempenho de um classificador

A finalidade de um modelo que utilizou algoritmo de aprendizagem é prever corretamente as classes de registros “desconhecidos”, ou seja, aqueles nunca vistos anteriormente no processo de criação do modelo (MITCHELL, 1997). O desempenho de um modelo de classificação é baseado em contagens: quantidade de registros preditos em uma classe que realmente pertencem à essa classe e quantidade de registros classificados incorretamente. Essas informações contemplam o que se conhece por matriz de confusão (TAN et al., 2018). A literatura sobre ML atribui as seguintes terminologias aos componentes de uma matriz de confusão para problemas binários com classes positiva (+1) e negativa (-1). A Figura 2 exemplifica a matriz de confusão para problemas binários.

- Verdadeiro Positivo (True positive – TP): Corresponde aos casos preditos como pertencentes à classe +1, sendo verdadeiramente dessa classe.

- Falso Negativo (False Negative – FN): Corresponde aos casos preditos como pertencentes à classe -1, sendo pertencentes à classe +1.

- Falso Positivo (False Positive – FP): Corresponde aos casos preditos como pertencentes à classe +1, sendo pertencentes à classe -1.

- Verdadeiro Negativo (True Negative – TN): Corresponde aos casos preditos como pertencentes à classe -1, sendo verdadeiramente dessa classe.

		Predicted Class	
		+	–
Actual Class	+	f_{++} (TP)	f_{+-} (FN)
	–	f_{-+} (FP)	f_{--} (TN)

Figura 2 Exemplo de matriz de confusão. Fonte: Retirada de TAN et al., 2018, 296.

A partir dos dados fornecido pela matriz de confusão é possível calcular uma série de medidas de desempenho do modelo, cada qual fornecendo um tipo de informação específica sobre o modelo:

- Acurácia: Corresponde ao número de acertos da classe, Eq. 3-4.
- Sensibilidade (Recall): Trata-se da quantidade de exemplos classificada como pertencente à classe positiva que realmente são da classe positiva, Eq. 3-5.
- Especificidade: Por outro lado, essa medida informa a quantidade de exemplos classificada como pertencente à classe negativa, sendo realmente dessa classe, Eq. 3-6.
- F-escore e F-escore macro (F-macro): É uma medida que está associada à confiabilidade da acurácia uma vez que penaliza os modelos classificatórios levando em consideração o valor de média harmônica entre precisão e recall. A medida F-escore macro é ainda mais abrangente no cálculo, considerando tanto a classificação para a classe positiva quanto para a classe negativa, Eq. 3-9.

Todas as medidas citadas tem valores que variam de 0 a 1, sendo que quanto melhor o desempenho, mais próximo de 1 é a medida (KOIRALA et al., 2019).

$$Acurácia = \frac{TP + TN}{TP + FP + FN + TN}$$

Eq. 3-4

$$Sensibilidade = Recall = \frac{TP}{TP + FN}$$

Eq. 3-5

$$\text{Especificidade} = \frac{TN}{FP + TN}$$

Eq. 3-6

$$\text{Precisão} = \frac{TP}{TP + FP}$$

Eq. 3-7

$$F \text{ Score} = \frac{2 \times TP}{2 \times TP + FP + FN}$$

Eq. 3-8

$$F \text{ Score Macro} = \text{média} \left(\frac{2 \times TP}{2 \times TP + FP + FN}, \frac{2 \times TN}{2 \times TN + FP + FN} \right)$$

Eq. 3-9

Na literatura existem ainda outras medidas de desempenho como o valor preditivo positivo (Positive Predictive Value – PPV) que é a probabilidade da classe positiva e valor preditivo negativo (Negative Predictive Value – NPV) que é a probabilidade da classe negativa. Existe também o gráfico Receiver Operating Characteristics, também chamado de curva ROC, que é usado para visualizar e separar classificadores de acordo com o seu desempenho (FAWCETT, 2006). A área sob a curva ROC é denominada AUC, que também é comumente utilizada como medida de desempenho para modelos. Todas essas medidas variam de 0 a 1, sendo que quanto melhor for o desempenho, mais próximo de 1 estão essas medidas.

Considera-se como um bom modelo aquele que tem alto desempenho tanto de treinamento quanto de generalização, ou seja, quando aplicado a registros não conhecidos (nesse documento, dados de teste). Em situações que ocorre o bom desempenho no dados de treino porém um comportamento contrário para dados de teste tem-se o fenômeno conhecido como *overfitting* do modelo (TAN et al., 2018). Para minimizar o erro de overfitting, algumas técnicas podem ser aplicadas no processo de geração dos modelos, a saber:

Método *Holdout*: De modo geral, nessa técnica os dados de treino são separados em dois conjuntos denominados conjunto de treino e conjunto de teste, com proporção podendo ser 50/50 ou também 2/3 e 1/3. Um modelo classificatório é gerado a partir do conjunto de treino e tem o desempenho avaliado no conjunto de teste. Um dos problemas

dessa técnica é que, com a diminuição das informações de treino, o modelo induzido pode apresentar desempenho menor (TAN et al., 2018).

Método Validação Cruzada (Cross-validation): Essa é uma técnica simples muito utilizada para estimar o erro de predição dos modelos. Nessa abordagem, o conjunto de dados utilizado para criação do modelo é particionado, por exemplo em dois conjuntos de mesmo tamanho, e cada um dos dois conjuntos assume o papel de treino e de teste pelo menos uma vez. Assim, tem-se a validação cruzada dupla e com isso, o erro de predição é resultado da soma dos erros de predição obtidos nas duas situações. A fim de generalizar essa ideia, o método de validação cruzada k-fold foi elaborado. Assim, ao invés dos dados serem particionados em dois conjuntos, passa-se a ser particionado em k conjuntos de tamanhos iguais. Em seguida, para cada execução, uma das partições é escolhida para teste e as demais usadas para treinamento. A execução é repetida k vezes fazendo com que todos os subconjuntos sejam considerados testes. Ao final, o desempenho é medido levando em consideração os k desempenhos calculados.

Capítulo 4

REVISÃO DA LITERATURA: SINAIS EEG E FERRAMENTAS DE APRENDIZADO DE MÁQUINA

Nesse capítulo será apresentada a revisão da literatura a respeito do prognóstico do coma a partir de sinais EEG e utilização de ferramentas de aprendizado de máquina.

4.1 Introdução

Pacientes com alterações graves na consciência internados em UTIs necessitam de tratamento intenso e geram demanda de diversos profissionais da saúde como médicos, fisioterapeutas, enfermeiros, além de acontecerem em números elevados (GOLKOWSKI et al., 2017; SCARPINO et al., 2020). No protocolo geral de atendimento desses pacientes estão presentes diversos tipos de exames com o objetivo de acompanhamento clínico, como por exemplo os sorológicos (LIU et al., 2016; MÜLLER et al., 2020), os de imagem (quando possível) e ainda, é comum que sejam submetidos a registros de EEG, sempre avaliados por neurologistas especializados (XIN et al., 2017). Como descrito no Capítulo 2, o sinal EEG mede o potencial elétrico presente no córtex cerebral (FREEMAN; QUIROGA, 2013) e, apesar de sua análise clínica não ser totalmente quantitativa como no caso do exame de Eletrocardiograma (ECG), estudos indicam que é possível realizar o prognóstico do paciente comatoso a partir de análises quantitativas do sinal EEG (NOOR; IBRAHIM, 2020; SONDAG et al., 2017).

Um paciente comatoso pode apresentar desfechos geralmente negativos como estado vegetativo, estado de consciência mínima ou ainda a morte (COMANDUCCI et al., 2020). A

revisão de (SONG et al., 2020) mostra que modelos prognósticos baseados em sinais EEG fornecem condições de aprimorar a predição para distúrbios de consciência em pacientes comatosos. (NOOR; IBRAHIM, 2020) em sua revisão abordou modelos preditivos aplicados em pacientes acometidos por TCE e concluiu que o desenvolvimento do modelo preditivo baseado na combinação de vários recursos de EEG quantitativo pode ser eficiente. A revisão de (CORCHS et al., 2019) evidenciou como o sinal EEG pode ser analisado computacionalmente a fim de diagnóstico entre estado vegetativo e estado minimamente consciente, concluindo que tal sinal é uma ferramenta útil para esta finalidade. E ainda (HOFMEIJER; PUTTEN, 2020) revisou estudos que abordaram o prognóstico do paciente comatoso também baseado no traçado EEG de pacientes pós parada cardíaca, concluindo que tal sinal é capaz de prever o bom resultado do paciente.

Técnicas de aprendizado de máquina em conjunto com sinais EEG tem apresentado resultados relevantes no prognóstico do paciente comatoso. Estudo como o de (LIU et al., 2016) apresentou uma taxa de sensibilidade e especificidade de 100% e 75%, respectivamente, para o bom prognóstico do paciente comatoso após acidente vascular encefálico (AVE). Em (MÜLLER et al., 2020) pacientes comatosos por diversas etiologias apresentaram área sob a curva ROC de 81,2% para prever a sobrevivência e 79% para um prognóstico favorável. Já em (PUTTEN et al., 2017) observou-se uma taxa de 58% de sensibilidade para o bom prognóstico do paciente comatoso após parada cardiorrespiratória. Em (SONDAG et al., 2017) pacientes comatosos tiveram uma taxa de especificidade de 100% e de 29% de sensibilidade para o mau prognóstico.

Portanto, nesse capítulo serão analisados estudos cujo objetivo central foi elaborar modelos prognósticos para pacientes comatosos, baseados em sinais EEG, fornecendo informações metodológicas básicas como tipo de processamento realizado no sinal EEG, ferramentas de aprendizado de máquina utilizadas, principais valores obtidos nas medidas de desempenho, para então fornecer um cenário geral do estado da arte no presente momento.

4.2 Metodologia

Os itens 4.2.1 a 4.2.4 indicam os métodos adotados nessa síntese bibliográfica.

4.2.1 Método de busca e grupos de palavras chave

Desde o início desse projeto, ainda quando estava sendo realizada a dissertação de mestrado, diversas pesquisas relacionando sinais EEG com estado de coma foram feitas. Contudo, para fins de compor essa revisão, a pesquisa inicial visando o prognóstico do coma a partir de sinais EEG foi iniciada no ano de 2018 e finalizada no ano de 2020, nos bancos de dados Google Acadêmico, PubMed, Scielo, IEEE Xplore, Scopus.

Para organizar as buscas, foram definidos três temas de busca, cujas palavras chave, em inglês, foram combinadas entre si no momento de realização das buscas, a saber:

i) Eletroencefalografia (EEG): Esse tema refere-se ao sinal que deveria ser analisado nos estudos. As palavras chave foram: EEG; qEEG,

ii) Coma: Necessariamente os estudos que fazem parte da pesquisa deveriam abordar tratamento em pacientes comatosos, independentemente da causa do coma. Foram utilizadas as palavras chave: Coma; Comatose; Disturbs of Consciousness (DoCs); Outcomes;

iii) Inteligência Artificial e/ou Aprendizado de Máquina: Os trabalhos deveriam fazer uso de ferramentas da inteligência artificial ou aprendizado de máquina para criarem modelos prognósticos a partir de sinais EEG em pacientes comatosos. As palavras chave utilizadas foram: Machine learning (ML); Artificial Intelligence (AI); Prognostic models;

Os estudos pesquisados foram limitados em relação ao ano de publicação, sendo considerados aqueles publicados entre 2014 e 2020. As buscas por estudos com esse perfil foram estendidas também às consultas em revisões sistemáticas recentes sobre esse tema.

4.2.2 Refinamento Crítico: critérios de inclusão

Para cada combinação de palavras chave, uma planilha foi elaborada com os títulos dos trabalhos selecionados, bem como os respectivos anos de publicação. A priori apenas os títulos foram analisados e, caso apresentassem no título algumas das palavras chave, eram selecionados. De posse das planilhas montadas, o passo a passo de refinamento mostrado na Figura 3 foi seguido com o intuito de filtrar apenas os estudos de interesse, que seguiam os seguintes critérios de inclusão:

- 1 – Estudo original publicado em periódico internacional;
- 2 – Estudo que analisa o sinal EEG (podendo analisar outros também) de pacientes comatosos;

- 3 – Estudo que aplica ferramentas do aprendizado de máquina criando modelos com o fim de prognóstico do paciente comatoso a partir do sinal EEG;
- 4 – Estudo publicado a partir do ano de 2015;
- 5 – Os pacientes analisados no estudo devem ser considerados maiores de idade;
- 6 – Estudo que fornece valores de pelo menos alguma medidas de desempenho ou estatística a respeito do prognóstico e/ou predição do coma, utilizando sinais EEG.

Ressalta-se que os critérios de exclusão são aqueles opostos aos critérios de inclusão. Vale lembrar ainda que títulos repetidos foram excluídos da análise final. Inicialmente foram encontrados 85 estudos a partir das buscas bibliográficas nas bases de dados mais seis estudos selecionados de artigos de revisão sistemática ou integrativa, totalizando 91 estudos. Fazendo uma análise por títulos, 14 estudos foram excluídos por serem repetidos. Dos 77 estudos restantes, cinco foram identificados como revisões literárias e 20 não mencionavam as palavras EEG ou coma ao fazer uma busca superficial no corpo do estudo. Restaram 52 títulos que foram lidos. Desses, 19 foram excluídos ou por apresentar um objetivo diferente do prognóstico do coma, ou por não apresentar metodologia clara em relação à análise dos dados EEG bem como utilização de ferramentas de aprendizado de máquina. Dos 33 estudos restantes, todos foram lidos e resumidos. Contudo, no ultimo refinamento, foram excluídos ainda 14 títulos que não apresentaram necessariamente um modelo prognóstico a partir de sinais EEG ou ainda, não apresentaram medidas de desempenho ou estatísticas do comportamento dos modelos elaborados.

4.2.3 Levantamento de informações

Dos artigos selecionados, foram extraídos os seguintes tópicos: ano de publicação, objetivo, etiologia do coma, grupos do estudo e quantidades, informações sobre a coleta do sinal EEG, como frequência de amostragem, filtros utilizados e sistema de colocação de eletrodos, pré-processamento do sinal EEG, quantificação do sinal EEG, tipo de ferramenta de aprendizado de máquina ou inteligência artificial utilizado, validação dos modelos criados, medidas de desempenho calculadas e, por fim, resultados obtidos em termos das medidas de desempenho ou estatísticas abordadas.




Figura 3 Fluxograma do refinamento das buscas bibliográficas. Fonte: Elaborado pela autora.

4.2.4 Análise dos resultados

Os dados coletados podem ser agrupados em relação ao tipo de informação, em qualitativo e quantitativo. Considerando os dados qualitativos, tais como objetivo, etiologia do coma, tipos de atributos do coma, que não são representadas por valores numéricos, foram analisados de forma estatística por meio de atribuições de frequências de ocorrências. Sendo assim, as ocorrências são contabilizadas e representadas em forma de porcentagens. Já os dados quantitativos são submetidos à análise estatística padrão, calculando-se valores de média $\pm$ desvio padrão dos valores, fornecendo assim uma ideia quantitativa geral de cada atributo analisado.

4.3 Resultados

Os estudos escolhidos para análise terão suas informações apresentadas em quatro tabelas, cada qual com um conjunto de dados específico, de forma cronológica, ou seja, do estudo mais antigo para o mais recente, representados por algarismos romanos, respeitando a

seguinte ordem: I. (ZUBLER et al., 2015); II. (BAGNATO et al., 2014) ; III. (HOFMEIJER et al., 2015); IV. (SIVARAJU et al., 2015). V. (KANG et al., 2015); VI. (TJEPKEMA-CLOOSTERMANS et al., 2017); VII. (PUTTEN et al., 2017); VIII. (ZUBLER et al., 2017a); IX. (SONDAG et al., 2017); X. (NAGARAJ et al., 2018); XI. (RUIJTER et al., 2018); XII. (WESTHALL et al., 2018); XIII. (FATUZZO et al., 2018); XIV. (BENGHANEM et al., 2019); XV. (AMORIM et al., 2019); XVI. (MÜLLER et al., 2020); XVII. (SCARPINO et al., 2020); XVIII. (WANG et al., 2020); e XIX. (ESTRANEO et al., 2020).

Com relação aos anos de publicação, um estudo foi publicado em 2014, três estudos foram publicados no ano de 2015, quatro estudos publicados no ano de 2017, quatro estudos foram publicados em 2018, dois publicados no ano de 2019 e quatro publicados no ano de 2020. Em relação aos objetivos dos dezenove estudos, prognóstico do coma bem como predição de distúrbios de consciência através de análises do sinal EEG foram os temas de todos os estudos avaliados.

Em se tratando da causa do coma (etiologia), Tabela 1 e Tabela 2, dos dezenove artigos analisados, treze papers (68,42%) estudaram pacientes com parada cardíaca e ressuscitação cardiopulmonar, três (15,78%) trataram de pacientes pós acidente vascular encefálico, dois (10,52%) estudaram pacientes pós traumatismo crânio-encefálico e três (15,78%) analisaram pacientes em coma pós anóxico. Três estudos (15,78) consideraram diversas etiologias do coma e em um estudo (5,26%) foram considerados outros tipos de etiologias.

Considerando agora a quantidade da população estudada, bem como os grupos de análise pertencentes aos estudos (Tabela 3 e Tabela 4), o total médio de voluntários é de $N = 303,21 \pm 324,43$ pacientes. A população do estudo em todos os estudos analisados foram divididos em dois grupos com relação ao desfecho do coma, ou prognóstico do paciente: bom desfecho e mau desfecho. A quantidade média de indivíduos agrupados no bom desfecho foi igual a $129,73 \pm 89,20$ pacientes, e a quantidade média de pacientes caracterizados com o mau desfecho foi de $175,78 \pm 136,06$ pacientes. Com relação aos critérios para classificação dos desfechos, 5,26% dos estudos utilizou o critério *Glasgow Outcome Scale* (GOS), 10,52% dos estudos utilizou a *Coma Recovery Scale Revised* (CRS-R), 15,78% dos estudos não deixaram claro a escala utilizada, e por fim, a maioria dos estudos (63,15%) utilizou a *Cerebral Performance Category* (CPC).

Agora em relação ao sinal EEG analisado nos estudos, ainda na Tabela 3 e na Tabela 4, treze (68 %) não mencionam o valor da frequência de amostragem do sinal EEG coletado. Dos que mencionam, em geral, a média de frequência de amostragem utilizada foi igual a $269,7 \pm 128,7$ Hz. Já em relação as faixas de análise, notou-se que sete (36,8 %) estudos não mencionam

a faixa de frequências de análise do sinal EEG. Dos estudos que mencionam, metade faz análise do sinal EEG para os ritmos delta a beta, e metade analisam também o ritmo gama (até 70 Hz). Considerando agora o sistema de colocação de eletrodos, 13 estudos mencionam utilizar o sistema 10-20 de colocação dos eletrodos no escalpo cerebral.

Com relação ao pré-processamento do sinal EEG (Tabela 3 e Tabela 4), dos dezenove estudos analisados, seis (32%) não mencionaram se houve separação de trechos (segmentos, épocas) para análise. Dos estudos que separam épocas, cinco tem trechos definidos por médicos neurologistas, sete tem épocas escolhidas via software. No geral há tendência nos estudos em não citar a quantidade de épocas analisadas bem como a duração de cada uma. Contudo, dos estudos que citaram, nota-se que em média são avaliadas cerca de 24 épocas. Já em relação à duração dessas épocas notou-se que em média, cada trecho de EEG analisado durou 300 segundos (ou 5 minutos).

Em relação à análise do sinal EEG (Tabela 5 e Tabela 6), dos dezenove artigos analisados, doze (63,2 %) utilizaram ferramentas do processamento digital de sinais biomédicos para quantificarem os registros EEG. Dez estudos (53%) utilizaram ferramentas neurológicas de quantificação do sinal EEG. Três estudos (16%) utilizaram tanto ferramentas corriqueiras da neurologia quanto ferramentas do processamento de sinais para análise do sinal EEG. Em relação às ferramentas quantitativas do processamento digital de sinais, foram definidos três grupos para classificação dos estudos analisados:

Grupo A: Ferramentas no domínio do tempo, como análise da assimetria, curtose, histograma: Do total de estudos, 26% dos estudos utilizaram ferramentas no tempo;

Grupo B: Ferramentas no domínio da frequência, como cálculo da potência espectral, potência relativa: Do total de estudos, 42% utilizaram alguma ferramenta pertencente a essa classe;

Grupo C: Cálculo de entropias: 21% dos estudos calculou entropia.

Já considerando as análises do sinal EEG a partir de padrões comportamentais desse sinal, geralmente respeitando padrões conhecidos na literatura clínica, e por diversas vezes sendo identificados por neurologistas especializados, 65% dos estudos mencionaram análises de EEG relacionados à esse tipo de quantificação como por exemplo relação de surto – supressão, relação ondas lentas – ondas rápidas e reatividade do sinal EEG.

Um mecanismo bastante utilizado em aprendizado de máquina é a seleção de atributos como ferramenta de pré-processamento dos modelos classificatórios. Do total de estudos analisados, dezoito estudos (95%) não utilizaram ou não mencionaram esta etapa de pré-

processamento. Já em relação ao tipo de ferramenta para criação dos modelos, tem-se que: 47% utilizou regressão logística; 32% utilizou classificador árvore de decisão e/ou floresta aleatória; 11% utilizou Classificador de Bayes; 5% utilizou redes neurais; e 5% utilizou classificador SVM.

Como validação dos modelos de aprendizado de máquina é comum dividir os dados em dados de treino e dados de teste. Essa informação é importante também quando são avaliadas as medidas de desempenho. Como mostrado na Tabela 5 e Tabela 6, 58% dos estudos não mencionam a separação dos dados. Dos que mencionam, apenas quatro citam a proporção utilizada para dados de treino e dados de teste.

As medidas de desempenho fornecem informações importantes sobre o comportamento dos modelos projetados. Abordando as medidas utilizadas nos estudos, Tabela 7, nota-se que em 11% dos estudos não há cálculo dessas, sendo utilizadas apenas métricas estatísticas, já estudos que calculam a AUC e/ou curva ROC totalizaram 42%. 68% dos estudos utilizaram as medidas clássicas como acurácia, sensibilidade, especificidade, taxa de falso positivo, etc. E apenas um estudo (5%) utilizou *ODDS ratio* como forma de medida de desempenho dos modelos gerados.

Com o objetivo de fornecer valores médios obtidos para as principais medidas de desempenho mencionadas nos estudos, a Tabela 8 foi elaborada. Nela estão representados os valores de média $\pm$ desvio padrão de média referente a cada medida, lembrando que não são todos os artigos que fornecem todas as medidas mostradas nessa tabela.

Tabela 1 Informações iniciais: objetivos e etiologia do coma por estudo analisado, parte A.

Nº	Objetivo	Etiologia Coma
I	Avaliar o valor diagnóstico e preditivo de vários métodos de análise quantitativa de EEG em pacientes comatosos.	Coma definido por Glasgow, foram excluídos pacientes com hemorragia cerebral ou traumatismo crânio encefálico ou com história recente de cirurgia cerebral.
II	Encontrar o valor prognóstico do EEG em pacientes com síndrome de vigília ou minimamente consciente.	Pacientes com síndrome da vigília ou em um estado minimamente consciente.
III	Estudar o valor preditivo do EEG para o coma pós anóxico.	Coma pós parada cardíaca.
IV	Avaliar o prognóstico usando terminologia padronizada do EEG para cuidados intensivos.	Coma pós parada cardíaca.
V	Investigar o valor prognóstico da reatividade do eletroencefalograma para o despertar comportamental em pacientes comatosos etiológicamente diversos.	Pacientes em coma diferentes etiologias.
VI	Apresentar valores preditivos de um novo índice de recuperação cerebral, com base em uma combinação de medidas quantitativas de eletroencefalografia, extraídas a cada hora e combinadas pelo uso de um classificador floresta aleatória.	Adultos em coma que foram admitidos na UTI após parada cardíaca e com escore na escala de coma de Glasgow.
VII	Explorar uma abordagem de aprendizado profundo, usando uma rede neural convolucional para previsão de resultados em pacientes com encefalopatia pós-anóxica.	Pacientes com encefalopatia pós-anóxica.
VIII	Investigar o valor prognóstico de combinações de medidas de sincronização bivariadas lineares e não-lineares de EEG.	Pacientes com parada cardíaca com medida do EEG em até 24h.
IX	Confirmar os valores preditivos da atividade EEG precoce para a previsão de resultados ruins ou bons de pacientes em coma após a parada cardíaca monitorados pelo EEG. Além disso, apresentar uma análise preliminar das consequências de custo da descontinuação do tratamento de terapia intensiva baseada no EEG.	Pacientes em coma após parada cardíaca. Glasgow inferior a 8.
X	Propor um modelo de aprendizado de máquina mais avançado e um conjunto estendido de recursos de EEG que melhora significativamente o desempenho do prognóstico.	Pacientes em coma após parada cardíaca. Glasgow inferior a 8.

Tabela 2 Informações iniciais: objetivos e etiologia do coma por estudo analisado, parte B.

Nº	Objetivo	Etiologia Coma
XI	Avaliar o valor da continuidade do EEG de fundo e as flutuações de amplitude do EEG para a previsão do resultado de pacientes comatosos após parada cardíaca.	Pacientes comatosos pós parada cardíaca.
XII	Investigar o desenvolvimento temporal do EEG e o prognóstico.	Pacientes comatosos pós parada cardíaca.
XIII	Examinar o impacto do EEG contínuo (> 18 h) versus EEG reativo (< 30 min) no resultado em pacientes comatosos após parada cardíaca como parte do prognóstico multimodal.	Pacientes comatosos pós parada cardíaca.
XIV	Avaliar o valor prognóstico da reatividade do EEG para resultado neurológico para paciente pós parada cardiorrespiratória e avaliar o potencial do efeito da sedação.	Paciente em coma após parada cardiorrespiratória.
XV	Avaliar o desempenho de métodos de aprendizado de máquina usando dados de reatividade de EEG para prever bons resultados de longo prazo em lesão cerebral hipóxico-ischêmica.	Paciente em coma após parada cardiorrespiratória.
XVI	Investigar o valor prognóstico de um modelo que combina 8 características visuais do EEG em pacientes com várias etiologias de coma e também em subgrupos de pacientes com subcategorias específicas de etiologias.	Pacientes criticamente enfermos com comprometimento agudo da consciência de várias etiologias (AVC, TCE, distúrbios metabólicos, encefalopatias).
XVII	Gerar um escore e o comparar com os escores do EEG previamente propostos para identificar aquele com melhor poder prognóstico para resultados neurológicos em pacientes com distúrbios graves de consciência.	Coma por encefalopatia isquêmica hipóxica após parada cardíaca, hemorragia intracerebral, lesão cerebral traumática grave, infarto cerebral.
XVIII	Propor uma abordagem para detecção automática de níveis de consciência por meio de sinais EEG.	Lesões cerebrais, incluindo infarto cerebral, hemorragia cerebral, infecção intracraniana e encefalopatia.
XIX	Identificar preditores de desfecho clínico de curto prazo em pacientes com distúrbios de consciência prolongados devido a lesão cerebral grave adquirida.	Coma anóxico, traumático ou vascular.

Tabela 3 População de estudo, captação e pré-processamento do sinal EEG, parte A.

Nº	Grupos do estudo	Captação e sinal EEG	Pré-processamento
I	N = 79. Desfecho bom = 46. Desfecho ruim = 32.	fa=500 Hz; Filtro: 0.5-20 Hz; Sistema 10-20.	Separou épocas? Sim. Quem separou? <i>Software</i> . Quantidade de épocas? 30. Duração das épocas? 10 segundos.
II	N = 106. síndrome de vigília = 59. Estado minimamente consciente = 47.	fa = 256; Filtro: 0,5-70 Hz; Sistema 10-20.	Separou épocas? Sim. Quem separou? Neurologista. Quantidade de épocas? Não cita. Duração das épocas? 1 segundo.
III	N = 277. Desfecho bom = 128. Desfecho ruim = 149.	fa= Não menciona; Filtro: Não menciona; Sistema 10-20.	Separou épocas? Sim. Quem separou? <i>Software</i> . Quantidade de épocas? Não cita. Duração das épocas? 300 segundos.
IV	N= 100. Desfecho bom = 29. Desfecho ruim = 71.	fa = Não menciona; Filtro: Não menciona; Sistema: Não menciona.	Separou épocas? Sim. Quem separou? Neurologista. Quantidade de épocas? Não cita. Duração das épocas? 300 segundos.
V	N= 106 pacientes. bom desfecho = 48. Mau desfecho = 58.	fa = Não menciona; Filtro: Não menciona; Sistema 10-20.	Não cita.
VI	N = 283.	fa = Não menciona; Filtro: 0.5-30 Hz; Sistema: Não menciona.	Separou épocas? Sim. Quem separou? Não cita. Quantidade de épocas? Não cita. Duração das épocas? 300 segundos.
VII	N= 287. Desfecho bom = 134. Desfecho ruim = 153.	fa= 256Hz; Filtro: 0,5-35 Hz; Sistema: Não menciona.	Separou épocas? Sim. Quem separou? <i>Software</i> . Quantidade de épocas? 30. Duração das épocas? 10 segundos.
VIII	N= 94. Bom desfecho = 48. Mau desfecho = 46.	fa= 250Hz; Filtro: 0,5-20Hz; Sistema 10-20.	Separou épocas? Sim. Quem separou? Neurologista. Quantidade de épocas? 30. Duração das épocas? 10 segundos.
IX	N = 388. Bom desfecho = 187. Mau desfecho = 197.	fa = Não menciona; Filtro: Não menciona; Sistema: 21 eletrodos.	Separou épocas? Sim. Quem separou? <i>Software</i> . Quantidade de épocas? Não cita. Duração das épocas? 300 segundos.
X	N=551. Bom desfecho = 256. Mau desfecho = 295.	fa= 256Hz e 500Hz; Filtro: Não menciona; Sistema 10-20.	Separou épocas? Sim. Quem separou? <i>Software</i> . Quantidade de épocas? Não cita. Duração das épocas? Cada época de 5 min foi segmentada em 10 segundos.

Tabela 4 População de estudo, captação e pré-processamento do sinal EEG, parte B.

Nº	Grupos do estudo	Captação e sinal EEG	Pré-processamento
XI	N=559. Bom desfecho = 259. Mau desfecho = 300.	fa = Não menciona; Filtro 0,5-30Hz; Sistema 10-20.	Separou épocas? Sim. Quem separou? <i>Software</i> . Quantidade de épocas? Não cita. Duração das épocas? 300 segundos.
XII	N = 134 pacientes. Bom desfecho = 65. Mau desfecho = 69.	fa = Não menciona; Filtro: 1 – 7 0 Hz; Sistema: Não menciona.	Separou épocas? Sim. Quem separou? Neurologista. Quantidade de épocas? 5. Duração das épocas? 30 minutos.
XIII	N = 497. Bom desfecho = 230. Mau desfecho = 267.	fa = Não menciona; Filtro: 0,5–30 Hz; Sistema: 10-20.	Não cita.
XIV	N = 428. Bom desfecho = 84. Mau desfecho = 344.	fa = Não menciona; Filtro: Não menciona; Sistema: Não menciona.	Não cita.
XV	N= 50. Bom desfecho = 16. Mau desfecho = 34.	fa = Não menciona; Filtro: 0,5-50 Hz; Sistema: 10-20.	Separou épocas? Sim. Quem separou? Neurologista. Quantidade de épocas? Não cita. Duração das épocas? 10 segundos.
XVI	N= 364. Morte (N=177). Desfecho favorável (N= 139) e desfecho desfavorável (N=425).	fa = Não menciona; Filtro: Não menciona; Sistema: 10-20.	Não cita.
XVII	N = 260. Síndrome da vigília sem resposta = 108. Estado minimamente consciente = 152.	fa = Não menciona; Filtro: Não menciona; Sistema: 10-20.	Não cita.
XVIII	N = 607. Bom desfecho = 202. Mau desfecho = 405.	fa=100 Hz; Filtro: 0,5-40 Hz; Sistema: 10-20.	Separou épocas? Sim. Quem separou? <i>Software</i> . Quantidade de épocas? Não cita. Duração das épocas? 10 minutos.
XIX	N = 143. Bom desfecho = 71. Mau desfecho = 72.	fa = Não menciona; Filtro: 0,5 -70 Hz; Sistema: 10-20.	Não cita.

Tabela 5 Quantificação EEG e Ferramenta de Machine Learning (ML), parte A.

Nº	Processamento Sinal EEG	Tipo de ML	Treino/Teste. Proporção.
I	(1) assimetria de potência delta relativa, (2) correlação cruzada, (3) transformação simbólica, (4) informação mútua simbólica e (5) direcionalidade de entropia de transferência simbólica	Classificador de Bayes.	Sim. Não cita proporção.
II	(1) Amplitude do sinal EEG. (2) Bandas de frequências (delta a beta). (3) reatividade do EEG (desaceleração do traçado ou mudança de amplitude).	Regressão Logística.	Não
III	(1) desaceleração difusa; (2) EEG normal em relação à frequência dominante; (3) Padrão surto -supressão;	ODDS ratio e Regressão logística.	Não
IV	(1) voltagem normal sem quaisquer padrões epileptiformes; (2) voltagem normal com padrões epileptiformes; (3) surto de supressão ou surto de atenuação; e (4) supressão / baixa tensão; (5) reatividade.	Arvore de classificação.	Não
V	(1) Idade (2) sexo (3) etiologia (4) reflexo pupilar à luz, pontuação da Escala de Coma de Glasgow na admissão ao N-UTL, EEG-R e fusos do sono.	Modelo de regressão logística multivariável.	Não
VI	(1) Razão alfa-delta; (2) Potência do sinal; (3) entropia de Shannon; (4) Coerência Delta; (5) regularidade; (6) Número de surtos por min; (7) correlação de surtos média; (8) máxima correlação de surtos; (9) fração de correlação de surtos maior que 0,8.	Modelo de classificador floresta aleatória.	Sim. Treino e teste com 50% dos dados cada.
VII	(1) EEG no tempo, segmentado em épocas.	Rede Neural.	Sim. 80% de treino e 20% teste
VIII	(1) Assimetria de potência delta relativa, (2) correlação cruzada, (3) Discretização de amplitude, (4) Informação mútua	Classificador de Bayes.	Sim. 2/3 para treino e 1/3 para teste
IX	(1) desfavoráveis (isoeétrico, baixa voltagem ou supressão de surto com surtos idênticos), (2) intermediários (convulsões em evolução, surto-supressão sem surtos idênticos) e (3) padrões favoráveis (padrões contínuos, seja difusamente lento ou normal).	Árvore de decisão.	Não
X	(1) características de domínio do tempo (n = 12) capturando informações de amplitude variável no tempo do sinal de EEG; (2) características de domínio de frequência (n = 24) que capturam os principais padrões de EEG em diferentes sub bandas no espectrograma; e (3) características do domínio de entropia (n = 8) fornecendo medidas de complexidade e aleatoriedade do sinal de EEG.	Classificador floresta aleatória.	Sim. Não cita proporção.

Tabela 6 Quantificação EEG e Ferramenta de Machine Learning (ML), parte B.

Nº	Processamento Sinal EEG	Tipo de ML	Treino/Teste. Proporção.
XI	(1) Razão de amplitude de surto - supressão (BSAR)	Regressão Logística.	Não
XII	(1) Sem recuperação de fundo de tensão normal contínua; (2) Recuperação de fundo de tensão normal contínua; (3) EEG não epileptiforme; (4) EEG epileptiforme (quaisquer descargas $\geq 0,1$ Hz)	Regressão Logística.	Não
XIII	(1) fundo, (2) reatividade aos estímulos (3) presença de atividade epileptiforme repetitiva	Regressão logística.	Não
XIV	(1) Padrão altamente maligno foi definido como estado elétrico epilético, surto de supressão ou supressão.	Regressão logística.	Não
XV	Dados EEG quantitativo (entropias, dados na frequência) mais idade, sexo, ritmo cardíaco não passível de choque, exame neurológico na admissão (presença de reflexo pupilar), presença de padrões de EEG malignos no EEG nas primeiras 72 horas.	Classificador floresta aleatória e regressão logística.	Sim. Não cita proporção.
XVI	Continuidade de fundo, amplitude de fundo, frequência predominante de fundo, reatividade de fundo, simetria de fundo, presença de transientes de sono em estágio Não-REM 2, presença de esporádicos (ou seja, não rítmicos ou periódicos) descargas epileptiformes e finalmente presença de padrões rítmicos ou periódicos. Além disso, idade,	Floresta aleatória.	Sim. 2/3 para treino e 1/3 para teste.
XVII	(1) a terminologia do ACNS (2) Escores calculados do EEG.	Modelos logísticos multivariáveis.	Não
XVIII I	(1) duas medidas lineares, (2) medidas de sincronização de duas fases e (3) duas medidas não lineares estão incluídas. As medidas lineares são PCC e COH; as medidas de sincronização de fase são PLV e PLI; as medidas não lineares são PSDD e ICOH (parte imaginária de COH). Essas seis medidas de cada banda de frequência são extraídas dos	Máquina de vetor de suporte (SVM) e regressão linear múltipla.	Sim. Não cita proporção.
XIX	(1) Menor idade, (2) menor tempo pós-lesão, (3) maior Escala de Recuperação de Coma total revisada, (4) presença de reatividade EEG à abertura do olho (5) etiologia (6) diagnóstico clínico (7) pontuação da escala de avaliação de deficiência (8) histórico de atividade do EEG (9) reatividade acústica (10) P300 em potenciais relacionados a eventos	Regressão logística.	Não

Tabela 7 Medidas de desempenho: valores obtidos, valor médio e desvio padrão finais.

Nº	AUC	Acur	Sens	Espec	PPV	NPV
I	0,875	-	-	-	-	-
II	-	-	-	-	-	-
III	0,9	-	0,54	-	0,92	0,65
IV	-	-	0,84	1	1	0,72
V	-	0,79	0,85	0,74	0,73	0,86
VI	0,92	-	0,56	-	1	0,66
VII	0,89	-	-	-	-	-
VIII	0,81	-	0,54	-	1	0,76
IX	-	-	0,51	0,88	0,81	0,65
X	0,94	-	0,78	-	-	-
XI	0,87	-	0,57	0,9	-	-
XII	-	-	0,55	0,85	0,68	0,76
XIII	-	-	-	-	-	-
XIV	-	-	0,63	0,93	0,97	0,39
XV	0,8	-	-	-	-	-
XVI	0,81	0,74	0,83	0,64	0,69	0,8
XVII	-	0,73	0,76	0,68	-	-
XVIII	-	0,98	1	0,96	-	-
XIX	0,94	0,88	-	-	-	-
$\mu \pm dp$	0,88±0,05	0,82±0,11	0,69±0,16	0,84±0,13	0,87±0,14	0,69±0,13

* Acur - Acurácia. Sens - Sensibilidade. Espec - Especificidade.

Tabela 8 Valores médios de medidas de desempenho obtidos na literatura.

Medida	Nº artigos	Média ± DP
AUC	10 (53%)	0,8755 ± 0,05
Acurácia	5 (26%)	0,8240 ± 0,11
PPV	9 (47%)	0,8700 ± 0,14
NPV	9 (47%)	0,6944 ± 0,13
Sensibilidade	13 (68%)	0,6892 ± 0,16
Especificidade	9 (47%)	0,8422 ± 0,13

4.4 Discussão

Diante dos resultados mostrados Tabela 1 a Tabela 8, nota-se que, em relação as etiologias do coma consideradas nos estudos, a maioria analisa pacientes em coma pós parada cardiorrespiratória. Com relação a quantidade de pacientes considerados nos estudos, nota-se que em média são analisados 300 voluntários. Já em relação aos grupos dos estudos, nota-se

que no geral os pacientes são agrupados em relação a CPC em dois desfechos: bom (CPC igual a 1 ou 2) ou mau (CPC variando de 3 a 5).

Ainda considerando os resultados obtidos, nota-se que em relação à aquisição do sinal EEG, a média de frequência de amostragem foi em torno de 200 Hz, com filtragem do sinal para altas frequências em torno de 40 Hz em média. Isso indica que praticamente os ritmos analisados são apenas os clínicos, delta a beta. No geral, os estudos apontam que houve separação de trechos de interesse do sinal EEG para processamento. Contudo, a minoria dos estudos indicam a quantidade de épocas analisadas bem como a duração de cada época. Em termos de processamento quantitativo do sinal EEG, nota-se que a grande parte dos cálculos envolve quantificação do sinal EEG em relação à frequência, como valores de potência relativa do ritmo e entropia espectral. Nota-se que mais de 50% dos estudos escolheram o classificador floresta aleatória como ferramenta para criação dos modelos prognósticos.

Em relação aos principais resultados encontrados referentes às medidas de desempenho dos modelos prognósticos, nota-se que, como mostrado na Tabela 8, os valores de acurácia e AUC são superiores à 80%. Uma curiosidade é que medidas de desempenho mais criteriosas, como a medida F-escore e, por consequência, F-macro, não foram mencionadas em nenhum dos estudos considerados nessa revisão.

Durante o processo de coleta de artigos para a revisão da literatura, foram identificadas três revisões com objetivos parecidos ao do presente estudo. Uma delas, (SONG et al., 2020) teve como objetivo central determinar os efeitos prognósticos das várias técnicas utilizadas nos modelos prognósticos para pacientes com desordem de consciência. Essa revisão considerou os resultados de 21 estudos publicados entre os anos de 2002 e 2019. Outra revisão importante foi a de (CORCHS et al., 2019) cujo objetivo central foi avaliar a utilidade do EEG quantitativo aprimorada por métodos computacionais para diferenciar o estado vegetativo do estado minimamente consciente do paciente. Essa revisão considerou o total de 17 estudos publicados entre 2008 e 2018. E um terceiro estudo de revisão, (NOOR; IBRAHIM, 2020) que visou entender melhor o potencial dos recursos de EEG quantitativo para o desenvolvimento de modelos preditivos. O total de quatorze estudos foram incluídos nessa revisão e não menciona limitação de ano de publicação.

Do que foi observado nos dezenove estudos aqui analisados, resumidos na Tabela 1 a Tabela 7 na maioria deles parada cardiorrespiratória prevaleceu como etiologia do coma, o que não foi observado na revisão de (NOOR; IBRAHIM, 2020) que avaliou estudos cuja etiologia do coma foi TCE. Em relação a quantidade de pacientes, a quantidade média de pacientes considerada nos estudos aqui analisados foi igual 303,21 pessoas. Isso se difere de (NOOR;

IBRAHIM, 2020) e (SONG et al., 2020), que analisaram estudos com quantidade menor de pacientes.

Em relação às características do sinal EEG, tanto nos estudos aqui analisados quanto nos observados pelas três revisões citadas, a consideração dos ritmos rápidos gama e supergama no processamento do sinal EEG é irrisória ou nula. E em relação a escolha de trechos do sinal EEG para processamento, (CORCHS et al., 2019) também observou resultados parecidos aos aqui obtidos, ou seja, o sinal EEG costuma ter trechos separados tanto por neurologistas quanto via softwares específicos.

Nota-se que, em termos de medidas de desempenho, a média de valores relatados nos estudos levantados nesse trabalho foi acima de 80% para AUC e Acurácia. A revisão de (SONG et al., 2020) mostra que alguns modelos prognósticos foram propostos para prever precocemente o prognóstico de distúrbio de consciência, com acurácias variando de 60 a 90%. Do que foi mencionado em (NOOR; IBRAHIM, 2020) as técnicas de ML têm grande potencial para melhorar a previsão de resultados de TCE, bem como o desenvolvimento de um modelo de prognóstico baseado na combinação de vários recursos EEG quantitativo pode ser processado de forma mais eficiente usando redes neurais por exemplo e também considerando a heterogeneidade da lesão cerebral. (CORCHS et al., 2019) mostrou por meio de sua revisão que a análise do sinal EEG em estado de repouso é uma ferramenta útil para avaliar e separar pacientes em estado vegetativo e em estado minimamente consciente.

Capítulo 5

MATERIAIS E MÉTODOS

Nesse capítulo serão apresentados os materiais e métodos utilizados no desenvolver da pesquisa

5.1 Introdução

Esse estudo retrospectivo analisa sinais EEG de pacientes comatosos internados no setor de Unidade de Terapia Intensiva do Hospital de Clínicas da Universidade Federal de Uberlândia entre os anos de 2010 a 2020. Nesse capítulo serão abordados os aspectos metodológicos da pesquisa, subdivididos em nove tópicos a saber:

- 5.2 Base de Dados EEG
- 5.3 Avaliação dos sinais EEG
- 5.4 Categorias de desfechos
- 5.5 Quantificação do sinal EEG
- 5.6 Organização dos atributos quantitativos de entrada
- 5.7 Organização dos atributos qualitativos de entrada
- 5.8 Dados de Treino e de Teste
- 5.9 Modelos prognósticos
- 5.10 Medidas de desempenho e análise estatística

Cada tópico terá como objetivo explicar as tomadas de decisões baseadas em eventos posteriores ou ainda análises da literatura, além de demonstrar o passo a passo para que os objetivos centrais desse estudo fossem alcançados.

5.2 Bases de Dados EEG

Os sinais EEG analisados nesse estudo foram coletados de forma clínica, provenientes do setor de neurologia do Hospital de Clínicas da Universidade Federal de Uberlândia (HCU-UFU). Trata-se de registros coletados entre os anos de 2010 a 2020, pela equipe técnica responsável, em pacientes comatosos internados na UTI Adulto desse hospital. Os dados coletados foram agrupados conforme período de coleta e suas características quantitativas, em termos da frequência de amostragem. Sendo assim, dois grupos de sinais foram armazenados: o Grupo denominado Frequências Clínicas 1 – 30 Hz, e o Grupo denominado Alta Frequência 1- 100 Hz. A diferença básica entre esses dois grupos é que no segundo as informações dos ritmos gama (30 – 80 Hz) e supergama (80 – 100 Hz) foram levadas em consideração na análise quantitativa do sinal EEG. Essa abordagem é de extrema relevância uma vez que, assim como apresentado no Capítulo 4, estudos que fazem tal tipo de análise não são realizados pelos pesquisadores da área.

5.2.1 Grupo Frequências Clínicas: 1 – 30 Hz

Inicialmente, para que os registros pertencentes à essa classe pudessem ser analisados, foi solicitado ao Comitê de Ética em Pesquisas com Seres Humanos da Universidade Federal de Uberlândia (CEP-UFU), uma liberação de uso e análise de dados. Sendo assim, e visto que o presente estudo é fruto de uma pesquisa realizada por pelo menos, sete anos, dois pareceres do CEP-UFU foram emitidos, cujos números são: 369/11 (Anexo I), que aborda a liberação da análise dos dados pertencentes aos anos 2010 a 2014, e 2.570.022 (Anexo II) o qual se refere aos registros realizados entre os anos de 2015 e 2020.

A quantidade de registros EEG coletados no setor de neurologia, realizados entre os anos de 2010 a 2014 foi igual a 238 exames. Entre os anos de 2015 a 2020 foram armazenados um total de 1252 exames EEG. Sendo assim, nesse grupo, tem-se o total de 1490 registros EEG.

Foram definidos alguns critérios de inclusão, a saber:

- 1 – O exame EEG deveria ter sido realizado em paciente comatoso;
- 2 – O exame EEG deveria, pelo menos, conter 20 minutos de dados;

3 – O exame EEG deveria estar clinicamente laudável, ou seja, após a observação de um neurologista especializado, o exame apresentasse condições de ser observado e avaliado clinicamente;

4 – O exame EEG deveria apresentar, no mínimo, dez trechos de dois segundos seguidos, livres de artefatos visuais, trechos esses, também definidos por neurologistas especializados;

5 – O sinal EEG deveria ter sido coletado por um amplificador de sinais biomédicos que fornecesse o arquivo do exame em formato compatível ao utilizado na presente pesquisa;

6 – A coleta do exame EEG deveria ter seguido o sistema 10-20 de colocação de eletrodos, sendo registrados portanto, o total de 20 canais de EEG.

7 – A frequência de amostragem mínima do registro EEG deveria ser de 200 Hz, para que as informações até 30 Hz pudessem ser analisadas com efetividade;

8 – Os seguintes dados do paciente deveriam ser armazenados: número do prontuário, data do registro EEG, motivo do pedido EEG, sexo do paciente, idade, nível de consciência do paciente no momento do exame, medido ou pela escala de Glasgow ou pelo índice de RASS, causa do coma (etiologia) e tipo de desfecho ou prognóstico do paciente.

9 – E escala natural do coma do paciente, se fosse o caso, deveria medir até no máximo oito pontos. Por outro lado, caso o paciente tivesse a informação do nível de sedação, esse deveria ser entre -5 e -3.

Além dos critérios de inclusão, definiu-se alguns critérios de exclusão, além dos casos opostos aos citados nos itens 1 a 8, a saber:

1 – Registros EEG contendo, pelo menos, 3 eletrodos considerados inadequados para processamento, critério esse também definido pelo médico neurologista;

2 – Pacientes menores de 18 anos de idade;

3 – Pacientes classificados mais de 8 na escala de coma de Glasgow.

É importante destacar que os dados clínicos coletados dos pacientes são confidenciais, e, assim como assinado em documento ao CEP-UFU, apenas uma equipe pertencente ao setor de neurologia da UFU, especializada e autorizada, realizou essa busca de informações, associando os dados demográficos apenas ao número do exame do paciente, inviabilizando a associação do número do exame do paciente ao seu nome.

5.2.2 Grupo Altas Frequências: 1 – 100 Hz

Assim como no Grupo de Frequências Clínicas, os registros do grupo Altas Frequências também foram liberados para análise pelo CEP com número de protocolo 2.570.022. O total de 519 exames EEG foram coletados para completar esse grupo. Nota-se que, os critérios de inclusão e exclusão para esse grupo são similares aos do grupo de frequências clínicas, contudo, como critério exclusão para altas frequências é necessário frisar que:

- 1 – Registros EEG com frequência de amostragem menor que 400 Hz foram excluídos;
- 2 – Registros EEG cujo filtro passa-baixa utilizado foi diferente de 100 Hz foram excluídos;

5.3 Avaliação dos sinais EEG e definição de trechos de interesse

Todos os sinais EEG aprovados para serem analisados quantitativamente foram avaliados por dois médicos neurologistas, Dr Marcos Campos e Dr Paulo Bettero, com o objetivo de:

- 1 – Constatar que o exame EEG trata-se de um registro pertencente à um paciente comatoso, apresentando características morfológicas bem definidas na literatura, como presente em (SCHOMER; SILVA, 2011).
- 2 – Definir os dez melhores trechos no exame, com pelo menos dois segundos seguidos de análise, sendo esses livres de artefatos visuais, como por exemplo ruído de rede, ruídos musculares, ruídos de eletrocardiograma (ECG).

Ao final, cada exame EEG analisado, é representado por dez trechos (épocas) de dois segundos cada.

5.4 Categorias de desfechos: Favorável versus Desfavorável

Observando os desfechos dos pacientes comatosos, percebeu-se que no geral esses desfechos podem ser resumidos em favorável ou desfavorável. Entende-se por desfecho favorável aquele em que o paciente consegue alta médica da UTI bem como do hospital, sem

maiores danos físicos e/ou neurológicos. Para os dados mais antigos, contou-se com a colaboração da equipe médica tanto do setor de neurologia quanto setor da UTI do HC/UFU para acesso a essas informações.

Nessa pesquisa, foram considerados três desfechos possíveis para o paciente comatoso, levando em consideração os dados demográficos coletados: Ativo (AT), ou seja, desfecho favorável, Óbito Clínico (OC), ou seja, desfecho desfavorável em que o paciente morreu ainda na UTI por motivos clínicos, podendo ser parada cardiorrespiratória por exemplo, e ainda Óbito por Morte Encefálica (OME), também desfecho desfavorável, contudo, nesse caso, o paciente comatoso deve obrigatoriamente evoluir para morte encefálica, tendo o protocolo de morte encefálica inicializado e finalizado pela equipe clínica do HCU-UFU conforme parâmetros médicos vigentes.

Tanto no grupo de frequências clínicas (1 – 30 Hz) quanto no grupo de altas frequências (1 – 100 Hz) os desfechos Ativo e Óbito Clínico foram identificados. Contudo o desfecho Óbito por morte encefálica foi menos observado no grupo de altas frequências.

5.5 Quantificação do sinal EEG

Todos os sinais EEG que tiveram épocas definidas pelos neurologistas foram submetidos ao processo de quantificação. Foram considerados sete quantificadores distintos, alguns bastante utilizados na literatura, que serão descritos nos itens 0 a 0. Desses, cinco quantificadores analisam o espectro do sinal EEG, portanto, tem-se informações no domínio da frequência, e dois analisam o sinal EEG no tempo.

5.5.1 Quantificador Porcentagem de Contribuição de Potência (PCP)

Trata-se de um quantificador desenvolvido na dissertação de mestrado da autora, (RAMOS, 2017), que quantifica os níveis de potência normalizada presente em cada ritmo cerebral avaliado. Esse cálculo é realizado para cada eletrodo EEG considerado no exame. A Eq. 5-1 resume como é calculada a PCP.

$$PCP_{ritmo}(i) = \frac{\int_{f=f_{in}}^{f_{out}} |S_x^i(f)|^2 df}{P_i} \quad i = 1, 2, \dots, N$$

Eq. 5-1

Sendo: i – Época (ou trecho); P_i – Potência total do sinal na época i ; PCP_{ritmo} – Porcentagem de potência espectral do ritmo, na época i ; f_{in} – Frequência inicial do ritmo (o ritmo pode variar de delta a beta no caso do grupo de frequências clínicas ou de delta a supergama, para altas frequências); f_{out} – Frequência final do ritmo; $S_x i(f)$ – Densidade espectral de potência na época i . N – quantidade total de segmentos.

Considerando um único registro EEG, o cálculo de PCP fornece dez valores, variando de 0 a 100 pois esse quantificador é fornecido em porcentagem, por ritmo e por eletrodo avaliados.

5.5.2 Quantificador Variação da Potência Cerebral (VPC)

Esse quantificador foi desenvolvido por (OLIVEIRA, 2018) na sua dissertação de mestrado. Trata-se da quantificação do desvio padrão de PCP, observado ao longo das N épocas do sinal EEG. A Eq. 5-2 resume como é calculada a VPC.

$$VPC_{ritmo} = \sqrt{\frac{\sum_{i=1}^N (PCP_i - PCP_{médio})^2}{N-1}} \quad i = 1, 2, \dots, N$$

Eq. 5-2

Sendo: i – Época (ou trecho); PCP_i – Porcentagem de potência espectral na época i ; $PCP_{médio}$ – Média de PCP.

Diferente do quantificador PCP, para cada EEG analisado, tem-se um valor de VPC por eletrodo e por ritmo. Esse quantificador não tem faixa pré-definida de valores mínimo e máximo.

5.5.3 Quantificador Frequência Mediana (FM)

Assim como PCP, é um quantificador retirado da dissertação de mestrado da autora, e o mesmo aponta em qual frequência, dentro de um ritmo cerebral, há maior concentração dos níveis de potência dentro daquele ritmo. A Eq. 5-3 indica como calcular o quantificador FM. Nota-se que, para cada sinal EEG e cada ritmo, calcula-se dez valores de FM por eletrodo.

$$FM_{ritmo}(i) = \frac{\sum_{i=1}^N |S_x i(f)|_{ritmo} \cdot f_{ritmo}}{P_i} \quad i = 1, 2, \dots, N$$

Eq. 5-3

Sendo: $FM_{ritmo}(i)$ – Frequência Mediana; S_x – Densidade espectral de potência calculada para determinada faixa de frequências; f_{ritmo} – Vetor de frequências pertencentes à determinada faixa de frequências. P_i – Potência espectral obtida no segmento. i – Segmento considerado.

5.5.4 Quantificador Coerência (COR)

Esse quantificador é bastante conhecido na literatura clássica de EEG. Trata-se do grau de simetria ou similaridade, medida entre dois eletrodos correspondentes. Aqui, a coerência calculada é baseada nos hemisférios direito e esquerdo, levando em consideração 8 pares de eletrodos, a saber: - PAR 1: FP1 e FP2; -PAR 2: F7 e F8; -PAR 3: F3 e F4; -PAR 4: T3 e T4; -PAR 5: C3 e C4; -PAR 6: T5 e T6; -PAR 7: P3 e P4; -PAR 8: O1 e O2. Os valores obtidos variam de 0, indicando baixa coerência, a 1, indicando coerência total. . A Eq. 5-4 demonstra como calcular o quantificador COR

$$|\Gamma_{xy}(e^{j\omega})|_i^2 = \frac{|S_{xy}(e^{j\omega})|^2}{S_x(e^{j\omega})S_y(e^{j\omega})} \quad i = 1, 2, \dots, N$$

Eq. 5-4

Sendo: S_{xy} – Densidade espectral de potência cruzada; S_x – Densidade espectral do sinal X; S_y – Densidade espectral do sinal Y; i – Segmento considerado.

5.5.5 Quantificador Entropia Espectral (SE)

Baseado no estudo de (NUNES; ALMEIDA; SLEIGH, 2004) esse quantificador calcula a entropia espectral normalizada, portanto, variando entre 0 e 1, do sinal EEG no domínio da frequência. Sendo assim, para cada ritmo cerebral, calcula-se os valores de SE para todas as épocas definidas para o sinal EEG analisado. Valores de SE próximos de 0 indicam regularidade total do sinal e valores próximos de 1 indicam irregularidade total do sinal. As Eq. 5-5 e Eq. 5-6 informam como foi calculada a entropia espectral.

$$SE_{ritmo}(i) = \sum_{i=0}^N Pn(f(i)) \log\left(\frac{1}{Pn(f(i))}\right) \quad i = 1, 2, \dots, N$$

Eq. 5-5

$$SEn_{ritmo}(i) = \frac{SE_{ritmo}(i)}{\log(N - length(Pn))}$$

Eq. 5-6

Sendo: $f(i)$ – Vetor de frequências do ritmo na época i ; Pn – Potência normalizada.

5.5.6 Quantificador Assimetria

A Assimetria é uma medida estatística que analisa os dados em torno da média da amostra. Se a assimetria for negativa, os dados se espalharão mais para a esquerda da média do que para a direita. Se a assimetria for positiva, os dados se espalharão mais para a direita. A função utilizada nesse quantificador foi a fornecida pelo software Matlab R2016b, denominada skewness, mostrada pela Eq. 5-7.

$$Skn = \frac{E(X - \mu)^3}{\sigma^3}$$

Eq. 5-7

Sendo: X – Sinal EEG; μ - Média de X ; E – Esperança; σ – Desvio padrão.

5.5.7 Quantificador Curtose

A curtose é a medida que caracteriza a forma da distribuição em relação ao achatamento da curva, ou ainda, o quão propensa a outliers é uma distribuição. A função utilizada para esse cálculo foi a kurtosis, fornecida também pelo software Matlab R2016b. A curtose da distribuição normal é 3. Valores maiores que 3 indicam maior propensão a outlier. Já distribuições que são menos propensas a outliers têm curtose menor que 3. A Eq. 5-8 demonstra como foi calculada a curtose.

$$Kurt = \frac{E(X - \mu)^4}{\sigma^4}$$

Eq. 5-8

Sendo: X – Sinal EEG; μ - Média de X ; E – Esperança; σ – Desvio padrão.

5.6 Organização dos atributos quantitativos de entrada

Sabe-se que o sinal EEG analisado nesse estudo é composto por, pelo menos, vinte informações (total de eletrodos utilizados), posicionados em regiões distintas do córtex cerebral, e que para cada eletrodo, foram calculados os quantificadores descritos na seção 5.5. Portanto, considerando apenas um registro EEG, para cada ritmo cerebral, serão obtidas 1220 informações englobando os cálculos dos quantificadores.

Estipulou-se portanto, que esses dados fossem resumidos em termos de regiões cerebrais. Esse método considerou o agrupamento dos eletrodos por região do córtex cerebral. Sendo assim, para cada ritmo cerebral bem como cada quantificador, os valores foram agrupados em cinco regiões cerebrais, que são: Frontal, Central, Temporal, Parietal e Occipital. Os valores agrupados em cada região foram submetidos a análise estatística descritiva, a fim de representar por meio da informação de mediana, o total de valores obtidos. Em suma, a quantidade de atributos considerada para análises está disposta na Tabela 9.

Tabela 9 Total de atributos de entrada por quantificador.

Quantificador	EEG 1 – 30 Hz		EEG 1 – 100 Hz	
	Regiões Observadas	Total de Dados	Regiões Observadas	Total de Dados
PCP	5	20	5	30
VPC	5	20	5	30
FM	5	20	5	30
COR	5	20	5	30
SE	5	20	5	30
Assimetria	5	5	5	5
Curtose	5	5	5	5

5.7 Organização dos atributos qualitativos de entrada

Os dados demográficos dos pacientes também foram considerados na análise. As informações qualitativas de etiologia do coma e nível de consciência no momento do exame EEG do paciente foram convertidas em dados quantitativos, utilizando para isso a ideia de

frequência de acontecimentos. Sendo assim, foram obtidas mais cinco informações, por registro EEG, os dados qualitativos desses pacientes são: presença da etiologia AVE, presença da etiologia TCE, presença da etiologia CM, identificação de qual escala do coma o paciente foi submetido (CGS ou RASS) e por fim o valor numérico da respectiva escala.

5.8 Dados de treino e dados de teste

Como o objetivo do estudo é criar modelos binários de aprendizado de máquina capazes de identificar o prognóstico do paciente comatoso, foi necessário segmentar os registros EEG em dados de treino e dados de teste. Treino são aqueles registros apresentados ao algoritmo de aprendizado de máquina, proporcionando informações necessárias para criar os modelos prognósticos. Dados de teste são os sinais EEG utilizados para testarem o desempenho de um modelo criado.

A proporção da distribuição dos registros EEG nas duas classes treino e teste foi de 2/3 e 1/3 respectivamente, e essa definição ocorreu de forma aleatória utilizando a técnica denominada holdout com cinco interações. A proposta desse estudo foi trabalhar com classificação binária, portanto, os sinais EEG foram agrupados conforme desfechos, compondo o que aqui se chama grupamentos. Optou-se por manter a proporção 2/3 treino e 1/3 teste para ambas as classes participantes de cada grupamento.

5.9 Modelos Prognósticos

Foram considerados três tipos de classificadores na criação dos modelos prognósticos desse estudo: modelos levando em consideração os classificadores máquina de vetores de suporte (SVM), ou ainda regressão logística (LR) e também k-vizinhos mais próximos (KNN).

O algoritmo criado a partir do classificador SVM foi capaz de gerar 24 modelos, a partir da função `fitcsvm`, disponibilizada no software Matlab 2016RB. Variando os parâmetros de entradas tais como tipo da função utilizada (polinomial, linear ou gaussiana), ordem ou grau da função polinomial, valor do kernel considerado na função gaussiana, foi possível gerar esses diferentes modelos prognósticos.

Em relação ao algoritmo criado a partir do classificador KNN, foram gerados 30 modelos a partir da função `fitcknn` (também disponibilizada no software Matlab 2016RB) cuja variação dos parâmetros de entrada foram: tipo de distância utilizada no cálculo (chebychev, cosseno, euclidiana, euclidiana padronizada e hamming); quantidade de vizinhos (1, 5 ou 10); e ainda a consideração ou não de pesos.

Já para o classificador LR foi gerado apenas um modelo a partir da função `fitglm` (disponível também no software Matlab 2016RB) com opção `logit` de parâmetro de entrada.

Para todos os modelos criados, foi adotada a validação cruzada considerando 5 folds, repetindo a iteração três vezes. Destaca-se que, como os dados de treino/teste sofrem cinco variações, é necessário realizar o processamento dos modelos para todas elas, o que resulta em 15 matrizes de confusão geradas por modelo implementado.

5.10 Medidas de Desempenho e Análise estatística

Nota-se que levando em consideração as técnicas de holdout e validação cruzada k-fold, a quantidade de matrizes de confusão geradas é elevada. A fim de resumir os dados, a estatística descritiva foi utilizada, representada pelos valores de média ou mediana. Sabe-se que as medidas de desempenho são referenciais importantes que fornecem informações a respeito do sucesso de um modelo gerado. Aqui foram consideradas as medidas de desempenho Acurácia, Sensibilidade, Especificidade e F-escore macro. Essas medidas foram calculadas e armazenadas em tabelas e gráficos para posterior análise e comparação dos modelos.

A fim de verificar se existe modelo com desempenho melhor, o teste de Mann-Whitney foi utilizado, considerando um nível de significância de 95%. Esse teste, por se tratar de um teste não paramétrico, foi escolhido uma vez que o comportamento das amostras submetidas ao teste nem sempre foram considerados normais. Nota-se que um valor de p menor que 0,05 (ou 5%) indica que os dados comparados são estatisticamente distintos, e o contrário também é verdade.

Capítulo 6

ANÁLISE RITMOS CLÍNICOS

Nesse capítulo estão os resultados obtidos nas análises de EEG considerando ritmos cerebrais clínicos, ou seja, delta, teta, alfa e beta

6.1 Introdução

Nesse capítulo os ritmos cerebrais clínicos, delta, teta, alfa e beta, serão considerados naqueles quantificadores estipulados para o domínio da frequência (PCP, VPC, FM, COR e SE) como apresentado no Capítulo 5. Os modelos prognósticos propostos tem como atributos de entrada os resultados dos quantificadores na frequência e/ou no tempo.

Esse capítulo está dividido em:

- Metodologia: Diante do exposto no Capítulo 5, aqui serão concentradas as principais tomadas de decisões no pré-processamento e análise dos dados EEG. Aborda-se os tipos dos sinais EEG utilizados e os grupos considerados nessa etapa; pré-processamento e atributos de entrada; separação entre dados de treino e de teste; modelos elaborados; medidas de desempenho utilizadas; e por fim análise estatística.
- Resultados: Os resultados serão apresentados em três tópicos. Cada tópico será a respeito de um grupamento de estudo, com resultados obtidos nos modelos treinados e testados.
- Discussão: Os resultados obtidos serão confrontados com os achados da literatura.

6.2 Metodologia

A metodologia aqui desenvolvida, resume o que foi apresentado no Capítulo 5, de forma a caracterizar como foi realizado o procedimento de materiais e métodos considerando os sinais EEG no domínio da frequência apenas nas faixas de 1 a 30 Hz.

6.2.1 Sinais EEG: Grupos do estudo

Diversos registros EEG foram coletados e submetidos às análises dos critérios de inclusão/ exclusão dessa pesquisa. Do total de 1490 registros, foram utilizados 112 registros EEG. Esses sinais foram representados por dez trechos de dois segundos cada trecho, em ordem cronológica.

Na Tabela 10 tem-se as quantidades de registros EEG agrupados conforme Desfecho e Etiologia do coma. Nesse capítulo serão analisados problemas binários de classificação, portanto os grupamento aqui analisados serão:

- Grupamento A: Grupos Ativo e OC, com total de 97 registros EEG;
- Grupamento B: Grupos Ativo e OME, com total de 51 registros EEG;
- Grupamento C: Grupos OC e OME, com total de 76 registros EEG.

Tabela 10 Quantitativo de registros EEG considerando etiologia e desfecho dos pacientes, EEG 1 – 30 Hz.

Etiologias	Ativo	OC	OME	Total
AVE	07	14	3	24
TCE	17	18	4	39
CM	05	14	3	22
Outros	07	15	5	27
<i>Total</i>	<i>36</i>	<i>61</i>	<i>15</i>	<i>112</i>

AVE – Acidente Vascular Encefálico. TCE – Traumatismo Crânio Encefálico. CM – Coma Metabólico.

6.2.2 Pré-processamento e preparação das Matrizes de Atributos

As épocas dos 112 registros EEG foram submetidas aos cálculos dos quantificadores PCP, FM, COR, VPC, S, Assimetria e Curtose. Além dos quantificadores, as informações de etiologia do coma e níveis de consciência também foram consideradas fazendo uso da adaptação dos dados qualitativos para informações quantitativas.

Com o objetivo de averiguar se há alguma categoria de quantificadores (domínio da frequência e/ou domínio do tempo) com melhor desempenho na separação das classes, foram elaboradas cinco conjuntos diferentes de análises, aqui denominados Matrizes de Processamento. Sendo assim, na Tabela 11 estão dispostos os conjuntos gerados. Vale lembrar que essa tarefa foi executada individualmente, para cada grupamento analisado.

Tabela 11 Atributos de entrada adotados nas matrizes utilizadas para modelos prognósticos

Matrizes de Processamentos	Parâmetros de Entrada	Quantidade de Atributos
1. Matriz ALL_Q	Todos quantificadores mais dados demográficos.	115
2. Matriz FRE_Q	Quantificadores PCP, FM, VPC, COR e SE.	100
3. Matriz FRE+D_Q	Quantificadores PCP, FM, VPC, COR e SE mais dados demográficos.	105
4. Matriz TMP_Q	Assimetria e Curtose.	10
5. Matriz TMP+D_Q	Assimetria e Curtose mais dados demográficos.	15

6.2.3 Dados Treino e Teste

Levando em consideração os grupamentos A a C, bem como a proporção 2/3 e 1/3 para dados de treino e de teste, respectivamente, na Tabela 12 estão demonstradas as quantidades de cada desfecho no processo de composição das matrizes de entradas.

Tabela 12 Quantitativo de dados de treino e dados de teste, EEG 1 – 30 Hz.

Desfechos	Dados de Treino	Dados de Teste
Ativo	24	12
OC	41	20
OME	10	5


Embora a quantidade de registros EEG classificados como treino e como teste seja fixa, a partir da ferramenta de *hold out*, cinco combinações de diferentes possibilidades para treino e teste foram feitas, de maneira aleatória. Sendo assim, cada matriz de entrada descrita no Tabela 11 foi composta por cinco diferentes dados de treino e cinco diferentes dados de teste.

6.2.4 Modelos Prognósticos e Medidas de Desempenho Treino: Ritmos Clínicos

Assim como descrito no Capítulo 5, foram elaborados 55 modelos prognósticos, resultantes da combinação entre algoritmo classificador e parâmetros de entradas, para cada matriz de dados, a partir dos dados de treino. Como método de validação cruzada, a ferramenta

k-fold com cinco pastas foi adotada, sendo repetida três vezes para cada modelo gerado. A Figura 4 ilustra o processo de criação dos modelos, contextualizando os diferentes grupamentos analisados, bem como as combinações de atributos de entrada.

Por meio da Figura 4 é possível notar que, inicialmente é gerada uma matriz de dados com todos os atributos de entradas, contendo uma quantidade X de dados de treino da classe 1 e uma quantidade Y de dados de treino da classe -1. Dessa matriz são geradas cinco matrizes de entrada contendo, nessa ordem, as informações: todos atributos; apenas atributos de frequência; atributos de frequência mais atributos de demografia; apenas atributos de tempo; e por fim atributos de tempo mais atributos de demografia. Cada matriz de entrada gerada é submetida aos algoritmos para geração de modelos e esse processo acontece três vezes para cada algoritmo. Ao final, considerando um único grupamento, contendo as classes 1 e -1, conclui-se que são gerados 55 diferentes tipos de modelos, e para cada modelo são obtidos quinze matrizes de confusão. Essas quinze matrizes de confusão fornecem subsídios para os cálculos da acurácia, sensibilidade, especificidade e F-Macro.



- A combinação de atributos de entrada pode ser : Todos os atributos; Frequência, Frequência + Demografia, Tempo, ou ainda Tempo + Demografia.
- Os grupamentos podem ser: A (ativo versus OC); B (ativo versus OME); e C (OC versus OME).

Figura 4 Ilustração da metodologia para criação dos modelos prognósticos.

6.2.5 Análise Estatística e Definição dos Melhores Modelos

Sendo F-macro a medida mais rigorosa para avaliar os modelos gerados, ela foi utilizada para definir quais combinações de parâmetros dos modelos bem como os tipos de classificadores geram melhores resultados. Sendo assim, foram considerados para cada grupamento, os modelos que tiveram maior índice de F-Macro no desempenho de treino. Para encontrar o valor final de F-Macro, foi realizada a estatística descritiva, ou seja, cálculo da mediana e desvio padrão de mediana dos quinze resultados obtidos no processamento dos dados. Uma vez escolhidos os melhores modelos, os dados de teste foram utilizados nas melhores combinações para verificar o desempenho dos modelos. Ao final, para cada modelo, foi gerada a matriz de confusão e por meio dessa, os valores de acurácia, sensibilidade, especificidade e F-macro foram calculados.

6.3 Resultados

Os resultados obtidos foram organizados por grupamento analisado. Assim os itens 0 a 0 são referentes aos resultados para o grupamento A ao grupamento C respectivamente.

6.3.1 Grupamento A: Ativo x Óbito Clínico

Nesse grupamento tem-se o total de 97 registros EEG, sendo 36 pertencentes à classe 1 (desfecho ativo). Nota-se portanto que a proporção dos dados é de 37% com desfecho de vida e 63% com desfecho de morte, resultando portanto em quantidade desbalanceadas dos dados. Essa informação deve ser levada em consideração uma vez que ao analisar medidas de desempenho, existe tendência em levar em consideração apenas os valores obtidos para acurácia, contudo, nesse capítulo, as medidas de desempenho serão avaliadas de maneira concomitante, dando prioridades à medida F-macro.

A Tabela 13 contém os valores de mediana $\pm$ desvio padrão da medida de desempenho acurácia de treino, obtidos nos 55 modelos gerados, para cada categoria de combinação dos atributos das matrizes de entrada. Já na Tabela 14 tem-se os valores obtidos de mediana $\pm$ desvio padrão da medida de desempenho de treino F-macro.

De modo geral nota-se que, levando em consideração apenas os resultados de acurácia, Tabela 13, os modelos apresentaram índices maiores quando as matrizes de entradas eram compostas apenas por atributos no domínio do tempo. Nota-se que o maior valor de acurácia obtido foi igual a 0,66 e o menor igual a 0,43. Esses resultados indicam que a classificação desses dados de EEG é de certa forma complexa.

Tabela 13 Valores de Acurácia treino, grupamento A, EEG 1 – 30 Hz.

(continua)

Modelos	Todos	Fre	Freq + D	Temp	Temp + D
SVM 1	0,58 ± 0,03	0,56 ± 0,03	0,6 ± 0,02	0,63 ± 0,04	0,58 ± 0,05
SVM 2	0,58 ± 0,05	0,55 ± 0,05	0,58 ± 0,05	0,6 ± 0,04	0,61 ± 0,04
SVM 3	0,58 ± 0,03	0,56 ± 0,06	0,56 ± 0,05	0,61 ± 0,04	0,6 ± 0,04
SVM 4	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0
SVM 5	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0
SVM 6	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0
SVM 7	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0
SVM 8	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0
SVM 9	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0
SVM 10	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0
SVM 11	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0
SVM 12	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0
SVM 13	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0
SVM 14	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0,01	0,63 ± 0,01
SVM 15	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,64 ± 0,03	0,61 ± 0,04
SVM 16	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0,00	0,63 ± 0,04
SVM 17	0,61 ± 0,02	0,61 ± 0,02	0,63 ± 0,02	0,63 ± 0	0,63 ± 0,01
SVM 18	0,63 ± 0,01	0,63 ± 0,01	0,63 ± 0,00	0,63 ± 0	0,63 ± 0
SVM 19	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0
SVM 20	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0
SVM 21	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0
SVM 22	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0
SVM 23	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0
SVM 24	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0
LR	0,56 ± 0,09	0,52 ± 0,05	0,55 ± 0,05	0,56 ± 0,03	0,56 ± 0,06
KNN 1	0,56 ± 0,07	0,6 ± 0,03	0,6 ± 0,05	0,58 ± 0,07	0,50 ± 0,03
KNN 2	0,56 ± 0,07	0,6 ± 0,03	0,6 ± 0,05	0,58 ± 0,07	0,50 ± 0,03
KNN 3	0,53 ± 0,05	0,53 ± 0,04	0,53 ± 0,05	0,56 ± 0,05	0,52 ± 0,06
KNN 4	0,53 ± 0,05	0,53 ± 0,04	0,53 ± 0,05	0,56 ± 0,05	0,52 ± 0,06
KNN 5	0,52 ± 0,05	0,49 ± 0,05	0,52 ± 0,06	0,53 ± 0,04	0,47 ± 0,08
KNN 6	0,55 ± 0,05	0,56 ± 0,05	0,53 ± 0,05	0,6 ± 0,03	0,50 ± 0,07
KNN 7	0,55 ± 0,05	0,58 ± 0,04	0,6 ± 0,06	0,64 ± 0,03	0,52 ± 0,04
KNN 8	0,55 ± 0,05	0,58 ± 0,04	0,6 ± 0,06	0,64 ± 0,03	0,52 ± 0,04

Tabela 13 Valores de Acurácia treino, grupamento A, EEG 1 – 30 Hz.

(conclusão)

Modelos	Todos	Fre	Freq + D	Temp	Temp + D
KNN 9	0,6 ± 0,03	0,56 ± 0,04	0,58 ± 0,05	0,61 ± 0,04	0,63 ± 0,04
KNN 10	0,6 ± 0,03	0,56 ± 0,04	0,58 ± 0,05	0,63 ± 0,03	0,6 ± 0,04
KNN 11	0,56 ± 0,03	0,56 ± 0,04	0,6 ± 0,04	0,6 ± 0,02	0,61 ± 0,04
KNN 12	0,6 ± 0,03	0,58 ± 0,03	0,63 ± 0,04	0,64 ± 0,04	0,6 ± 0,04
KNN 13	0,55 ± 0,04	0,55 ± 0,04	0,53 ± 0,05	0,56 ± 0,04	0,53 ± 0,04
KNN 14	0,55 ± 0,04	0,55 ± 0,04	0,53 ± 0,05	0,56 ± 0,04	0,53 ± 0,04
KNN 15	0,61 ± 0,06	0,56 ± 0,04	0,55 ± 0,06	0,6 ± 0,04	0,64 ± 0,05
KNN 16	0,61 ± 0,06	0,56 ± 0,04	0,55 ± 0,06	0,6 ± 0,04	0,63 ± 0,05
KNN 17	0,58 ± 0,05	0,55 ± 0,04	0,56 ± 0,04	0,6 ± 0,04	0,64 ± 0,04
KNN 18	0,63 ± 0,03	0,56 ± 0,04	0,6 ± 0,03	0,63 ± 0,04	0,66 ± 0,04
KNN 19	0,55 ± 0,04	0,43 ± 0,10	0,53 ± 0,04	0,50 ± 0,11	0,56 ± 0,04
KNN 20	0,55 ± 0,04	0,43 ± 0,10	0,53 ± 0,04	0,50 ± 0,11	0,56 ± 0,04
KNN 21	0,58 ± 0,05	0,49 ± 0,08	0,56 ± 0,07	0,47 ± 0,10	0,58 ± 0,04
KNN 22	0,58 ± 0,05	0,49 ± 0,08	0,56 ± 0,07	0,47 ± 0,10	0,58 ± 0,04
KNN 23	0,61 ± 0,06	0,56 ± 0,13	0,58 ± 0,06	0,47 ± 0,10	0,6 ± 0,06
KNN 24	0,55 ± 0,06	0,56 ± 0,13	0,58 ± 0,05	0,47 ± 0,09	0,56 ± 0,05
KNN 25	0,55 ± 0,04	0,55 ± 0,04	0,53 ± 0,05	0,56 ± 0,04	0,53 ± 0,04
KNN 26	0,55 ± 0,04	0,55 ± 0,04	0,53 ± 0,05	0,56 ± 0,04	0,53 ± 0,04
KNN 27	0,61 ± 0,06	0,56 ± 0,04	0,55 ± 0,06	0,6 ± 0,04	0,64 ± 0,05
KNN 28	0,61 ± 0,06	0,56 ± 0,04	0,55 ± 0,06	0,6 ± 0,04	0,63 ± 0,05
KNN 29	0,58 ± 0,05	0,55 ± 0,04	0,56 ± 0,04	0,6 ± 0,04	0,64 ± 0,04
KNN 30	0,63 ± 0,03	0,56 ± 0,04	0,6 ± 0,03	0,63 ± 0,04	0,66 ± 0,04

Fre – Atributos na frequência; Freq + D – Atributos na frequência mais dados demográficos; Temp – Atributos no tempo; Temp + D – Atributos no tempo mais dados demográficos.

Avaliando os valores de F-macro, medida que penaliza os modelos gerados, Tabela 14, nota-se que quando as matrizes de entradas são compostas por atributos no tempo mais informações demográficas os modelos tendem a apresentar melhor desempenho. A faixa de F-macro obtida foi de 0,35 a 0,59. Índices menores que os valores de acurácia.

Tabela 14 Valores de F-macro treino, grupamento A, EEG 1 – 30 Hz.

(continua)

Modelos	Todos	Fre	Freq + D	Temp	Temp + D
SVM 1	0,44 ± 0,04	0,42 ± 0,04	0,45 ± 0,03	0,51 ± 0,07	0,51 ± 0,08
SVM 2	0,54 ± 0,05	0,50 ± 0,06	0,53 ± 0,05	0,53 ± 0,04	0,56 ± 0,04
SVM 3	0,53 ± 0,04	0,53 ± 0,06	0,53 ± 0,05	0,56 ± 0,04	0,55 ± 0,04
SVM 4	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,38 ± 0
SVM 5	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,38 ± 0
SVM 6	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,38 ± 0
SVM 7	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,38 ± 0

Tabela 14 Valores de F-macro treino, agrupamento A, EEG 1 – 30 Hz.

(continua)

Modelos	Todos	Fre	Freq + D	Temp	Temp + D
SVM 8	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,38 ± 0
SVM 9	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,38 ± 0
SVM 10	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,38 ± 0
SVM 11	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,38 ± 0
SVM 12	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,38 ± 0
SVM 13	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,38 ± 0
SVM 14	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,41 ± 0,02	0,38 ± 0,00
SVM 15	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,46 ± 0,06	0,43 ± 0,06
SVM 16	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,41 ± 0,03	0,49 ± 0,07
SVM 17	0,38 ± 0,03	0,41 ± 0,03	0,41 ± 0,05	0,38 ± 0	0,38 ± 0,01
SVM 18	0,38 ± 0,01	0,38 ± 0,00	0,38 ± 0,00	0,38 ± 0	0,38 ± 0
SVM 19	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,38 ± 0
SVM 20	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,38 ± 0
SVM 21	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,38 ± 0
SVM 22	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,38 ± 0
SVM 23	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,38 ± 0
SVM 24	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,38 ± 0
LR	0,54 ± 0,09	0,49 ± 0,05	0,52 ± 0,05	0,51 ± 0,04	0,52 ± 0,07
KNN 1	0,51 ± 0,07	0,56 ± 0,03	0,54 ± 0,05	0,54 ± 0,08	0,46 ± 0,04
KNN 2	0,51 ± 0,07	0,56 ± 0,03	0,54 ± 0,05	0,54 ± 0,08	0,46 ± 0,04
KNN 3	0,47 ± 0,05	0,45 ± 0,05	0,47 ± 0,07	0,47 ± 0,05	0,44 ± 0,06
KNN 4	0,47 ± 0,05	0,45 ± 0,05	0,47 ± 0,07	0,47 ± 0,05	0,44 ± 0,06
KNN 5	0,48 ± 0,06	0,45 ± 0,05	0,47 ± 0,07	0,41 ± 0,05	0,41 ± 0,05
KNN 6	0,45 ± 0,05	0,47 ± 0,06	0,47 ± 0,06	0,44 ± 0,04	0,42 ± 0,06
KNN 7	0,49 ± 0,06	0,51 ± 0,03	0,52 ± 0,05	0,59 ± 0,03	0,49 ± 0,04
KNN 8	0,49 ± 0,06	0,51 ± 0,03	0,52 ± 0,05	0,59 ± 0,03	0,49 ± 0,04
KNN 9	0,52 ± 0,03	0,49 ± 0,04	0,53 ± 0,05	0,50 ± 0,06	0,58 ± 0,06
KNN 10	0,53 ± 0,03	0,49 ± 0,04	0,53 ± 0,05	0,53 ± 0,05	0,54 ± 0,05
KNN 11	0,51 ± 0,04	0,52 ± 0,05	0,56 ± 0,05	0,51 ± 0,03	0,55 ± 0,07
KNN 12	0,51 ± 0,05	0,50 ± 0,05	0,55 ± 0,05	0,53 ± 0,05	0,54 ± 0,06
KNN 13	0,53 ± 0,05	0,51 ± 0,05	0,50 ± 0,06	0,52 ± 0,05	0,49 ± 0,03
KNN 14	0,53 ± 0,05	0,51 ± 0,05	0,50 ± 0,06	0,52 ± 0,05	0,49 ± 0,03
KNN 15	0,53 ± 0,06	0,51 ± 0,05	0,49 ± 0,05	0,50 ± 0,05	0,57 ± 0,06
KNN 16	0,53 ± 0,06	0,51 ± 0,05	0,49 ± 0,05	0,51 ± 0,05	0,56 ± 0,05
KNN 17	0,53 ± 0,05	0,52 ± 0,06	0,54 ± 0,05	0,49 ± 0,04	0,57 ± 0,06
KNN 18	0,55 ± 0,04	0,48 ± 0,06	0,53 ± 0,05	0,49 ± 0,05	0,56 ± 0,07
KNN 19	0,49 ± 0,05	0,36 ± 0,05	0,49 ± 0,04	0,35 ± 0,05	0,51 ± 0,05
KNN 20	0,49 ± 0,05	0,36 ± 0,05	0,49 ± 0,04	0,35 ± 0,05	0,51 ± 0,05
KNN 21	0,52 ± 0,07	0,35 ± 0,03	0,50 ± 0,08	0,38 ± 0,03	0,51 ± 0,07
KNN 22	0,52 ± 0,07	0,35 ± 0,03	0,50 ± 0,08	0,38 ± 0,03	0,51 ± 0,07

Tabela 14 Valores de F-macro treino, grupamento A, EEG 1 – 30 Hz.

(conclusão)

Modelos	Todos	Fre	Freq + D	Temp	Temp + D
KNN 23	0,51 ± 0,06	0,38 ± 0,07	0,53 ± 0,07	0,38 ± 0,07	0,54 ± 0,07
KNN 24	0,48 ± 0,07	0,38 ± 0,06	0,52 ± 0,07	0,38 ± 0,05	0,51 ± 0,06
KNN 25	0,53 ± 0,05	0,51 ± 0,05	0,50 ± 0,06	0,52 ± 0,05	0,49 ± 0,03
KNN 26	0,53 ± 0,05	0,51 ± 0,05	0,50 ± 0,06	0,52 ± 0,05	0,49 ± 0,03
KNN 27	0,53 ± 0,06	0,51 ± 0,05	0,49 ± 0,05	0,50 ± 0,05	0,57 ± 0,06
KNN 28	0,53 ± 0,06	0,51 ± 0,05	0,49 ± 0,05	0,51 ± 0,05	0,56 ± 0,05
KNN 29	0,53 ± 0,05	0,52 ± 0,06	0,54 ± 0,05	0,49 ± 0,04	0,57 ± 0,06
KNN 30	0,55 ± 0,04	0,48 ± 0,06	0,53 ± 0,05	0,49 ± 0,05	0,56 ± 0,07

Como já mencionado, a medida de desempenho F-macro induz a conclusões mais precisas a partir de seus valores e portanto foram escolhidos os dez melhores modelos baseados em resultados obtidos de F-macro, ou seja, aqueles com medidas mais próximas a 1. Optou-se por ter pelo menos uma representação de cada classificador utilizado, portanto, entre os dez melhores modelos tem-se aqueles criados a partir dos classificadores SVM, KNN e LR.

Na Tabela 15 estão representados os valores de acurácia dos dez melhores modelos considerando as cinco combinações de atributos de entradas. Há também a informação do valor médio obtido considerando todos os modelos por combinação de atributo bem como média geral de combinações de atributos considerando todos os modelos. A faixa de variação desses valores foi de 0,38 a 0,63. Nota-se que a acurácia máxima obtida foi menor quando comparada ao desempenho treino. O modelo SVM15 foi o que apresentou melhores acurácias em média. Por fim, pode-se dizer que o valor médio geral de acurácia para os modelos prognósticos testados foi de 0,56.

Tabela 15 Valores de Acurácia teste, grupamento A, EEG 1 – 30 Hz.

Modelos	Todos	Fre	Freq + D	Temp	Temp + D	Média
SVM 1	0,59 ± 0,05	0,56 ± 0,04	0,56 ± 0,03	0,59 ± 0,06	0,56 ± 0,06	0,58
SVM 2	0,5 ± 0,10	0,5 ± 0,05	0,5 ± 0,11	0,56 ± 0,05	0,53 ± 0,07	0,52
SVM 3	0,56 ± 0,05	0,53 ± 0,04	0,56 ± 0,05	0,5 ± 0,08	0,53 ± 0,06	0,54
SVM 15	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,59 ± 0,04	0,63 ± 0,03	0,62
LR	0,5 ± 0,05	0,53 ± 0,09	0,5 ± 0,07	0,53 ± 0,07	0,56 ± 0,07	0,53
KNN1	0,59 ± 0,05	0,63 ± 0,05	0,63 ± 0,03	0,56 ± 0,06	0,53 ± 0,07	0,59
KNN9	0,59 ± 0,05	0,53 ± 0,09	0,56 ± 0,07	0,59 ± 0,07	0,59 ± 0,08	0,58
KNN13	0,59 ± 0,10	0,59 ± 0,10	0,56 ± 0,09	0,47 ± 0,11	0,5 ± 0,06	0,54
KNN21	0,63 ± 0	0,38 ± 0,18	0,63 ± 0,13	0,63 ± 0,13	0,63 ± 0	0,58
KNN25	0,59 ± 0,10	0,59 ± 0,10	0,56 ± 0,09	0,47 ± 0,11	0,5 ± 0,06	0,54
Média	0,58	0,55	0,57	0,55	0,56	

Na Tabela 16, elaborada em padrões semelhantes à Tabela 15, estão representados os valores de sensibilidade dos dez melhores modelos, ou seja, os níveis de acerto para a classe ativo. A variação desses valores foi de 0,20 a 0,50, indicando que a maior dificuldade dos modelos está em acertar essa classe. Esse resultado pode ser justificado devido à quantidade de dados de EEG ativos ser menor que a outra classe, OC. O modelo KNN1 apresentou média de valores de sensibilidade maior. Pode-se dizer que o valor médio de sensibilidade para os modelos prognósticos testados foi de 0,38.

Tabela 16 Valores de Sensibilidade teste, grupamento A, EEG 1 – 30 Hz.

Modelos	Todos	Fre	Freq + D	Temp	Temp + D	Média
SVM 1	0,33 ± 0,24	0,25 ± 0,15	0,2 ± 0,19	0,43 ± 0,3	0,33 ± 0,13	0,31
SVM 2	0,25 ± 0,19	0,33 ± 0,12	0,3 ± 0,18	0,38 ± 0,11	0,36 ± 0,1	0,33
SVM 3	0,4 ± 0,08	0,38 ± 0,08	0,4 ± 0,07	0,36 ± 0,14	0,33 ± 0,08	0,37
SVM 15	0 ± 0	0 ± 0	0 ± 0	0,33 ± 0,26	0,5 ± 0,35	0,42
LR	0,38 ± 0,05	0,38 ± 0,08	0,38 ± 0,07	0,33 ± 0,12	0,38 ± 0,1	0,37
KNN1	0,44 ± 0,08	0,5 ± 0,05	0,5 ± 0,06	0,38 ± 0,09	0,36 ± 0,1	0,43
KNN9	0,46 ± 0,07	0,36 ± 0,13	0,38 ± 0,12	0,4 ± 0,16	0,45 ± 0,15	0,41
KNN13	0,46 ± 0,12	0,46 ± 0,13	0,43 ± 0,15	0,27 ± 0,16	0,33 ± 0,13	0,39
KNN21	0 ± 0	0,38 ± 0	0,38 ± 0	0,38 ± 0	0 ± 0	0,38
KNN25	0,46 ± 0,12	0,46 ± 0,13	0,43 ± 0,15	0,27 ± 0,16	0,33 ± 0,13	0,39
Média	0,40	0,39	0,38	0,35	0,38	

Os valores de especificidade por outro lado indicam os acertos que os modelos tiveram pra classe de óbito clínico. A Tabela 17 contém os valores de mediana ± desvio padrão das especificidades encontradas em cada um dos modelos, conforme as combinações dos atributos de entrada. É evidente que os valores obtidos são maiores que os de sensibilidade, com faixa de variação de 0,57 a 0,69. O valor médio de especificidade encontrado foi de 0,63, o que aponta que os modelos conseguem classificar melhor os registros com desfecho de OC. O modelo KNN1 foi o que apresentou melhores resultados nessa medida de desempenho. Com relação aos atributos de entrada, nota-se que aquela combinação com melhor valor de especificidade foi a que considerou todos os atributos de entrada.

Por fim, na Tabela 18, estão os resultados de F-macro. Os valores mínimo e máximo obtidos foram iguais a 0,27 e 0,58 respectivamente. Nota-se que o maior valor obtido indica que, apesar da dificuldade nessa classificação, o modelo KNN1 com os atributos frequência mais demografia, consegue de maneira razoável distinguir os prognósticos dos pacientes desse grupamento.

Tabela 17 Valores de Especificidade teste, grupamento A, EEG 1 – 30 Hz.

Modelos	Todos	Fre	Freq + D	Temp	Temp + D	Média
SVM 1	0,62 ± 0,03	0,61 ± 0,02	0,6 ± 0,02	0,64 ± 0,03	0,62 ± 0,04	0,62
SVM 2	0,58 ± 0,07	0,6 ± 0,06	0,59 ± 0,08	0,63 ± 0,09	0,62 ± 0,05	0,60
SVM 3	0,64 ± 0,05	0,63 ± 0,04	0,64 ± 0,04	0,61 ± 0,07	0,61 ± 0,04	0,62
SVM 15	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,62 ± 0,02	0,63 ± 0,02	0,62
LR	0,64 ± 0,04	0,63 ± 0,08	0,63 ± 0,05	0,61 ± 0,04	0,63 ± 0,06	0,63
KNN1	0,69 ± 0,05	0,67 ± 0,01	0,68 ± 0,06	0,63 ± 0,05	0,61 ± 0,06	0,65
KNN9	0,68 ± 0,05	0,62 ± 0,06	0,63 ± 0,06	0,63 ± 0,05	0,64 ± 0,05	0,64
KNN13	0,68 ± 0,09	0,68 ± 0,1	0,67 ± 0,1	0,57 ± 0,08	0,6 ± 0,06	0,64
KNN21	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63 ± 0	0,63
KNN25	0,68 ± 0,09	0,68 ± 0,1	0,67 ± 0,1	0,57 ± 0,08	0,6 ± 0,06	0,64
Média	0,65	0,64	0,63	0,61	0,62	

Tabela 18 Valores de F-macro teste, grupamento A, EEG 1 – 30 Hz.

Modelos	Todos	Fre	Freq + D	Temp	Temp + D	Média
SVM 1	0,43 ± 0,07	0,42 ± 0,06	0,4 ± 0,07	0,51 ± 0,06	0,47 ± 0,07	0,45
SVM 2	0,42 ± 0,12	0,47 ± 0,08	0,45 ± 0,12	0,51 ± 0,09	0,49 ± 0,08	0,47
SVM 3	0,52 ± 0,06	0,49 ± 0,06	0,52 ± 0,06	0,48 ± 0,1	0,47 ± 0,06	0,49
SVM 15	0,38 ± 0	0,38 ± 0	0,38 ± 0	0,43 ± 0,06	0,38 ± 0,1	0,39
LR	0,49 ± 0,05	0,51 ± 0,08	0,49 ± 0,06	0,47 ± 0,06	0,51 ± 0,08	0,49
KNN1	0,56 ± 0,06	0,56 ± 0,03	0,58 ± 0,05	0,49 ± 0,07	0,48 ± 0,07	0,54
KNN9	0,57 ± 0,06	0,49 ± 0,09	0,51 ± 0,09	0,48 ± 0,09	0,52 ± 0,1	0,51
KNN13	0,57 ± 0,1	0,57 ± 0,11	0,55 ± 0,12	0,42 ± 0,11	0,47 ± 0,09	0,52
KNN21	0,38 ± 0	0,27 ± 0,08	0,38 ± 0,06	0,38 ± 0,06	0,38 ± 0	0,36
KNN25	0,57 ± 0,1	0,57 ± 0,11	0,55 ± 0,12	0,42 ± 0,11	0,47 ± 0,09	0,52
Média	0,49	0,47	0,48	0,46	0,46	

6.3.2 Grupamento B: Ativo x Óbito por Morte Encefálica

Com o total de 51 registros EEG, sendo 29% pertencentes a classe de OME, esse grupamento, também desbalanceado, foi submetido a criações dos modelos prognósticos com parâmetros de entradas do classificadores semelhantes ao grupamento A. Sendo assim, 55 modelos foram criados e os valores de treino obtidos para a medida de desempenho acurácia estão mostrados na Tabela 19. Já na Tabela 20 tem-se os valores de F-macro obtidos no processo de treino dos modelos.

Observando a Tabela 19 percebe-se que os valores de acurácia encontrados variam de 0,58 a 0,79. Diferentemente do grupamento A, os valores aqui obtidos são maiores, indicando

que esses modelos tem desempenho de treino melhor em relação à acurácia. Nota-se que, no geral, os atributos de entrada não tiveram média de valores diferentes.

Tabela 19 Valores de Acurácia treino, grupamento B, EEG 1 – 30 Hz.

(continua)

Modelos	Todos	Fre	Freq + D	Temp	Temp + D
SVM 1	0,76 ± 0,04	0,75 ± 0,05	0,76 ± 0,05	0,73 ± 0,04	0,73 ± 0,03
SVM 2	0,73 ± 0,05	0,76 ± 0,05	0,76 ± 0,06	0,70 ± 0,04	0,73 ± 0,07
SVM 3	0,73 ± 0,06	0,76 ± 0,06	0,76 ± 0,07	0,64 ± 0,06	0,70 ± 0,07
SVM 4	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,70 ± 0
SVM 5	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,70 ± 0
SVM 6	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,70 ± 0
SVM 7	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,70 ± 0
SVM 8	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,70 ± 0
SVM 9	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,70 ± 0
SVM 10	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,70 ± 0
SVM 11	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,70 ± 0
SVM 12	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,70 ± 0
SVM 13	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,70 ± 0
SVM 14	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,70 ± 0,02	0,70 ± 0
SVM 15	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,67 ± 0,02	0,70 ± 0,02
SVM 16	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,73 ± 0,03	0,70 ± 0,02
SVM 17	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,79 ± 0,05	0,73 ± 0,03
SVM 18	0,70 ± 0,02	0,70 ± 0,01	0,70 ± 0,00	0,70 ± 0,01	0,70 ± 0
SVM 19	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,70 ± 0
SVM 20	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,70 ± 0
SVM 21	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,70 ± 0
SVM 22	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,70 ± 0
SVM 23	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,70 ± 0
SVM 24	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,70 ± 0	0,70 ± 0
LR	0,61 ± 0,06	0,61 ± 0,03	0,58 ± 0,08	0,58 ± 0,06	0,62 ± 0,11
KNN 1	0,64 ± 0,09	0,59 ± 0,08	0,58 ± 0,10	0,68 ± 0,09	0,67 ± 0,07
KNN 2	0,64 ± 0,09	0,59 ± 0,08	0,58 ± 0,10	0,68 ± 0,09	0,67 ± 0,07
KNN 3	0,73 ± 0,07	0,67 ± 0,07	0,67 ± 0,07	0,73 ± 0,04	0,70 ± 0,04
KNN 4	0,73 ± 0,07	0,67 ± 0,07	0,67 ± 0,07	0,73 ± 0,05	0,70 ± 0,04
KNN 5	0,73 ± 0,03	0,70 ± 0,02	0,70 ± 0,03	0,70 ± 0,02	0,70 ± 0,02
KNN 6	0,70 ± 0,05	0,67 ± 0,06	0,7 ± 0,06	0,73 ± 0,03	0,73 ± 0,02
KNN 7	0,65 ± 0,08	0,68 ± 0,08	0,64 ± 0,09	0,72 ± 0,05	0,68 ± 0,09
KNN 8	0,65 ± 0,08	0,68 ± 0,08	0,64 ± 0,09	0,72 ± 0,05	0,68 ± 0,09
KNN 9	0,76 ± 0,05	0,73 ± 0,06	0,76 ± 0,05	0,75 ± 0,07	0,73 ± 0,07
KNN 10	0,76 ± 0,05	0,73 ± 0,06	0,76 ± 0,06	0,73 ± 0,07	0,70 ± 0,06
KNN 11	0,70 ± 0,03	0,70 ± 0,01	0,70 ± 0,01	0,73 ± 0,02	0,73 ± 0,02
KNN 12	0,73 ± 0,05	0,73 ± 0,03	0,73 ± 0,03	0,76 ± 0,05	0,73 ± 0,06

Tabela 19 Valores de Acurácia treino, grupamento B, EEG 1 – 30 Hz.

(continua)

Modelos	Todos	Fre	Freq + D	Temp	Temp + D
KNN 13	0,76 ± 0,07	0,70 ± 0,06	0,79 ± 0,09	0,68 ± 0,05	0,68 ± 0,09
KNN 14	0,76 ± 0,07	0,70 ± 0,06	0,79 ± 0,09	0,68 ± 0,05	0,68 ± 0,09
KNN 15	0,73 ± 0,03	0,73 ± 0,03	0,73 ± 0,04	0,70 ± 0,05	0,73 ± 0,05
KNN 16	0,73 ± 0,03	0,73 ± 0,03	0,73 ± 0,04	0,73 ± 0,05	0,73 ± 0,04
KNN 17	0,70 ± 0,01	0,70 ± 0,01	0,70 ± 0,00	0,73 ± 0,02	0,70 ± 0,02
KNN 18	0,70 ± 0,02	0,73 ± 0,03	0,70 ± 0,03	0,73 ± 0,03	0,76 ± 0,04
KNN 19	0,64 ± 0,10	0,64 ± 0,19	0,64 ± 0,10	0,63 ± 0,19	0,7 ± 0,06
KNN 20	0,64 ± 0,10	0,64 ± 0,19	0,64 ± 0,10	0,63 ± 0,19	0,7 ± 0,06
KNN 21	0,73 ± 0,07	0,70 ± 0,13	0,73 ± 0,03	0,70 ± 0,16	0,72 ± 0,06
KNN 22	0,73 ± 0,07	0,70 ± 0,13	0,73 ± 0,03	0,70 ± 0,16	0,72 ± 0,06
KNN 23	0,70 ± 0,03	0,70 ± 0	0,73 ± 0,03	0,70 ± 0,04	0,70 ± 0,02
KNN 24	0,73 ± 0,03	0,70 ± 0,01	0,73 ± 0,05	0,70 ± 0,04	0,73 ± 0,02
KNN 25	0,76 ± 0,07	0,70 ± 0,06	0,79 ± 0,09	0,68 ± 0,05	0,68 ± 0,09
KNN 26	0,76 ± 0,07	0,70 ± 0,06	0,79 ± 0,09	0,68 ± 0,05	0,68 ± 0,09
KNN 27	0,73 ± 0,03	0,73 ± 0,03	0,73 ± 0,04	0,70 ± 0,05	0,73 ± 0,05
KNN 28	0,73 ± 0,03	0,73 ± 0,03	0,73 ± 0,04	0,73 ± 0,05	0,73 ± 0,04
KNN 29	0,70 ± 0,01	0,70 ± 0,01	0,70 ± 0,00	0,73 ± 0,02	0,70 ± 0,02
KNN 30	0,70 ± 0,02	0,73 ± 0,03	0,70 ± 0,03	0,73 ± 0,03	0,76 ± 0,04

Na Tabela 20 os valores de F-macro obtidos são claramente menores que os de acurácia. Esse resultado já era esperado uma vez que os dados são desbalanceados. A faixa de valores de F-macro obtida foi de 0,38 a 0,71. Quando observa-se o comportamento geral de F-macro considerando os atributos de entradas, percebe-se que os modelos gerados apenas com atributos no tempo tem valores maiores que o restante.

Tabela 20 Valores de F-macro treino, grupamento B, EEG 1 – 30 Hz.

(continua)

Modelos	Todos	Fre	Freq + D	Temp	Temp + D
SVM 1	0,56 ± 0,10	0,60 ± 0,12	0,60 ± 0,11	0,53 ± 0,08	0,53 ± 0,07
SVM 2	0,59 ± 0,09	0,61 ± 0,09	0,60 ± 0,10	0,53 ± 0,06	0,56 ± 0,09
SVM 3	0,60 ± 0,09	0,64 ± 0,11	0,62 ± 0,11	0,51 ± 0,08	0,49 ± 0,10
SVM 4	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0
SVM 5	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0
SVM 6	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0
SVM 7	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0
SVM 8	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0
SVM 9	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0
SVM 10	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0
SVM 11	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0

Tabela 20 Valores de F-macro treino, agrupamento B, EEG 1 – 30 Hz.

(continua)

Modelos	Todos	Fre	Freq + D	Temp	Temp + D
SVM 12	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0
SVM 13	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0
SVM 14	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0,06	0,41 ± 0
SVM 15	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,43 ± 0,04	0,41 ± 0,03
SVM 16	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,53 ± 0,09	0,46 ± 0,05
SVM 17	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,63 ± 0,14	0,48 ± 0,08
SVM 18	0,41 ± 0,06	0,41 ± 0,02	0,41 ± 0,00	0,41 ± 0,03	0,41 ± 0
SVM 19	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0
SVM 20	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0
SVM 21	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0
SVM 22	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0
SVM 23	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0
SVM 24	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0
LR	0,49 ± 0,06	0,55 ± 0,04	0,51 ± 0,07	0,52 ± 0,07	0,54 ± 0,13
KNN 1	0,53 ± 0,09	0,45 ± 0,10	0,47 ± 0,10	0,57 ± 0,10	0,50 ± 0,10
KNN 2	0,53 ± 0,09	0,45 ± 0,10	0,47 ± 0,10	0,57 ± 0,10	0,50 ± 0,10
KNN 3	0,52 ± 0,09	0,46 ± 0,08	0,46 ± 0,07	0,56 ± 0,08	0,48 ± 0,05
KNN 4	0,52 ± 0,09	0,46 ± 0,08	0,46 ± 0,07	0,56 ± 0,08	0,50 ± 0,06
KNN 5	0,48 ± 0,07	0,41 ± 0,04	0,41 ± 0,06	0,41 ± 0,06	0,41 ± 0,05
KNN 6	0,47 ± 0,11	0,43 ± 0,08	0,42 ± 0,09	0,49 ± 0,06	0,48 ± 0,05
KNN 7	0,55 ± 0,11	0,60 ± 0,10	0,57 ± 0,12	0,63 ± 0,07	0,50 ± 0,15
KNN 8	0,55 ± 0,11	0,60 ± 0,10	0,57 ± 0,12	0,63 ± 0,07	0,50 ± 0,15
KNN 9	0,62 ± 0,10	0,55 ± 0,11	0,57 ± 0,10	0,60 ± 0,11	0,57 ± 0,10
KNN 10	0,62 ± 0,11	0,55 ± 0,12	0,57 ± 0,11	0,62 ± 0,12	0,58 ± 0,09
KNN 11	0,41 ± 0,08	0,41 ± 0,04	0,41 ± 0,04	0,48 ± 0,06	0,48 ± 0,05
KNN 12	0,48 ± 0,11	0,48 ± 0,07	0,48 ± 0,07	0,66 ± 0,13	0,59 ± 0,11
KNN 13	0,67 ± 0,11	0,66 ± 0,08	0,71 ± 0,11	0,60 ± 0,06	0,51 ± 0,13
KNN 14	0,67 ± 0,11	0,66 ± 0,08	0,71 ± 0,11	0,60 ± 0,06	0,51 ± 0,13
KNN 15	0,55 ± 0,07	0,53 ± 0,06	0,53 ± 0,06	0,59 ± 0,10	0,55 ± 0,08
KNN 16	0,55 ± 0,07	0,53 ± 0,06	0,53 ± 0,06	0,58 ± 0,09	0,58 ± 0,09
KNN 17	0,41 ± 0,01	0,41 ± 0,01	0,41 ± 0,02	0,48 ± 0,06	0,41 ± 0,06
KNN 18	0,47 ± 0,05	0,48 ± 0,05	0,46 ± 0,05	0,56 ± 0,08	0,56 ± 0,09
KNN 19	0,56 ± 0,12	0,42 ± 0,14	0,55 ± 0,13	0,38 ± 0,09	0,62 ± 0,10
KNN 20	0,56 ± 0,12	0,42 ± 0,14	0,55 ± 0,13	0,38 ± 0,09	0,62 ± 0,10
KNN 21	0,56 ± 0,10	0,41 ± 0,08	0,55 ± 0,09	0,41 ± 0,08	0,54 ± 0,12
KNN 22	0,56 ± 0,10	0,41 ± 0,08	0,55 ± 0,09	0,41 ± 0,08	0,54 ± 0,12
KNN 23	0,41 ± 0,07	0,41 ± 0	0,48 ± 0,05	0,41 ± 0,02	0,41 ± 0,06
KNN 24	0,55 ± 0,09	0,41 ± 0,02	0,48 ± 0,11	0,41 ± 0,04	0,55 ± 0,08
KNN 25	0,67 ± 0,11	0,66 ± 0,08	0,71 ± 0,11	0,60 ± 0,06	0,51 ± 0,13
KNN 26	0,67 ± 0,11	0,66 ± 0,08	0,71 ± 0,11	0,60 ± 0,06	0,51 ± 0,13

Tabela 20 Valores de F-macro treino, grupamento B, EEG 1 – 30 Hz.

(conclusão)

Modelos	Todos	Fre	Freq + D	Temp	Temp + D
KNN 27	0,55 ± 0,07	0,53 ± 0,06	0,53 ± 0,06	0,59 ± 0,10	0,55 ± 0,08
KNN 28	0,55 ± 0,07	0,53 ± 0,06	0,53 ± 0,06	0,58 ± 0,09	0,58 ± 0,09
KNN 29	0,41 ± 0,01	0,41 ± 0,01	0,41 ± 0,02	0,48 ± 0,06	0,41 ± 0,06
KNN 30	0,47 ± 0,05	0,48 ± 0,05	0,46 ± 0,05	0,56 ± 0,08	0,56 ± 0,09

Analisando o desempenho de F-macro de todos os grupamentos, os melhores modelos foram definidos. Portanto, assim como para o grupamento A, dez modelos, incluindo aqueles com classificadores SVM, KNN e LR, foram escolhidos. É importante destacar que, por padrão, os modelos escolhidos foram os mesmos que na situação descrita no Capítulo 6. Os resultados de acurácia, sensibilidade, especificidade e F-macro estão mostrados na Tabela 21, Tabela 22, Tabela 23 e Tabela 24 respectivamente.

Os resultados de acurácia dos modelos testados, mostrados na Tabela 21, indicam que em média, a acurácia é de 0,72, com valor máximo obtido igual 0,82 e o menor valor igual a 0,53. Considerando os modelos gerados, nota-se que o modelo SVM1 apresentou maior média de acurácia em relação aos outros. Já em relação aos atributos de entrada, observa-se que a combinação de todos os atributos gera resultado médio melhor de acurácia.

Tabela 21 Valores de acurácia teste, grupamento B, EEG 1 – 30 Hz.

Modelos	Todos	Fre	Freq + D	Temp	Temp + D	Média
SVM 1	0,76 ± 0,08	0,82 ± 0,07	0,82 ± 0,07	0,76 ± 0,07	0,71 ± 0,08	0,78
SVM 2	0,82 ± 0,1	0,82 ± 0,11	0,76 ± 0,11	0,59 ± 0,11	0,65 ± 0,09	0,73
SVM 3	0,82 ± 0,09	0,82 ± 0,1	0,82 ± 0,1	0,59 ± 0,12	0,71 ± 0,09	0,75
SVM 15	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0,07	0,71 ± 0	0,71
LR	0,71 ± 0,17	0,71 ± 0,17	0,53 ± 0,15	0,59 ± 0,12	0,59 ± 0,14	0,62
KNN1	0,71 ± 0,1	0,71 ± 0,2	0,65 ± 0,1	0,59 ± 0,09	0,71 ± 0,12	0,67
KNN9	0,71 ± 0,04	0,71 ± 0,04	0,71 ± 0	0,71 ± 0,06	0,76 ± 0,07	0,72
KNN13	0,82 ± 0,19	0,76 ± 0,11	0,76 ± 0,11	0,65 ± 0,09	0,76 ± 0,19	0,75
KNN21	0,71 ± 0,21	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71
KNN25	0,82 ± 0,19	0,76 ± 0,11	0,76 ± 0,11	0,65 ± 0,09	0,76 ± 0,19	0,75
Média	0,76	0,75	0,72	0,65	0,71	

A análise dos valores de sensibilidade, mostrados na Tabela 22, permite inferir que a taxa de acerto da classe ativo é em média igual a 0,76. Os valores máximo e mínimo de sensibilidade obtidos nessa análise são iguais a 0,89 e 0,69 respectivamente. O modelo com melhor desempenho nessa análise foi o LR, com o valor máximo de sensibilidade obtido, considerando todos atributos de entrada. Contudo, uma análise global dos resultados obtidos por modelos, nota-se que KNN13 e KNN25 tem maiores médias de sensibilidade. Em relação

aos atributos de entrada, nota-se que a combinação de todos os atributos bem como a análise dos quantificadores na frequência, apresentaram médias maiores de sensibilidade.

Tabela 22 Valores de sensibilidade teste, grupamento B, EEG 1 – 30 Hz.

Modelos	Todos	Fre	Freq + D	Temp	Temp + D	Média
SVM 1	0,75 ± 0,04	0,8 ± 0,04	0,8 ± 0,03	0,75 ± 0,04	0,77 ± 0,04	0,77
SVM 2	0,8 ± 0,08	0,8 ± 0,09	0,79 ± 0,08	0,69 ± 0,07	0,75 ± 0,05	0,77
SVM 3	0,8 ± 0,09	0,8 ± 0,09	0,8 ± 0,09	0,69 ± 0,08	0,77 ± 0,06	0,77
SVM 15	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0,02	0,71 ± 0	0,71
LR	0,89 ± 0,16	0,78 ± 0,1	0,7 ± 0,14	0,69 ± 0,11	0,73 ± 0,1	0,76
KNN1	0,77 ± 0,07	0,8 ± 0,13	0,77 ± 0,07	0,73 ± 0,06	0,73 ± 0,11	0,76
KNN9	0,71 ± 0,03	0,73 ± 0,02	0,71 ± 0,01	0,73 ± 0,04	0,75 ± 0,05	0,73
KNN13	0,85 ± 0,09	0,83 ± 0,07	0,82 ± 0,04	0,75 ± 0,06	0,79 ± 0,13	0,81
KNN21	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71
KNN25	0,85 ± 0,09	0,83 ± 0,07	0,82 ± 0,04	0,75 ± 0,06	0,79 ± 0,13	0,81
Média	0,78	0,78	0,76	0,72	0,75	

Já os acertos obtidos para a classe OME, mostrados a partir dos valores de especificidade, na Tabela 23, tem representação média igual a 0,60, com variação entre 0,25 e 1,0. O cálculo da especificidade para os modelos SVM15 e KNN21 não foi possível e portanto não foram representados na Tabela 23. Nota-se que, em termos de modelo, o SVM1 apresentou maior valor médio de especificidade em relação aos outros. Considerando os atributos de entrada, os modelos utilizando dados quantitativos na frequência apresentaram melhores resultados em média.

Tabela 23 Valores de especificidade teste, grupamento B, EEG 1 – 30 Hz.

Modelos	Todos	Fre	Freq + D	Temp	Temp + D	Média
SVM 1	1 ± 0,42	1 ± 0,3	1 ± 0,3	0,67 ± 0,3	0,75 ± 0,29	0,88
SVM 2	1 ± 0,35	1 ± 0,3	0,67 ± 0,25	0,25 ± 0,27	0,4 ± 0,22	0,66
SVM 3	0,8 ± 0,22	1 ± 0,25	1 ± 0,25	0,25 ± 0,22	0,5 ± 0,2	0,71
LR	0,5 ± 0,2	0,5 ± 0,23	0,29 ± 0,19	0,25 ± 0,16	0,33 ± 0,21	0,37
KNN1	0,5 ± 0,17	0,5 ± 0,32	0,43 ± 0,15	0,33 ± 0,14	0,5 ± 0,37	0,45
KNN9	0,5 ± 0,5	1 ± 0,35	0,5 ± 0	0,5 ± 0,35	0,83 ± 0,51	0,67
KNN13	0,75 ± 0,33	0,6 ± 0,17	0,67 ± 0,24	0,4 ± 0,18	0,67 ± 0,4	0,62
KNN25	0,75 ± 0,33	0,6 ± 0,17	0,67 ± 0,24	0,4 ± 0,18	0,67 ± 0,4	0,62
Média	0,68	0,78	0,65	0,36	0,58	

Para finalizar as análises do grupamento B, a Tabela 24 contém os valores de F-macro obtidos pelos modelos testados. Nota-se que os valores observados variam entre 0,41 e 0,77, com média igual 0,58. Considerando os dez modelos testados, KNN13 e KNN25 apresentaram

maior média de F-macro. Já em relação aos tipos de atributos de entrada, nota-se que os quantificadores na frequência novamente apresentaram resultados médios maiores.

Tabela 24 Valores de F-macro teste, grupamento B, EEG 1 – 30 Hz.

Modelos	Todos	Fre	Freq + D	Temp	Temp + D	Média
SVM 1	0,6 ± 0,11	0,73 ± 0,11	0,73 ± 0,09	0,6 ± 0,09	0,62 ± 0,13	0,65
SVM 2	0,73 ± 0,15	0,73 ± 0,17	0,67 ± 0,16	0,47 ± 0,14	0,58 ± 0,1	0,64
SVM 3	0,73 ± 0,13	0,73 ± 0,15	0,73 ± 0,16	0,47 ± 0,14	0,62 ± 0,12	0,66
SVM 15	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0,05	0,41 ± 0	0,41
LR	0,69 ± 0,19	0,62 ± 0,16	0,48 ± 0,17	0,47 ± 0,12	0,53 ± 0,16	0,56
KNN1	0,62 ± 0,11	0,62 ± 0,19	0,61 ± 0,12	0,53 ± 0,1	0,55 ± 0,19	0,59
KNN9	0,41 ± 0,11	0,55 ± 0,1	0,41 ± 0,07	0,55 ± 0,13	0,6 ± 0,16	0,50
KNN13	0,77 ± 0,18	0,72 ± 0,12	0,67 ± 0,11	0,58 ± 0,1	0,67 ± 0,24	0,68
KNN21	0,41 ± 0,09	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41 ± 0	0,41
KNN25	0,77 ± 0,18	0,72 ± 0,12	0,67 ± 0,11	0,58 ± 0,1	0,67 ± 0,24	0,68
Média	0,62	0,62	0,58	0,51	0,57	

6.3.3 Grupamento C: Óbito Clínico x Óbito por Morte Encefálica

O grupamento C é composto por 76 registros EEG, sendo 61 deles com desfecho de OC e o restante, OME. Portanto, 80% dos dados pertencem à classe 1 (OC). Essa consideração deve ser relevante nas análises dos resultados. Inicialmente, na Tabela 25 são representados os valores de acurácia de treino, obtidos para os 55 modelos gerados. Ressalta-se que são os mesmos modelos dispostos nos grupamentos A e B.

Na Tabela 25 pode-se contatar que os valores de acurácia de treino variam entre 0,58 e 0,80. Destaca-se que, em média, os valores obtidos considerando os atributos de entrada apenas no tempo são maiores. Já em relação aos modelos nota-se que o modelo obtido pelo classificador LR apresentou baixo desempenho de acurácia.

Tabela 25 Valores de acurácia treino, grupamento C, EEG 1 – 30 Hz.

(continua)

Modelos	Todos	Fre	Freq + D	Temp	Temp + D
SVM 1	0,80 ± 0,02	0,78 ± 0,02	0,78 ± 0,02	0,80 ± 0,02	0,80 ± 0,02
SVM 2	0,78 ± 0,02	0,76 ± 0,03	0,76 ± 0,03	0,78 ± 0,03	0,74 ± 0,06
SVM 3	0,78 ± 0,03	0,74 ± 0,04	0,74 ± 0,03	0,74 ± 0,04	0,72 ± 0,05
SVM 4	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0
SVM 5	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0
SVM 6	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0
SVM 7	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0

Tabela 25 Valores de acurácia treino, agrupamento C, EEG 1 – 30 Hz.

(continua)

Modelos	Todos	Fre	Freq + D	Temp	Temp + D
SVM 8	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0
SVM 9	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0
SVM 10	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0
SVM 11	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0
SVM 12	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0
SVM 13	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0
SVM 14	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0,00	0,80 ± 0
SVM 15	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0,00
SVM 16	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0
SVM 17	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0,00
SVM 18	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0
SVM 19	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0
SVM 20	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0
SVM 21	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0
SVM 22	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0
SVM 23	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0
SVM 24	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0
LR	0,64 ± 0,06	0,58 ± 0,06	0,64 ± 0,08	0,72 ± 0,04	0,68 ± 0,05
KNN 1	0,72 ± 0,06	0,68 ± 0,04	0,64 ± 0,05	0,76 ± 0,05	0,70 ± 0,03
KNN 2	0,72 ± 0,06	0,68 ± 0,04	0,64 ± 0,05	0,76 ± 0,05	0,70 ± 0,03
KNN 3	0,80 ± 0,01	0,78 ± 0,03	0,78 ± 0,03	0,80 ± 0,02	0,80 ± 0,02
KNN 4	0,80 ± 0,01	0,78 ± 0,03	0,78 ± 0,03	0,80 ± 0,02	0,80 ± 0,02
KNN 5	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0
KNN 6	0,80 ± 0,01	0,80 ± 0,01	0,80 ± 0,00	0,80 ± 0,00	0,80 ± 0,00
KNN 7	0,70 ± 0,05	0,68 ± 0,05	0,68 ± 0,02	0,74 ± 0,06	0,68 ± 0,04
KNN 8	0,70 ± 0,05	0,68 ± 0,05	0,68 ± 0,02	0,74 ± 0,06	0,68 ± 0,04
KNN 9	0,78 ± 0,01	0,76 ± 0,02	0,78 ± 0,02	0,78 ± 0,02	0,78 ± 0,01
KNN 10	0,78 ± 0,01	0,76 ± 0,02	0,78 ± 0,02	0,76 ± 0,03	0,78 ± 0,02
KNN 11	0,80 ± 0,00	0,80 ± 0,00	0,80 ± 0,00	0,80 ± 0,00	0,80 ± 0
KNN 12	0,80 ± 0,01	0,80 ± 0,01	0,80 ± 0,01	0,78 ± 0,02	0,80 ± 0,00
KNN 13	0,70 ± 0,03	0,70 ± 0,05	0,66 ± 0,05	0,78 ± 0,04	0,68 ± 0,02
KNN 14	0,70 ± 0,03	0,70 ± 0,05	0,66 ± 0,05	0,78 ± 0,04	0,68 ± 0,02
KNN 15	0,78 ± 0,01	0,78 ± 0,04	0,76 ± 0,02	0,80 ± 0,02	0,80 ± 0,01
KNN 16	0,78 ± 0,01	0,78 ± 0,04	0,76 ± 0,02	0,80 ± 0,02	0,80 ± 0,01
KNN 17	0,80 ± 0,00	0,80 ± 0,01	0,80 ± 0,00	0,80 ± 0,00	0,80 ± 0
KNN 18	0,80 ± 0,00	0,80 ± 0,01	0,80 ± 0,00	0,80 ± 0,00	0,80 ± 0,00
KNN 19	0,70 ± 0,08	0,80 ± 0,01	0,68 ± 0,06	0,80 ± 0,14	0,68 ± 0,13
KNN 20	0,70 ± 0,08	0,80 ± 0,01	0,68 ± 0,06	0,80 ± 0,14	0,68 ± 0,13
KNN 21	0,78 ± 0,03	0,80 ± 0,01	0,78 ± 0,02	0,80 ± 0,02	0,80 ± 0,01
KNN 22	0,78 ± 0,03	0,80 ± 0,01	0,78 ± 0,02	0,80 ± 0,02	0,80 ± 0,01

Tabela 25 Valores de acurácia treino, grupamento C, EEG 1 – 30 Hz.

(conclusão)

Modelos	Todos	Fre	Freq + D	Temp	Temp + D
KNN 23	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0	0,80 ± 0
KNN 24	0,80 ± 0	0,80 ± 0	0,80 ± 0,00	0,80 ± 0	0,80 ± 0,00
KNN 25	0,70 ± 0,03	0,70 ± 0,05	0,66 ± 0,05	0,78 ± 0,04	0,68 ± 0,02
KNN 26	0,70 ± 0,03	0,70 ± 0,05	0,66 ± 0,05	0,78 ± 0,04	0,68 ± 0,02
KNN 27	0,78 ± 0,01	0,78 ± 0,04	0,76 ± 0,02	0,80 ± 0,02	0,80 ± 0,01
KNN 28	0,78 ± 0,01	0,78 ± 0,04	0,76 ± 0,02	0,80 ± 0,02	0,80 ± 0,01
KNN 29	0,80 ± 0,00	0,80 ± 0,01	0,80 ± 0,00	0,80 ± 0,00	0,80 ± 0
KNN 30	0,80 ± 0,00	0,80 ± 0,01	0,80 ± 0,00	0,80 ± 0,00	0,80 ± 0,00

Já considerando a Tabela 26, nota-se que os valores obtidos são menores comparados aos de acurácia, variando entre 0,42 e 0,57. Assim como para a acurácia de treino, F-macro apresentou maior média de desempenho quando analisados atributos de entrada no tempo.

Tabela 26 Valores de F-macro treino, grupamento C, EEG 1 – 30 Hz.

(continua)

Modelos	Todos	Fre	Freq + D	Temp	Temp + D
SVM 1	0,44 ± 0,05	0,43 ± 0,03	0,43 ± 0,01	0,51 ± 0,05	0,51 ± 0,04
SVM 2	0,52 ± 0,05	0,46 ± 0,06	0,46 ± 0,04	0,50 ± 0,06	0,50 ± 0,06
SVM 3	0,51 ± 0,05	0,48 ± 0,06	0,45 ± 0,03	0,52 ± 0,07	0,47 ± 0,05
SVM 4	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0
SVM 5	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0
SVM 6	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0
SVM 7	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0
SVM 8	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0
SVM 9	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0
SVM 10	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0
SVM 11	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0
SVM 12	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0
SVM 13	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0
SVM 14	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0,00	0,44 ± 0
SVM 15	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0,00
SVM 16	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0
SVM 17	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0,00
SVM 18	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0
SVM 19	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0
SVM 20	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0
SVM 21	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0
SVM 22	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0
SVM 23	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0

Tabela 26 Valores de F-macro treino, grupamento C, EEG 1 – 30 Hz.

(continua)

Modelos	Todos	Fre	Freq + D	Temp	Temp + D
SVM 24	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0
LR	0,50 ± 0,06	0,46 ± 0,07	0,51 ± 0,10	0,52 ± 0,06	0,52 ± 0,06
KNN 1	0,47 ± 0,05	0,48 ± 0,06	0,42 ± 0,04	0,54 ± 0,06	0,48 ± 0,04
KNN 2	0,47 ± 0,05	0,48 ± 0,06	0,42 ± 0,04	0,54 ± 0,06	0,48 ± 0,04
KNN 3	0,50 ± 0,05	0,44 ± 0,04	0,44 ± 0,04	0,48 ± 0,03	0,48 ± 0,03
KNN 4	0,50 ± 0,05	0,44 ± 0,04	0,44 ± 0,04	0,48 ± 0,03	0,49 ± 0,03
KNN 5	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0
KNN 6	0,44 ± 0,01	0,44 ± 0,02	0,44 ± 0,00	0,44 ± 0,03	0,44 ± 0,01
KNN 7	0,45 ± 0,04	0,46 ± 0,05	0,42 ± 0,03	0,55 ± 0,08	0,45 ± 0,05
KNN 8	0,45 ± 0,04	0,46 ± 0,05	0,42 ± 0,03	0,55 ± 0,08	0,45 ± 0,05
KNN 9	0,44 ± 0,03	0,44 ± 0,04	0,43 ± 0,05	0,43 ± 0,06	0,44 ± 0,01
KNN 10	0,44 ± 0,03	0,44 ± 0,04	0,44 ± 0,05	0,43 ± 0,06	0,43 ± 0,02
KNN 11	0,44 ± 0,02	0,44 ± 0,00	0,44 ± 0,01	0,44 ± 0,00	0,44 ± 0
KNN 12	0,44 ± 0,02	0,44 ± 0,00	0,44 ± 0,02	0,43 ± 0,04	0,44 ± 0,00
KNN 13	0,50 ± 0,04	0,57 ± 0,05	0,49 ± 0,05	0,57 ± 0,08	0,45 ± 0,02
KNN 14	0,50 ± 0,04	0,57 ± 0,05	0,49 ± 0,05	0,57 ± 0,08	0,45 ± 0,02
KNN 15	0,48 ± 0,03	0,44 ± 0,04	0,43 ± 0,03	0,44 ± 0,02	0,44 ± 0,00
KNN 16	0,48 ± 0,03	0,44 ± 0,04	0,43 ± 0,03	0,44 ± 0,02	0,44 ± 0,00
KNN 17	0,44 ± 0,01	0,44 ± 0,02	0,44 ± 0,00	0,44 ± 0,01	0,44 ± 0
KNN 18	0,44 ± 0,02	0,44 ± 0,05	0,44 ± 0,00	0,44 ± 0,02	0,44 ± 0,01
KNN 19	0,44 ± 0,05	0,44 ± 0,02	0,42 ± 0,04	0,44 ± 0,03	0,43 ± 0,06
KNN 20	0,44 ± 0,05	0,44 ± 0,02	0,42 ± 0,04	0,44 ± 0,03	0,43 ± 0,06
KNN 21	0,43 ± 0,00	0,44 ± 0,00	0,43 ± 0,00	0,44 ± 0,00	0,44 ± 0,00
KNN 22	0,43 ± 0,00	0,44 ± 0,00	0,43 ± 0,00	0,44 ± 0,00	0,44 ± 0,00
KNN 23	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0
KNN 24	0,44 ± 0	0,44 ± 0	0,44 ± 0,00	0,44 ± 0	0,44 ± 0,00
KNN 25	0,50 ± 0,04	0,57 ± 0,05	0,49 ± 0,05	0,57 ± 0,08	0,45 ± 0,02
KNN 26	0,50 ± 0,04	0,57 ± 0,05	0,49 ± 0,05	0,57 ± 0,08	0,45 ± 0,02
KNN 27	0,48 ± 0,03	0,44 ± 0,04	0,43 ± 0,03	0,44 ± 0,02	0,44 ± 0,00
KNN 28	0,48 ± 0,03	0,44 ± 0,04	0,43 ± 0,03	0,44 ± 0,02	0,44 ± 0,00
KNN 29	0,44 ± 0,01	0,44 ± 0,02	0,44 ± 0,00	0,44 ± 0,01	0,44 ± 0
KNN 30	0,44 ± 0,02	0,44 ± 0,05	0,44 ± 0,00	0,44 ± 0,02	0,44 ± 0,01

Assim como nas análises dos grupamento anteriores, os dez melhores modelos foram submetidos aos testes e as medidas de desempenho acurácia, sensibilidade, especificidade e F-macro foram calculadas. Na Tabela 27 estão os valores de acurácia obtidos para os modelos prognósticos do grupamento C. Com valor médio de 0,74, as acurácias encontradas variaram entre 0,48 e 0,80. Considerando os modelos testados, três deles tiveram média de valores de acurácia igual a 0,8: SVM15, KNN9 e KNN21. Em relação aos atributos considerados nas

análises, nota-se que quando são considerados apenas os dados no domínio do tempo, o valor de acurácia médio é maior.

Tabela 27 Valores de acurácia teste, grupamento C, EEG 1 – 30 Hz.

Modelos	Todos	Fre	Freq + D	Temp	Temp + D	Média
SVM 1	$0,8 \pm 0,03$	$0,8 \pm 0,02$	$0,8 \pm 0$	$0,76 \pm 0,05$	$0,76 \pm 0,03$	0,78
SVM 2	$0,8 \pm 0,03$	$0,76 \pm 0,03$	$0,76 \pm 0,03$	$0,76 \pm 0,09$	$0,68 \pm 0,06$	0,75
SVM 3	$0,8 \pm 0,06$	$0,76 \pm 0,03$	$0,8 \pm 0,03$	$0,68 \pm 0,08$	$0,68 \pm 0,15$	0,74
SVM 15	$0,8 \pm 0$	$0,8 \pm 0$	$0,8 \pm 0$	$0,8 \pm 0$	$0,8 \pm 0$	0,80
LR	$0,56 \pm 0,1$	$0,52 \pm 0,22$	$0,48 \pm 0,1$	$0,72 \pm 0,08$	$0,68 \pm 0,06$	0,59
KNN1	$0,68 \pm 0,09$	$0,64 \pm 0,13$	$0,64 \pm 0,12$	$0,8 \pm 0,08$	$0,68 \pm 0,06$	0,69
KNN9	$0,8 \pm 0$	$0,8 \pm 0$	$0,8 \pm 0$	$0,8 \pm 0,02$	$0,8 \pm 0$	0,80
KNN13	$0,72 \pm 0,12$	$0,64 \pm 0,11$	$0,68 \pm 0,1$	$0,76 \pm 0,06$	$0,72 \pm 0,09$	0,70
KNN21	$0,8 \pm 0$	$0,8 \pm 0$	$0,8 \pm 0$	$0,8 \pm 0$	$0,8 \pm 0$	0,80
KNN25	$0,72 \pm 0,12$	$0,64 \pm 0,11$	$0,68 \pm 0,1$	$0,76 \pm 0,06$	$0,72 \pm 0,09$	0,70
Média	0,75	0,72	0,72	0,76	0,73	

Em termos de sensibilidade, Tabela 28, e especificidade, Tabela 29, nota-se que o primeiro apresenta valores em média iguais a 0,80 e o segundo, iguais a 0,19. Nota-se que em ambos, os quantificadores no tempo produziram resultados médios melhores. Já em relação aos modelos, nota-se que para a especificidade, quatro dos dez modelos propostos, não apresentaram valores de especificidade.

Por fim, em relação aos valores de F-macro, apresentados na Tabela 30, nota-se que a variação de índices obtidos está entre 0,38 e 0,58, com média igual a 0,47. O modelo LR nesse caso apresentou melhor média de valores. Por outro lado, considerando os atributos de entrada notou-se que, em concordância com os resultados encontrados para acurácia, sensibilidade e especificidade, os atributos temporais apresentaram resultados melhores de F-macro.

Tabela 28 Valores de sensibilidade teste, grupamento C, EEG 1 – 30 Hz.

Modelos	Todos	Fre	Freq + D	Temp	Temp + D	Média
SVM 1	$0,8 \pm 0,02$	$0,8 \pm 0$	$0,8 \pm 0$	$0,79 \pm 0,02$	$0,79 \pm 0,02$	0,80
SVM 2	$0,8 \pm 0,02$	$0,79 \pm 0,02$	$0,79 \pm 0,01$	$0,83 \pm 0,03$	$0,8 \pm 0,02$	0,80
SVM 3	$0,8 \pm 0,02$	$0,79 \pm 0,02$	$0,8 \pm 0,01$	$0,79 \pm 0,02$	$0,79 \pm 0,07$	0,79
SVM 15	$0,8 \pm 0$	$0,8 \pm 0$	$0,8 \pm 0$	$0,8 \pm 0$	$0,8 \pm 0$	0,80
LR	$0,77 \pm 0,09$	$0,79 \pm 0,11$	$0,73 \pm 0,1$	$0,83 \pm 0,04$	$0,81 \pm 0,05$	0,79
KNN1	$0,8 \pm 0,05$	$0,79 \pm 0,05$	$0,78 \pm 0,06$	$0,83 \pm 0,04$	$0,8 \pm 0,04$	0,80
KNN9	$0,8 \pm 0$	$0,8 \pm 0$	$0,8 \pm 0$	$0,8 \pm 0,02$	$0,8 \pm 0$	0,80
KNN13	$0,81 \pm 0,04$	$0,82 \pm 0,03$	$0,83 \pm 0,04$	$0,81 \pm 0,03$	$0,78 \pm 0,05$	0,81
KNN21	$0,8 \pm 0$	$0,8 \pm 0$	$0,8 \pm 0$	$0,8 \pm 0$	$0,8 \pm 0$	0,80
KNN25	$0,81 \pm 0,04$	$0,82 \pm 0,03$	$0,83 \pm 0,04$	$0,81 \pm 0,03$	$0,78 \pm 0,05$	0,81
Média	0,80	0,80	0,80	0,81	0,80	

Tabela 29 Valores de especificidade teste, grupamento C, EEG 1 – 30 Hz.

Modelos	Todos	Fre	Freq + D	Temp	Temp + D	Média
SVM 2	0,25 ± 0,5	0 ± 0,25	0 ± 0	0,33 ± 0,36	0,2 ± 0,14	0,16
SVM 3	0,25 ± 0,5	0 ± 0,29	0 ± 0,35	0,17 ± 0,2	0 ± 0,19	0,08
LR	0,17 ± 0,13	0,18 ± 0,25	0,1 ± 0,15	0,33 ± 0,18	0,25 ± 0,16	0,21
KNN1	0,2 ± 0,23	0,17 ± 0,3	0,14 ± 0,31	0,5 ± 0,33	0,2 ± 0,21	0,24
KNN13	0,25 ± 0,17	0,25 ± 0,09	0,29 ± 0,14	0,29 ± 0,28	0,14 ± 0,23	0,24
KNN25	0,25 ± 0,17	0,25 ± 0,09	0,29 ± 0,14	0,29 ± 0,28	0,14 ± 0,23	0,24
Média	0,27	0,12	0,14	0,27	0,13	

Tabela 30 Valores de F-macro teste, grupamento C, EEG 1 – 30 Hz.

Modelos	Todos	Fre	Freq + D	Temp	Temp + D	Média
SVM 1	0,44 ± 0,11	0,44 ± 0,01	0,44 ± 0	0,43 ± 0,08	0,43 ± 0,08	0,44
SVM 2	0,44 ± 0,11	0,43 ± 0,08	0,43 ± 0,01	0,58 ± 0,07	0,5 ± 0,06	0,48
SVM 3	0,44 ± 0,11	0,43 ± 0,08	0,44 ± 0,07	0,48 ± 0,08	0,43 ± 0,1	0,45
SVM 15	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44
LR	0,43 ± 0,13	0,45 ± 0,22	0,38 ± 0,13	0,58 ± 0,1	0,53 ± 0,1	0,47
KNN1	0,5 ± 0,13	0,48 ± 0,15	0,45 ± 0,16	0,58 ± 0,12	0,5 ± 0,11	0,50
KNN9	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0,09	0,44 ± 0	0,44
KNN13	0,53 ± 0,09	0,53 ± 0,07	0,56 ± 0,09	0,53 ± 0,12	0,45 ± 0,13	0,52
KNN21	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44
KNN25	0,53 ± 0,09	0,53 ± 0,07	0,56 ± 0,09	0,53 ± 0,12	0,45 ± 0,13	0,52
Média	0,46	0,46	0,46	0,50	0,46	

6.4 Discussão

A quantidade de dados utilizada na presente análise difere da maioria dos estudos mencionados no Capítulo 4, uma vez que apenas três estudos, (AMORIM et al., 2019; ZUBLER et al., 2015, 2017b) utilizaram uma quantidade de pacientes menor que 100. Essa consideração é importante uma vez que, em casos de modelos classificatórios que dividem dados em treino e teste, a quantidade de contribuições é fator determinável para garantir o sucesso da aprendizagem do(s) modelo(s).

Observando os quantificadores de EEG utilizados no presente estudo e comparando-os com os quantificadores descritos nos estudos apresentados no Capítulo 4, nota-se que, em relação à quantificação no domínio da frequência e do tempo-frequência o presente estudo se equipara aos mencionados na literatura. Contudo, o que ocorre na literatura também é a consideração de especialistas em EEG na quantificação do sinal EEG, associando padrões

anormais com os exames dos pacientes. Esse tipo de análise não foi considerada no presente estudo.

Se faz necessário discutir as duas principais abordagens dessa pesquisa: Em relação ao classificador, qual apresentou melhores desempenhos no prognóstico do paciente comatoso? E em relação aos atributos de entrada, existe alguma combinação que resulta em resultados melhores de medidas de desempenho?

De forma abrangente, todos os dados de teste obtidos nos três grupamentos, para as quatro medidas de desempenho foram considerados na montagem do gráfico da Figura 5. Percebe-se que, em termos de mediana, o modelo KNN9 foi o que apresentou maior valor. Analisando as informações dos quartis, nota-se que o pior modelo foi LR, sendo estatisticamente comprovado que apresentou comportamento diferente dos demais modelos por meio do teste de Mann-Whitney com valor- $p < 0,05$. O modelo que alcançou maiores valores das medidas de desempenho adotadas nesse estudo foi SVM1. Consta-se que então os modelos SVM1 e KNN9 apresentaram melhores desempenhos de teste. Comparando esses resultados à literatura, nota-se que no geral os estudos publicados não mencionam comparação entre tipos de classificadores utilizados nos modelos. O que de fato é evidenciado pela literatura é que no geral modelos combinados com mais de uma técnica de aprendizado de máquina tendem a ser mais eficazes para o prognóstico do paciente comatoso a partir de dados extraídos do sinal EEG.




Figura 5 Valores obtidos nas medidas de desempenho conforme o tipo de modelo testado.

Considerando agora as combinações de atributos, independentemente dos modelos utilizados, nota-se pela Figura 6 que quando são considerados apenas atributos no domínio do

tempo (assimetria e curtose) os modelos tendem a apresentar os piores desempenhos médios ($\text{valor-p} < 0,05$). Quando são considerados apenas os atributos no domínio da frequência associados aos dados demográficos, a mediana de valores de desempenho é próxima à obtida quando considerados todos os atributos juntos. Por meio dos comportamentos dos gráficos é notório que a combinação de todos os atributos ocasionou melhores resultados de desempenho dos modelos.




Figura 6 Comportamento estatístico dos modelos considerando as combinações de atributos.

Capítulo 7

ANÁLISE RITMOS CLÍNICOS E RITMOS RÁPIDOS

Nesse capítulo estão os resultados obtidos nas análises de EEG considerando ritmos clínicos de delta a supergama (1 a 100 Hz).

7.1 Introdução

Diferentemente do capítulo de análise dos ritmos clínicos, no presente capítulo serão consideradas informações do sinal EEG em frequências maiores que 30 Hz, ou seja, ritmos grama (30 – 80 Hz) e supergama (até 100 Hz). A disposição dos itens desse capítulo é:

- Metodologia: Para esclarecer os materiais e métodos abordados para essa análise, informando como os dados do sinal EEG foram manuseados em alta frequência.
- Resultados: Assim como no Capítulo 6, os resultados serão apresentados em três tópicos, sendo cada um referente a um grupamento de estudo.
- Discussão: Os resultados obtidos serão discutidos e confrontados com a literatura.

7.2 Metodologia

A metodologia aqui descrita, resume o que foi apresentado no Capítulo 5, de forma a enfatizar como foi realizado o procedimento de materiais e métodos considerando os sinais EEG no domínio da frequência nas faixas de 1 a 100 Hz.

7.2.1 Sinais EEG: Grupos do estudo

Como mostrado no Capítulo 5, diversos registros EEG foram coletados e submetidos às análises dos critérios de inclusão/ exclusão dessa pesquisa. Nessa análise foram utilizados 109 registros EEG, distribuídos conforme a Tabela 31. Na Tabela 31 tem-se as quantidades de registros EEG agrupados conforme Desfecho e Etiologia do coma. Nesse capítulo serão analisados problemas binários de classificação, portanto os grupamento aqui analisados serão: Grupamento A, com total de 97 registros EEG; Grupamento B, com total de 51 registros EEG; e Grupamento C, com total de 76 registros EEG.

Tabela 31 Quantitativo de registros EEG considerando etiologia e desfecho dos pacientes, análise 1 – 100 Hz.

Etiologias	Ativo	OC	OME	Total
AVE	10	20	6	36
TCE	32	23	0	55
Outros	8	8	2	18
Total	50	51	8	109

7.2.2 Pré-processamento e preparação das Matrizes de Atributos

Os sinais EEG escolhidos para análise em alta frequência foram submetidos aos cálculos de todos os quantificadores descritos no Capítulo 5. Contudo, antes desses sinais serem escolhidos, foram submetidos à análise de ruído de rede. Após certificação que a potência do sinal entre as frequências de 55 a 65 Hz não superou a potência do sinal em faixas menores de frequências, os sinais foram analisados considerando seis ritmos cerebrais: delta, teta, alfa, beta, gama e supergama. Na Tabela 32 estão as informações sobre os atributos de entradas considerados nas criações dos modelos prognósticos.

Tabela 32 Atributos de entrada adotados nas matrizes utilizadas para modelos prognósticos, análise 1 – 100 Hz.

Matrizes de Processamentos	Parâmetros de Entrada	Quantidade de Atributos
1. Matriz ALL_Q	Todos quantificadores mais dados demográficos.	165
2. Matriz FRE_Q	Quantificadores PCP, FM, VPC, COR e S.	150
3. Matriz FRE+D_Q	Quantificadores PCP, FM, VPC, COR e S mais dados demográficos.	155
4. Matriz TMP_Q	Assimetria e Curtose.	10
5. Matriz TMP+D_Q	Assimetria e Curtose mais dados demográficos.	15

7.2.3 Dados Treino e Teste

Assim como ocorreu na análise dos sinais EEG nos ritmos clínicos, no presente capítulo abordou-se os três grupamentos de análise: Grupamento A (ativo e OC), Grupamento B (ativo e OME) e Grupamento C (OC e OME). Levando em consideração esses grupamentos, bem como a proporção 2/3 e 1/3 para dados de treino e de teste, respectivamente, na Tabela 33 estão demonstradas as quantidades de cada desfecho na composição das matrizes de entradas mostradas.

Tabela 33 Quantitativo de dados de treino e dados de teste, análise 1 – 100 Hz.

Desfecho	Dados de Treino	Dados de Teste
Ativo	34	16
OC	34	17
OME	6	2

A partir da ferramenta de *hold out*, cinco combinações de diferentes possibilidades para treino e teste foram feitas, de maneira aleatória. Sendo assim, cada matriz de entrada foi composta por cinco diferentes dados de treino e cinco diferentes dados de teste.

7.2.4 Modelos Prognósticos e Medidas de Desempenho Treino: Ritmos Clínicos

Nesse processo também foram elaborados 55 modelos prognósticos a partir da combinação entre algoritmo classificador, podendo ser SVM, LR ou KNN, bem como a composição dos parâmetros de entradas das matrizes de dados de treinos. K-fold com cinco pastas foi adotada, sendo repetida três vezes para cada modelo gerado. Essa metodologia é semelhante à metodologia explicada no Capítulo 5.

7.2.5 Análise Estatística e Definição dos Melhores Modelos

Após a criação dos 55 modelos, os que apresentaram melhores medidas para o padrão F-Macro foram testados a partir dos dados de teste. Com isso, as medidas de acurácia, sensibilidade, especificidade e F-macro foram calculadas para os dez melhores modelos prognósticos.

Com o objetivo de verificar os melhores classificadores bem como as melhores combinações de parâmetros de entrada, ou seja, atributos, foram gerados gráficos do tipo boxplots, que fornecem dados de mediana, quartis e outliers.

7.3 Resultados

7.3.1 Grupamento A: Ativo x Óbito Clínico

Nessa análise o total de 101 registros foram analisados, sendo 50% pertencente ao desfecho ativo e os demais ao desfecho OC. Esse conjunto de dados formado por 68 dados de treino e 33 dados de teste é o primeiro grupamento desse estudo com classes balanceadas. Sendo assim, as medidas de acurácia tendem a representar de maneira melhor o desempenho dos modelos comparado com o que foi apresentado no Capítulo 5. Contudo, a fim de seguir um padrão de metodologia, a medida F-macro foi essencial na definição dos melhores modelos prognósticos.

Na Tabela 34 estão os valores de mediana $\pm$ desvio padrão da acurácia de treino, para os 55 modelos gerados, enquanto na Tabela 35 tem-se os valores obtidos de mediana $\pm$ desvio padrão da medida de desempenho de treino F-macro.

A observação dos valores de acurácia de treino (Tabela 34) permite concluir que os valores aqui obtidos variam entre 0,44 e 0,66. A média de valores obtidos para cada combinação de atributos é em torno de 0,52 de acurácia, o que indica comportamento parecido para todas as combinações de atributos de entradas.

Tabela 34 Valores de Acurácia treino, grupamento A, análise 1 – 100 Hz.

(continua)

Modelos	Todos	Fre	Freq + D	Temp	Temp + D
SVM 1	0,58 $\pm$ 0,03	0,58 $\pm$ 0,05	0,57 $\pm$ 0,04	0,48 $\pm$ 0,05	0,54 $\pm$ 0,06
SVM 2	0,58 $\pm$ 0,03	0,54 $\pm$ 0,04	0,57 $\pm$ 0,03	0,45 $\pm$ 0,07	0,52 $\pm$ 0,06
SVM 3	0,57 $\pm$ 0,04	0,55 $\pm$ 0,05	0,57 $\pm$ 0,04	0,5 $\pm$ 0,04	0,51 $\pm$ 0,05
SVM 4	0,48 $\pm$ 0	0,48 $\pm$ 0	0,48 $\pm$ 0	0,48 $\pm$ 0	0,48 $\pm$ 0
SVM 5	0,48 $\pm$ 0	0,48 $\pm$ 0	0,48 $\pm$ 0	0,48 $\pm$ 0	0,48 $\pm$ 0
SVM 6	0,48 $\pm$ 0	0,48 $\pm$ 0	0,48 $\pm$ 0	0,48 $\pm$ 0	0,48 $\pm$ 0
SVM 7	0,48 $\pm$ 0	0,48 $\pm$ 0	0,48 $\pm$ 0	0,48 $\pm$ 0	0,48 $\pm$ 0
SVM 8	0,48 $\pm$ 0	0,48 $\pm$ 0	0,48 $\pm$ 0	0,48 $\pm$ 0,00	0,48 $\pm$ 0
SVM 9	0,48 $\pm$ 0	0,48 $\pm$ 0	0,48 $\pm$ 0	0,48 $\pm$ 0,01	0,48 $\pm$ 0,00

Tabela 34 Valores de Acurácia treino, grupamento A, análise 1 – 100 Hz.

(continua)

Modelos	Todos	Fre	Freq + D	Temp	Temp + D
SVM 10	0,48 ± 0	0,48 ± 0	0,48 ± 0	0,48 ± 0,01	0,48 ± 0,00
SVM 11	0,48 ± 0	0,48 ± 0	0,48 ± 0	0,48 ± 0,02	0,48 ± 0,01
SVM 12	0,48 ± 0	0,48 ± 0,00	0,48 ± 0	0,47 ± 0,03	0,48 ± 0,02
SVM 13	0,48 ± 0	0,48 ± 0,01	0,48 ± 0,01	0,48 ± 0,04	0,5 ± 0,05
SVM 14	0,48 ± 0	0,48 ± 0,02	0,48 ± 0,01	0,44 ± 0,08	0,55 ± 0,07
SVM 15	0,48 ± 0,01	0,48 ± 0,01	0,5 ± 0,02	0,45 ± 0,08	0,66 ± 0,07
SVM 16	0,52 ± 0,04	0,55 ± 0,04	0,52 ± 0,03	0,45 ± 0,06	0,60 ± 0,05
SVM 17	0,55 ± 0,05	0,54 ± 0,04	0,54 ± 0,05	0,48 ± 0,03	0,58 ± 0,05
SVM 18	0,55 ± 0,02	0,54 ± 0,04	0,55 ± 0,04	0,48 ± 0,02	0,5 ± 0,03
SVM 19	0,52 ± 0,03	0,5 ± 0,04	0,54 ± 0,05	0,48 ± 0,02	0,47 ± 0,03
SVM 20	0,5 ± 0,02	0,5 ± 0,02	0,48 ± 0,03	0,48 ± 0,02	0,48 ± 0,03
SVM 21	0,48 ± 0,01	0,48 ± 0,02	0,48 ± 0,03	0,48 ± 0,02	0,48 ± 0,03
SVM 22	0,48 ± 0,01	0,48 ± 0,01	0,48 ± 0,03	0,48 ± 0,02	0,48 ± 0,03
SVM 23	0,48 ± 0,01	0,48 ± 0,01	0,5 ± 0,02	0,48 ± 0,02	0,48 ± 0,03
SVM 24	0,48 ± 0,01	0,48 ± 0,01	0,5 ± 0,02	0,48 ± 0,02	0,48 ± 0,03
LR	0,5 ± 0,06	0,52 ± 0,06	0,52 ± 0,05	0,51 ± 0,04	0,54 ± 0,04
KNN 1	0,51 ± 0,04	0,51 ± 0,05	0,52 ± 0,04	0,5 ± 0,04	0,52 ± 0,05
KNN 2	0,51 ± 0,04	0,51 ± 0,05	0,52 ± 0,04	0,5 ± 0,04	0,52 ± 0,05
KNN 3	0,5 ± 0,03	0,5 ± 0,03	0,51 ± 0,06	0,5 ± 0,05	0,55 ± 0,06
KNN 4	0,5 ± 0,03	0,5 ± 0,03	0,51 ± 0,06	0,5 ± 0,06	0,57 ± 0,06
KNN 5	0,47 ± 0,05	0,48 ± 0,04	0,5 ± 0,04	0,5 ± 0,05	0,52 ± 0,06
KNN 6	0,48 ± 0,03	0,48 ± 0,04	0,5 ± 0,04	0,48 ± 0,06	0,57 ± 0,07
KNN 7	0,57 ± 0,04	0,57 ± 0,05	0,57 ± 0,04	0,52 ± 0,07	0,55 ± 0,06
KNN 8	0,57 ± 0,04	0,57 ± 0,05	0,57 ± 0,04	0,52 ± 0,07	0,55 ± 0,06
KNN 9	0,57 ± 0,05	0,52 ± 0,07	0,60 ± 0,05	0,45 ± 0,05	0,58 ± 0,06
KNN 10	0,58 ± 0,05	0,54 ± 0,07	0,60 ± 0,04	0,47 ± 0,06	0,57 ± 0,06
KNN 11	0,52 ± 0,04	0,54 ± 0,05	0,51 ± 0,04	0,44 ± 0,06	0,55 ± 0,07
KNN 12	0,54 ± 0,04	0,52 ± 0,05	0,52 ± 0,04	0,47 ± 0,04	0,61 ± 0,06
KNN 13	0,55 ± 0,04	0,57 ± 0,05	0,58 ± 0,03	0,48 ± 0,05	0,54 ± 0,05
KNN 14	0,55 ± 0,04	0,57 ± 0,05	0,58 ± 0,03	0,48 ± 0,05	0,54 ± 0,05
KNN 15	0,57 ± 0,03	0,55 ± 0,05	0,55 ± 0,04	0,47 ± 0,04	0,58 ± 0,05
KNN 16	0,57 ± 0,03	0,55 ± 0,05	0,55 ± 0,04	0,47 ± 0,04	0,60 ± 0,05
KNN 17	0,54 ± 0,06	0,52 ± 0,04	0,54 ± 0,05	0,45 ± 0,05	0,57 ± 0,07
KNN 18	0,55 ± 0,05	0,52 ± 0,06	0,55 ± 0,04	0,47 ± 0,06	0,60 ± 0,06
KNN 19	0,52 ± 0,05	0,51 ± 0,02	0,57 ± 0,07	0,5 ± 0,00	0,54 ± 0,07
KNN 20	0,52 ± 0,05	0,51 ± 0,02	0,57 ± 0,07	0,5 ± 0,00	0,54 ± 0,07
KNN 21	0,61 ± 0,04	0,5 ± 0,04	0,63 ± 0,04	0,5 ± 0,00	0,60 ± 0,07
KNN 22	0,61 ± 0,04	0,5 ± 0,04	0,63 ± 0,04	0,5 ± 0,00	0,60 ± 0,07
KNN 23	0,57 ± 0,07	0,48 ± 0,02	0,57 ± 0,07	0,5 ± 0,00	0,55 ± 0,06
KNN 24	0,63 ± 0,05	0,5 ± 0,03	0,61 ± 0,07	0,5 ± 0,00	0,60 ± 0,07

Tabela 34 Valores de Acurácia treino, grupamento A, análise 1 – 100 Hz.

(conclusão)

Modelos	Todos	Fre	Freq + D	Temp	Temp + D
KNN 25	0,48 ± 0	0,57 ± 0,05	0,48 ± 0	0,48 ± 0,05	0,48 ± 0
KNN 26	0,48 ± 0	0,57 ± 0,05	0,48 ± 0	0,48 ± 0,05	0,48 ± 0
KNN 27	0,48 ± 0	0,55 ± 0,05	0,48 ± 0	0,47 ± 0,04	0,48 ± 0
KNN 28	0,48 ± 0	0,55 ± 0,05	0,48 ± 0	0,47 ± 0,04	0,48 ± 0
KNN 29	0,48 ± 0	0,52 ± 0,04	0,48 ± 0	0,45 ± 0,05	0,48 ± 0
KNN 30	0,48 ± 0	0,52 ± 0,06	0,48 ± 0	0,47 ± 0,06	0,48 ± 0

Na Tabela 35 tem-se os valores de F-macro e percebe-se que a variação dessa medida é maior que para acurácia, sendo o menor valor igual a 0,38 e o valor máximo igual a 0,66. Nota-se que para F-macro, quando os atributos de entrada estão apenas no domínio do tempo acrescidos das informações demográficas, o comportamento médio dos 55 modelos tem melhor desempenho, com média de F-macro igual a 0,57.

Tabela 35 Valores de F-macro treino, grupamento A, análise 1 – 100 Hz.

(continua)

Modelos	Todos	Fre	Freq + D	Temp	Temp + D
SVM 1	0,57 ± 0,03	0,57 ± 0,06	0,57 ± 0,06	0,51 ± 0,05	0,58 ± 0,06
SVM 2	0,58 ± 0,02	0,54 ± 0,05	0,55 ± 0,04	0,47 ± 0,09	0,54 ± 0,06
SVM 3	0,56 ± 0,04	0,55 ± 0,06	0,55 ± 0,04	0,46 ± 0,05	0,53 ± 0,05
SVM 4	0,53 ± 0,09	0,60 ± 0,05	0,53 ± 0,06	0,60 ± 0,11	0,60 ± 0,06
SVM 5	0,53 ± 0,09	0,60 ± 0,05	0,53 ± 0,06	0,60 ± 0,11	0,60 ± 0,06
SVM 6	0,53 ± 0,09	0,60 ± 0,05	0,53 ± 0,06	0,60 ± 0,11	0,60 ± 0,06
SVM 7	0,53 ± 0,09	0,60 ± 0,05	0,53 ± 0,06	0,60 ± 0,11	0,60 ± 0,06
SVM 8	0,53 ± 0,09	0,60 ± 0,05	0,53 ± 0,06	0,60 ± 0,11	0,60 ± 0,06
SVM 9	0,53 ± 0,09	0,60 ± 0,05	0,53 ± 0,06	0,57 ± 0,09	0,57 ± 0,05
SVM 10	0,53 ± 0,09	0,60 ± 0,05	0,53 ± 0,06	0,53 ± 0,09	0,55 ± 0,04
SVM 11	0,53 ± 0,09	0,60 ± 0,05	0,53 ± 0,06	0,45 ± 0,10	0,42 ± 0,09
SVM 12	0,53 ± 0,09	0,60 ± 0,05	0,53 ± 0,06	0,43 ± 0,08	0,38 ± 0,11
SVM 13	0,53 ± 0,09	0,60 ± 0,06	0,53 ± 0,06	0,47 ± 0,07	0,42 ± 0,06
SVM 14	0,53 ± 0,09	0,60 ± 0,06	0,53 ± 0,06	0,45 ± 0,08	0,50 ± 0,08
SVM 15	0,53 ± 0,12	0,58 ± 0,09	0,55 ± 0,09	0,41 ± 0,08	0,61 ± 0,08
SVM 16	0,56 ± 0,05	0,56 ± 0,06	0,57 ± 0,08	0,51 ± 0,08	0,56 ± 0,06
SVM 17	0,54 ± 0,06	0,54 ± 0,05	0,56 ± 0,07	0,56 ± 0,02	0,55 ± 0,06
SVM 18	0,55 ± 0,03	0,55 ± 0,05	0,55 ± 0,05	0,55 ± 0,06	0,55 ± 0,07
SVM 19	0,58 ± 0,03	0,58 ± 0,05	0,58 ± 0,04	0,55 ± 0,07	0,56 ± 0,06
SVM 20	0,60 ± 0,02	0,59 ± 0,03	0,59 ± 0,01	0,55 ± 0,07	0,55 ± 0,06
SVM 21	0,59 ± 0,02	0,59 ± 0,02	0,59 ± 0,01	0,55 ± 0,07	0,55 ± 0,06
SVM 22	0,59 ± 0,02	0,59 ± 0,02	0,59 ± 0,01	0,55 ± 0,07	0,55 ± 0,06
SVM 23	0,59 ± 0,02	0,59 ± 0,02	0,59 ± 0,01	0,55 ± 0,07	0,55 ± 0,06

Tabela 35 Valores de F-macro treino, grupamento A, análise 1 – 100 Hz.

(conclusão)

Modelos	Todos	Fre	Freq + D	Temp	Temp + D
SVM 24	0,59 ± 0,02	0,59 ± 0,02	0,59 ± 0,01	0,55 ± 0,07	0,55 ± 0,06
LR	0,49 ± 0,08	0,52 ± 0,06	0,52 ± 0,06	0,52 ± 0,04	0,57 ± 0,04
KNN 1	0,49 ± 0,05	0,5 ± 0,05	0,51 ± 0,05	0,49 ± 0,04	0,54 ± 0,05
KNN 2	0,49 ± 0,05	0,5 ± 0,05	0,51 ± 0,05	0,49 ± 0,04	0,54 ± 0,05
KNN 3	0,46 ± 0,05	0,5 ± 0,03	0,50 ± 0,09	0,49 ± 0,05	0,58 ± 0,04
KNN 4	0,46 ± 0,05	0,5 ± 0,03	0,50 ± 0,09	0,49 ± 0,06	0,59 ± 0,05
KNN 5	0,53 ± 0,06	0,56 ± 0,07	0,58 ± 0,05	0,56 ± 0,06	0,57 ± 0,03
KNN 6	0,47 ± 0,05	0,45 ± 0,06	0,50 ± 0,07	0,47 ± 0,07	0,56 ± 0,04
KNN 7	0,53 ± 0,06	0,53 ± 0,06	0,54 ± 0,05	0,5 ± 0,07	0,54 ± 0,06
KNN 8	0,53 ± 0,06	0,53 ± 0,06	0,54 ± 0,05	0,5 ± 0,07	0,54 ± 0,06
KNN 9	0,55 ± 0,05	0,52 ± 0,07	0,60 ± 0,04	0,44 ± 0,05	0,58 ± 0,06
KNN 10	0,56 ± 0,05	0,53 ± 0,07	0,60 ± 0,04	0,42 ± 0,05	0,58 ± 0,05
KNN 11	0,6 ± 0,04	0,57 ± 0,06	0,58 ± 0,04	0,53 ± 0,05	0,57 ± 0,06
KNN 12	0,56 ± 0,04	0,51 ± 0,06	0,52 ± 0,05	0,45 ± 0,04	0,58 ± 0,06
KNN 13	0,54 ± 0,05	0,53 ± 0,06	0,53 ± 0,04	0,46 ± 0,05	0,57 ± 0,05
KNN 14	0,54 ± 0,05	0,53 ± 0,06	0,53 ± 0,04	0,46 ± 0,05	0,57 ± 0,05
KNN 15	0,51 ± 0,05	0,51 ± 0,06	0,54 ± 0,07	0,46 ± 0,06	0,59 ± 0,04
KNN 16	0,51 ± 0,05	0,51 ± 0,06	0,54 ± 0,07	0,46 ± 0,06	0,62 ± 0,04
KNN 17	0,59 ± 0,09	0,58 ± 0,09	0,58 ± 0,09	0,51 ± 0,06	0,58 ± 0,05
KNN 18	0,53 ± 0,09	0,51 ± 0,10	0,53 ± 0,10	0,45 ± 0,08	0,57 ± 0,05
KNN 19	0,55 ± 0,06	0,65 ± 0,22	0,57 ± 0,12	0,62 ± 0,15	0,60 ± 0,09
KNN 20	0,55 ± 0,06	0,65 ± 0,22	0,57 ± 0,12	0,62 ± 0,15	0,60 ± 0,09
KNN 21	0,61 ± 0,04	0,54 ± 0,23	0,63 ± 0,04	0,66 ± 0,26	0,64 ± 0,08
KNN 22	0,61 ± 0,04	0,54 ± 0,23	0,63 ± 0,04	0,66 ± 0,26	0,64 ± 0,08
KNN 23	0,62 ± 0,03	0,60 ± 0,15	0,61 ± 0,03	0,66 ± 0,08	0,61 ± 0,04
KNN 24	0,63 ± 0,03	0,59 ± 0,14	0,6 ± 0,05	0,66 ± 0,08	0,60 ± 0,05
KNN 25	0,60 ± 0	0,53 ± 0,06	0,60 ± 0	0,46 ± 0,05	0,60 ± 0
KNN 26	0,60 ± 0	0,53 ± 0,06	0,60 ± 0	0,46 ± 0,05	0,60 ± 0
KNN 27	0,60 ± 0	0,51 ± 0,06	0,60 ± 0	0,46 ± 0,06	0,60 ± 0
KNN 28	0,60 ± 0	0,51 ± 0,06	0,60 ± 0	0,46 ± 0,06	0,60 ± 0
KNN 29	0,60 ± 0	0,58 ± 0,09	0,60 ± 0	0,51 ± 0,06	0,60 ± 0
KNN 30	0,60 ± 0	0,51 ± 0,10	0,60 ± 0	0,45 ± 0,08	0,60 ± 0

Os dez modelos aqui testados são semelhantes aos modelos escolhidos no Capítulo 6 e portanto, os valores de acurácia, sensibilidade, especificidade e F-macro obtidos nos testes dos modelos, estão mostrados na Tabela 36 a Tabela 39. Analisando a Tabela 36 nota-se que no geral os atributos no domínio da frequência apresentaram média maior de acurácia que as demais combinações. Já em termos de modelos, nota-se que aquele com maior média independentemente dos atributos analisados, foi SVM3. Nota-se ainda que o menor valor de acurácia obtido foi igual a 0,42 e o valor máximo igual a 0,61.

Tabela 36 Valores de Acurácia teste, grupamento A, análise 1 – 100 Hz.

Modelos	Todos	Fre	Freq + D	Temp	Temp + D	Média
SVM 1	0,61 ± 0,08	0,61 ± 0,09	0,61 ± 0,1	0,52 ± 0,12	0,52 ± 0,08	0,57
SVM 2	0,61 ± 0,08	0,58 ± 0,07	0,61 ± 0,04	0,48 ± 0,1	0,45 ± 0,1	0,55
SVM 3	0,61 ± 0,07	0,61 ± 0,07	0,58 ± 0,07	0,58 ± 0,09	0,52 ± 0,05	0,58
SVM 15	0,48 ± 0,02	0,48 ± 0,02	0,48 ± 0,02	0,48 ± 0,07	0,58 ± 0,08	0,50
LR	0,48 ± 0,09	0,55 ± 0,1	0,45 ± 0,13	0,55 ± 0,1	0,52 ± 0,08	0,51
KNN1	0,52 ± 0,1	0,58 ± 0,07	0,52 ± 0,07	0,52 ± 0,11	0,48 ± 0,12	0,52
KNN9	0,55 ± 0,06	0,61 ± 0,09	0,52 ± 0,09	0,42 ± 0,11	0,52 ± 0,07	0,52
KNN13	0,58 ± 0,09	0,55 ± 0,08	0,61 ± 0,09	0,55 ± 0,12	0,55 ± 0,08	0,56
KNN21	0,48 ± 0	0,48 ± 0	0,48 ± 0	0,48 ± 0	0,48 ± 0	0,48
KNN25	0,48 ± 0	0,55 ± 0,08	0,48 ± 0	0,55 ± 0,12	0,48 ± 0	0,51
Média	0,54	0,56	0,53	0,51	0,51	

A sensibilidade, mostrada na Tabela 37 tem variação de valores entre 0,44 e 0,62, com média de 0,52. Nota-se que SVM1 é o modelo com melhor valor de sensibilidade, porém SVM3 também apresentou um média de desempenho semelhante. Já em relação aos atributos de entradas, aqueles no domínio da frequência tendem a ter melhores valores de sensibilidade.

Tabela 37 Valores de Sensibilidade teste, grupamento A, análise 1 – 100 Hz.

Modelos	Todos	Fre	Freq + D	Temp	Temp + D	Média
SVM 1	0,59 ± 0,1	0,62 ± 0,12	0,6 ± 0,11	0,5 ± 0,13	0,5 ± 0,09	0,56
SVM 2	0,6 ± 0,08	0,57 ± 0,08	0,59 ± 0,07	0,47 ± 0,11	0,44 ± 0,13	0,54
SVM 3	0,58 ± 0,06	0,61 ± 0,08	0,56 ± 0,08	0,57 ± 0,1	0,5 ± 0,06	0,56
SVM 15	0,48 ± 0	0,48 ± 0,24	0,48 ± 0,24	0,44 ± 0,05	0,6 ± 0,14	0,50
LR	0,47 ± 0,1	0,53 ± 0,09	0,44 ± 0,12	0,53 ± 0,1	0,5 ± 0,09	0,50
KNN1	0,5 ± 0,1	0,55 ± 0,07	0,5 ± 0,07	0,5 ± 0,11	0,47 ± 0,15	0,50
KNN9	0,52 ± 0,04	0,57 ± 0,07	0,5 ± 0,07	0,44 ± 0,09	0,5 ± 0,07	0,51
KNN13	0,56 ± 0,08	0,54 ± 0,07	0,58 ± 0,08	0,55 ± 0,11	0,53 ± 0,1	0,55
KNN21	0,48 ± 0	0,48 ± 0	0,48 ± 0	0,48 ± 0	0,48 ± 0	0,48
KNN25	0,48 ± 0	0,54 ± 0,07	0,48 ± 0	0,55 ± 0,11	0,48 ± 0	0,51
Média	0,53	0,55	0,52	0,50	0,50	

Na Tabela 38, a especificidade é apresentada. Com variação dos valores de 0,25 a 0,64, a média geral dessa medida foi de 0,55. Nota-se que SVM1 e SVM3 tiveram os melhores valores médios de especificidade. Além disso, os atributos apenas no domínio da frequência apresentaram média elevada de especificidade. É evidente a dificuldade dos modelos em acertar a classe OC.

Tabela 38 Valores de Especificidade teste, grupamento A, análise 1 – 100 Hz.

Modelos	Todos	Fre	Freq + D	Temp	Temp + D	Média
SVM 1	0,63 ± 0,08	0,6 ± 0,09	0,61 ± 0,09	0,6 ± 0,11	0,53 ± 0,07	0,59
SVM 2	0,61 ± 0,08	0,58 ± 0,07	0,63 ± 0,04	0,5 ± 0,1	0,47 ± 0,11	0,56
SVM 3	0,63 ± 0,08	0,62 ± 0,07	0,58 ± 0,08	0,58 ± 0,1	0,53 ± 0,04	0,59
SVM 15	0,51 ± 0,01	0,5 ± 0,5	0,25 ± 0,35	0,5 ± 0,25	0,56 ± 0,06	0,46
LR	0,5 ± 0,09	0,56 ± 0,12	0,47 ± 0,13	0,55 ± 0,1	0,53 ± 0,08	0,52
KNN1	0,53 ± 0,11	0,6 ± 0,08	0,54 ± 0,07	0,53 ± 0,1	0,5 ± 0,11	0,54
KNN9	0,63 ± 0,09	0,64 ± 0,13	0,56 ± 0,14	0,39 ± 0,16	0,53 ± 0,08	0,55
KNN13	0,6 ± 0,11	0,55 ± 0,11	0,6 ± 0,11	0,56 ± 0,13	0,57 ± 0,08	0,58
KNN25	0 ± 0	0,55 ± 0,11	0 ± 0	0,56 ± 0,13	0 ± 0	0,55
Média	0,58	0,58	0,53	0,53	0,53	

Por fim, como mostra a Tabela 39, F-macro varia de 0,33 a 0,61, com média geral igual 0,49. Também para essa medida, os modelos SVM1 e SVM3 tem melhores médias de desempenho. E como ocorreu para as três medidas de desempenho analisadas, a combinação dos atributos apenas no domínio da frequência gerou melhores resultados de F-macro.

Tabela 39 Valores de F-macro teste, grupamento A, análise 1 – 100 Hz.

Modelos	Todos	Fre	Freq + D	Temp	Temp + D	Média
SVM 1	0,61 ± 0,09	0,6 ± 0,1	0,6 ± 0,1	0,51 ± 0,12	0,51 ± 0,08	0,57
SVM 2	0,6 ± 0,08	0,57 ± 0,07	0,61 ± 0,04	0,48 ± 0,1	0,45 ± 0,1	0,54
SVM 3	0,6 ± 0,07	0,59 ± 0,07	0,58 ± 0,07	0,57 ± 0,09	0,51 ± 0,05	0,57
SVM 15	0,33 ± 0,02	0,33 ± 0,03	0,33 ± 0,01	0,45 ± 0,11	0,52 ± 0,1	0,39
LR	0,48 ± 0,09	0,55 ± 0,1	0,45 ± 0,13	0,53 ± 0,1	0,51 ± 0,08	0,51
KNN1	0,51 ± 0,1	0,57 ± 0,07	0,51 ± 0,07	0,51 ± 0,11	0,48 ± 0,12	0,52
KNN9	0,54 ± 0,05	0,6 ± 0,1	0,51 ± 0,08	0,39 ± 0,12	0,51 ± 0,07	0,51
KNN13	0,58 ± 0,09	0,54 ± 0,08	0,6 ± 0,09	0,54 ± 0,12	0,54 ± 0,08	0,56
KNN21	0,33 ± 0	0,33 ± 0	0,33 ± 0	0,33 ± 0	0,33 ± 0	0,33
KNN25	0,33 ± 0	0,54 ± 0,08	0,33 ± 0	0,54 ± 0,12	0,33 ± 0	0,41
Média	0,49	0,52	0,48	0,49	0,47	

7.3.2 Grupamento B: Ativo x Óbito por Morte Encefálica

Como a quantidade de desfechos de morte encefálica foi de apenas oito registros EEG, optou-se por reduzir a quantidade de registros da classe ativo para 22 (escolhidos de maneira aleatória). Sendo assim, esse grupamento foi composto por 30 dados EEG, com 75% dos dados pertencentes à classe ativo. Destaca-se que a quantidade de dados de treino foi igual a 21, e de teste, igual a 7.

Seguindo a metodologia descrita, inicialmente foram calculados os valores de acurácia e F-macro de treino para os 55 modelos gerados, considerando as cinco combinações de atributos existentes. Na Tabela 40 estão os valores de acurácia de treino, enquanto a

Tabela 41 contém os valores obtidos da medida F-macro. Em relação aos valores de acurácia obtidos, nota-se que houve variação de valores entre 0,52 a 0,80. Já em termos de F-macro, a variação foi de 0,64 a 0,88. Embora esse grupamento seja desbalanceado, priorizando a classe ativo, os resultados de F-macro são melhores que os obtidos para o grupamento A.

Tabela 40 Valores de Acurácia treino, grupamento B, análise 1 – 100 Hz.

(continua)

Modelos	Todos	Fre	Freq + D	Temp	Temp + D
SVM 1	0,76 ± 0,04	0,80 ± 0,03	0,76 ± 0,02	0,66 ± 0,04	0,71 ± 0,03
SVM 2	0,76 ± 0,03	0,80 ± 0,03	0,80 ± 0,04	0,61 ± 0,09	0,71 ± 0,06
SVM 3	0,76 ± 0,04	0,80 ± 0,03	0,76 ± 0,05	0,66 ± 0,07	0,71 ± 0,06
SVM 4	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0
SVM 5	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0
SVM 6	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0
SVM 7	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0
SVM 8	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0
SVM 9	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0
SVM 10	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0
SVM 11	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0
SVM 12	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0
SVM 13	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0
SVM 14	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0
SVM 15	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0,01	0,71 ± 0
SVM 16	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0,03	0,71 ± 0,01
SVM 17	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0
SVM 18	0,71 ± 0,04	0,71 ± 0,05	0,71 ± 0,04	0,71 ± 0	0,71 ± 0
SVM 19	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0
SVM 20	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0
SVM 21	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0
SVM 22	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0
SVM 23	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0
SVM 24	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0
LR	0,66 ± 0,09	0,66 ± 0,07	0,66 ± 0,09	0,52 ± 0,07	0,57 ± 0,09
KNN 1	0,66 ± 0,10	0,71 ± 0,07	0,66 ± 0,06	0,61 ± 0,06	0,66 ± 0,09
KNN 2	0,66 ± 0,10	0,71 ± 0,07	0,66 ± 0,06	0,61 ± 0,06	0,66 ± 0,09
KNN 3	0,71 ± 0,05	0,71 ± 0,04	0,71 ± 0,04	0,76 ± 0,02	0,76 ± 0,04
KNN 4	0,71 ± 0,05	0,71 ± 0,04	0,71 ± 0,04	0,76 ± 0,02	0,71 ± 0,04
KNN 5	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0
KNN 6	0,71 ± 0,02	0,71 ± 0,01	0,71 ± 0,01	0,71 ± 0	0,71 ± 0

Tabela 40 Valores de Acurácia treino, grupamento B, análise 1 – 100 Hz.

(conclusão)

Modelos	Todos	Fre	Freq + D	Temp	Temp + D
KNN 7	0,76 ± 0,06	0,76 ± 0,06	0,76 ± 0,06	0,52 ± 0,09	0,66 ± 0,07
KNN 8	0,76 ± 0,06	0,76 ± 0,06	0,76 ± 0,06	0,52 ± 0,09	0,66 ± 0,07
KNN 9	0,76 ± 0,05	0,76 ± 0,04	0,76 ± 0,04	0,66 ± 0,05	0,66 ± 0,07
KNN 10	0,76 ± 0,05	0,76 ± 0,04	0,76 ± 0,04	0,66 ± 0,08	0,71 ± 0,06
KNN 11	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0
KNN 12	0,71 ± 0,03	0,71 ± 0,01	0,71 ± 0,01	0,66 ± 0,03	0,71 ± 0,03
KNN 13	0,76 ± 0,07	0,76 ± 0,05	0,80 ± 0,05	0,52 ± 0,07	0,71 ± 0,05
KNN 14	0,76 ± 0,07	0,76 ± 0,05	0,80 ± 0,05	0,52 ± 0,07	0,71 ± 0,05
KNN 15	0,71 ± 0,02	0,71 ± 0,02	0,71 ± 0,03	0,71 ± 0,03	0,76 ± 0,04
KNN 16	0,71 ± 0,02	0,71 ± 0,02	0,71 ± 0,03	0,71 ± 0,03	0,76 ± 0,04
KNN 17	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0
KNN 18	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0
KNN 19	0,71 ± 0,08	0,61 ± 0,18	0,71 ± 0,09	0,71 ± 0,19	0,66 ± 0,06
KNN 20	0,71 ± 0,08	0,61 ± 0,18	0,71 ± 0,09	0,71 ± 0,19	0,66 ± 0,06
KNN 21	0,71 ± 0,08	0,71 ± 0,13	0,71 ± 0,07	0,71 ± 0,04	0,71 ± 0,06
KNN 22	0,71 ± 0,08	0,71 ± 0,13	0,71 ± 0,07	0,71 ± 0,04	0,71 ± 0,06
KNN 23	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0
KNN 24	0,71 ± 0,05	0,71 ± 0	0,66 ± 0,05	0,71 ± 0	0,71 ± 0,03
KNN 25	0,71 ± 0	0,76 ± 0,05	0,71 ± 0	0,52 ± 0,07	0,71 ± 0
KNN 26	0,71 ± 0	0,76 ± 0,05	0,71 ± 0	0,52 ± 0,07	0,71 ± 0
KNN 27	0,71 ± 0	0,71 ± 0,02	0,71 ± 0	0,71 ± 0,03	0,71 ± 0
KNN 28	0,71 ± 0	0,71 ± 0,02	0,71 ± 0	0,71 ± 0,03	0,71 ± 0
KNN 29	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0
KNN 30	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0	0,71 ± 0

Tabela 41 Valores de F-macro treino, grupamento B, análise 1 – 100 Hz.

(continua)

Modelos	Todos	Fre	Freq + D	Temp	Temp + D
SVM 1	0,85 ± 0,02	0,87 ± 0,01	0,85 ± 0,01	0,8 ± 0,02	0,82 ± 0,01
SVM 2	0,85 ± 0,02	0,88 ± 0,01	0,87 ± 0,02	0,75 ± 0,08	0,81 ± 0,04
SVM 3	0,85 ± 0,02	0,88 ± 0,02	0,85 ± 0,03	0,77 ± 0,05	0,81 ± 0,04
SVM 4	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0
SVM 5	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0
SVM 6	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0
SVM 7	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0
SVM 8	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0
SVM 9	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0
SVM 10	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0
SVM 11	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0
SVM 12	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0

Tabela 41 Valores de F-macro treino, grupamento B, análise 1 – 100 Hz.

(conclusão)

Modelos	Todos	Fre	Freq + D	Temp	Temp + D
SVM 13	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0
SVM 14	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0
SVM 15	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0,01	0,83 ± 0
SVM 16	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0,02	0,83 ± 0,01
SVM 17	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0
SVM 18	0,83 ± 0,02	0,83 ± 0,02	0,83 ± 0,02	0,83 ± 0	0,83 ± 0
SVM 19	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0
SVM 20	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0
SVM 21	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0
SVM 22	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0
SVM 23	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0
SVM 24	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0
LR	0,78 ± 0,06	0,77 ± 0,05	0,78 ± 0,07	0,64 ± 0,05	0,66 ± 0,07
KNN 1	0,77 ± 0,07	0,81 ± 0,06	0,75 ± 0,05	0,75 ± 0,05	0,78 ± 0,07
KNN 2	0,77 ± 0,07	0,81 ± 0,06	0,75 ± 0,05	0,75 ± 0,05	0,78 ± 0,07
KNN 3	0,82 ± 0,03	0,83 ± 0,02	0,83 ± 0,02	0,85 ± 0,01	0,84 ± 0,02
KNN 4	0,82 ± 0,03	0,83 ± 0,02	0,83 ± 0,02	0,85 ± 0,01	0,83 ± 0,02
KNN 5	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0
KNN 6	0,83 ± 0,01	0,83 ± 0,01	0,83 ± 0,00	0,83 ± 0	0,83 ± 0
KNN 7	0,84 ± 0,03	0,83 ± 0,04	0,83 ± 0,04	0,66 ± 0,07	0,77 ± 0,05
KNN 8	0,84 ± 0,03	0,83 ± 0,04	0,83 ± 0,04	0,66 ± 0,07	0,77 ± 0,05
KNN 9	0,85 ± 0,03	0,84 ± 0,02	0,85 ± 0,02	0,78 ± 0,04	0,78 ± 0,04
KNN 10	0,85 ± 0,03	0,84 ± 0,02	0,85 ± 0,02	0,77 ± 0,06	0,81 ± 0,04
KNN 11	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0
KNN 12	0,83 ± 0,01	0,83 ± 0,00	0,83 ± 0,00	0,8 ± 0,02	0,83 ± 0,02
KNN 13	0,85 ± 0,04	0,85 ± 0,03	0,88 ± 0,03	0,68 ± 0,06	0,81 ± 0,03
KNN 14	0,85 ± 0,04	0,85 ± 0,03	0,88 ± 0,03	0,68 ± 0,06	0,81 ± 0,03
KNN 15	0,83 ± 0,01	0,83 ± 0,01	0,83 ± 0,01	0,83 ± 0,01	0,84 ± 0,02
KNN 16	0,83 ± 0,01	0,83 ± 0,01	0,83 ± 0,01	0,83 ± 0,01	0,84 ± 0,02
KNN 17	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0
KNN 18	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0	0,83 ± 0
KNN 19	0,78 ± 0,06	0,75 ± 0,35	0,81 ± 0,06	0,83 ± 0,30	0,78 ± 0,05
KNN 20	0,78 ± 0,06	0,75 ± 0,35	0,81 ± 0,06	0,83 ± 0,30	0,78 ± 0,05

Os dez melhores modelos foram testados e os valores de acurácia, sensibilidade, especificidade e F-macro calculados. Na Tabela 42 tem-se os resultados de acurácia de teste. Nota-se que os valores obtidos variam entre 0,44 e 0,78, com média geral de 0,74. O modelo com média de acurácia mais baixa foi o de LR. Outra observação importante é que quando são processados todos os atributos a média de valor de acurácia é 0,77, o que também é observado

quando os modelos são constituídos por atributos apenas no domínio do tempo acrescidos pelos dados demográficos.

Tabela 42 Valores de acurácia teste, grupamento B, análise 1 – 100 Hz.

Modelos	Todos	Fre	Freq + D	Temp	Temp + D	Média
SVM 1	0,78 ± 0,08	0,78 ± 0	0,78 ± 0,06	0,78 ± 0,08	0,78 ± 0	0,78
SVM 2	0,78 ± 0,06	0,78 ± 0,06	0,78 ± 0,06	0,78 ± 0,08	0,78 ± 0,06	0,78
SVM 3	0,78 ± 0,08	0,78 ± 0,06	0,78 ± 0,06	0,78 ± 0,06	0,78 ± 0,1	0,78
SVM 15	0,78 ± 0	0,78 ± 0	0,78 ± 0	0,78 ± 0	0,78 ± 0	0,78
LR	0,67 ± 0,1	0,44 ± 0,18	0,67 ± 0,12	0,56 ± 0,12	0,67 ± 0,17	0,60
KNN1	0,78 ± 0,06	0,78 ± 0,08	0,78 ± 0,06	0,78 ± 0,14	0,78 ± 0,12	0,78
KNN9	0,78 ± 0	0,78 ± 0	0,78 ± 0	0,78 ± 0	0,78 ± 0,06	0,78
KNN13	0,78 ± 0,06	0,67 ± 0,08	0,67 ± 0,08	0,56 ± 0,14	0,78 ± 0,06	0,69
KNN21	0,78 ± 0	0,78 ± 0	0,78 ± 0	0,78 ± 0	0,78 ± 0	0,78
KNN25	0,78 ± 0	0,67 ± 0,08	0,78 ± 0	0,56 ± 0,14	0,78 ± 0	0,71
Média	0,77	0,72	0,76	0,71	0,77	

Os valores de sensibilidade de teste, Tabela 43, são maiores comparados aos de acurácia, variando entre 0,67 e 0,86. Destaca-se que os modelos SVM2 e SVM3 apresentaram as maiores médias gerais de sensibilidade. Além disso, é importante observar que os modelos elaborados com atributos no tempo mais informações demográficas apresentaram resultados de sensibilidade maiores em média.

Tabela 43 Valores de sensibilidade teste, grupamento B, análise 1 – 100 Hz.

Modelos	Todos	Fre	Freq + D	Temp	Temp + D	Média
SVM 1	0,78 ± 0,07	0,78 ± 0	0,78 ± 0,05	0,78 ± 0,06	0,78 ± 0,04	0,78
SVM 2	0,78 ± 0,05	0,78 ± 0,05	0,78 ± 0,05	0,86 ± 0,05	0,86 ± 0,06	0,81
SVM 3	0,78 ± 0,07	0,78 ± 0,05	0,78 ± 0,05	0,86 ± 0,01	0,86 ± 0,06	0,81
SVM 15	0,78 ± 0	0,78 ± 0	0,78 ± 0	0,78 ± 0	0,78 ± 0	0,78
LR	0,83 ± 0,03	0,67 ± 0,18	0,83 ± 0,1	0,8 ± 0,1	0,83 ± 0,09	0,79
KNN1	0,78 ± 0,01	0,78 ± 0,02	0,78 ± 0,01	0,83 ± 0,07	0,8 ± 0,05	0,79
KNN9	0,78 ± 0	0,78 ± 0	0,78 ± 0	0,78 ± 0	0,78 ± 0,01	0,78
KNN13	0,78 ± 0,01	0,75 ± 0,02	0,75 ± 0,02	0,8 ± 0,09	0,86 ± 0,04	0,79
KNN21	0,78 ± 0	0,78 ± 0	0,78 ± 0	0,78 ± 0	0,78 ± 0	0,78
KNN25	0,78 ± 0	0,75 ± 0,02	0,78 ± 0	0,8 ± 0,09	0,78 ± 0	0,78
Média	0,78	0,76	0,78	0,81	0,81	

A observação dos valores de especificidade, mostrados na Tabela 44, permite inferir que alguns modelos no geral apresentam dificuldades maiores em acertar a classe OME. Destaca-se que em média, quando os atributos considerados nos modelos relacionam apenas informações no domínio da frequência, os resultados de especificidade são piores.

Tabela 44 Valores de especificidade teste, grupamento B, análise 1 – 100 Hz.

Modelos	Todos	Fre	Freq + D	Temp	Temp + D	Média
SVM 1	1 ± 0	0 ± 0	1 ± 0	0,5 ± 0,5	0,5 ± 0	0,75
SVM 2	1 ± 0	1 ± 0	1 ± 0	0,5 ± 0,35	0,5 ± 0,35	0,80
SVM 3	1 ± 0	1 ± 0	1 ± 0	0,5 ± 0,08	0,5 ± 0,43	0,80
LR	0,33 ± 0,1	0 ± 0,28	0,33 ± 0,24	0,25 ± 0,13	0,33 ± 0,18	0,25
KNN1	-	-	-	0,42 ± 0,42	0,5 ± 0,4	0,18
KNN13	-	-	-	0,25 ± 0,22	0,5 ± 0,1	0,15
KNN25	-	-	-	0,25 ± 0,22	0 ± 0	0,13
Média	0,56	0,33	0,56	0,38	0,40	

Por fim, na Tabela 45, estão os valores de F-macro, variando entre 0,31 e 0,68, com média geral igual 0,47. Nota-se que os modelos SVM2 e SVM3 foram os que tiveram média de F-macro maior em relação aos outros modelos. Além disso, novamente os atributos no tempo indicam melhores resultados uma vez que os valores de média obtidos são maiores comparados aos demais grupos de atributos.

Tabela 45 Valores de F-macro teste, grupamento B, análise 1 – 100 Hz.

Modelos	Todos	Fre	Freq + D	Temp	Temp + D	Média
SVM 1	0,44 ± 0,26	0,44 ± 0	0,44 ± 0,18	0,44 ± 0,22	0,44 ± 0,12	0,44
SVM 2	0,44 ± 0,18	0,44 ± 0,18	0,44 ± 0,18	0,68 ± 0,15	0,68 ± 0,18	0,53
SVM 3	0,44 ± 0,26	0,44 ± 0,18	0,44 ± 0,18	0,68 ± 0,05	0,68 ± 0,16	0,53
SVM 15	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44
LR	0,58 ± 0,08	0,31 ± 0,24	0,58 ± 0,18	0,5 ± 0,13	0,58 ± 0,17	0,51
KNN1	0,44 ± 0,02	0,44 ± 0,03	0,44 ± 0,02	0,58 ± 0,18	0,5 ± 0,18	0,48
KNN9	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0,02	0,44
KNN13	0,44 ± 0,02	0,4 ± 0,03	0,4 ± 0,03	0,5 ± 0,16	0,68 ± 0,13	0,48
KNN21	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44 ± 0	0,44
KNN25	0,44 ± 0	0,4 ± 0,03	0,44 ± 0	0,5 ± 0,16	0,44 ± 0	0,44
Média	0,45	0,42	0,45	0,52	0,53	

7.3.3 Grupamento C: Óbito Clínico x Óbito por Morte Encefálica

Esse grupamento é formado por 25 registros EEG com desfecho de OC e 8 registros EEG com desfecho de OME. Assim como no grupamento B, nesse caso foram escolhidos de maneira aleatória os registros EEG com desfecho de OC, uma vez que a quantidade desses dados disponível é igual a 51. Ainda mantendo a divisão de 2/3 dos dados dedicados para treino e 1/3 dos dados voltados para teste, os 55 modelos prognósticos foram criados com resultados de acurácia de treino mostrados na Tabela 46 e valores de F-macro indicados na Tabela 47.

Observando os valores de acurácia, nota-se que a variação desses índices gira em torno de 0,56 a 0,82. Já os valores de F-macro variam entre 0,66 a 0,88. Para as duas medidas nota-se que a média geral dos valores obtidos, considerando apenas atributos no domínio da frequência, são maiores que os demais modelos.

Tabela 46 Valores de acurácia treino, grupamento C, análise 1 – 100 Hz.

(continua)

Modelos	Todos	Fre	Freq + D	Temp	Temp + D
SVM 1	0,73 ± 0,04	0,78 ± 0,05	0,73 ± 0,03	0,73 ± 0,05	0,73 ± 0,04
SVM 2	0,78 ± 0,02	0,82 ± 0,04	0,82 ± 0,04	0,69 ± 0,06	0,69 ± 0,05
SVM 3	0,78 ± 0,03	0,78 ± 0,03	0,78 ± 0,03	0,69 ± 0,08	0,73 ± 0,05
SVM 4	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0
SVM 5	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0
SVM 6	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0
SVM 7	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0
SVM 8	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0
SVM 9	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0
SVM 10	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0
SVM 11	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0
SVM 12	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0
SVM 13	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0
SVM 14	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0,01	0,73 ± 0
SVM 15	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0,01	0,73 ± 0
SVM 16	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0,02	0,73 ± 0,01
SVM 17	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0
SVM 18	0,73 ± 0,03	0,69 ± 0,03	0,69 ± 0,02	0,73 ± 0	0,73 ± 0
SVM 19	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0
SVM 20	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0
SVM 21	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0
SVM 22	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0
SVM 23	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0
SVM 24	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0
LR	0,65 ± 0,12	0,69 ± 0,09	0,69 ± 0,08	0,60 ± 0,11	0,56 ± 0,09
KNN 1	0,65 ± 0,06	0,65 ± 0,06	0,69 ± 0,05	0,65 ± 0,09	0,65 ± 0,10
KNN 2	0,65 ± 0,06	0,65 ± 0,06	0,69 ± 0,05	0,65 ± 0,09	0,65 ± 0,10
KNN 3	0,73 ± 0,05	0,73 ± 0,04	0,73 ± 0,05	0,73 ± 0,05	0,73 ± 0,07
KNN 4	0,73 ± 0,05	0,73 ± 0,04	0,73 ± 0,05	0,69 ± 0,06	0,69 ± 0,07
KNN 5	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0
KNN 6	0,73 ± 0,02	0,73 ± 0,02	0,73 ± 0,02	0,73 ± 0	0,73 ± 0,01
KNN 7	0,78 ± 0,07	0,73 ± 0,04	0,78 ± 0,05	0,65 ± 0,06	0,60 ± 0,06
KNN 8	0,78 ± 0,07	0,73 ± 0,04	0,78 ± 0,05	0,65 ± 0,06	0,60 ± 0,06
KNN 9	0,78 ± 0,05	0,78 ± 0,06	0,78 ± 0,06	0,78 ± 0,04	0,73 ± 0,05
KNN 10	0,78 ± 0,05	0,78 ± 0,07	0,78 ± 0,06	0,73 ± 0,04	0,73 ± 0,05

Tabela 46 Valores de acurácia treino, grupamento C, análise 1 – 100 Hz.

(conclusão)

Modelos	Todos	Fre	Freq + D	Temp	Temp + D
KNN 11	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0
KNN 12	0,73 ± 0,02	0,73 ± 0,02	0,73 ± 0,02	0,73 ± 0,02	0,73 ± 0,03
KNN 13	0,78 ± 0,05	0,78 ± 0,08	0,78 ± 0,05	0,65 ± 0,08	0,60 ± 0,07
KNN 14	0,78 ± 0,05	0,78 ± 0,08	0,78 ± 0,05	0,65 ± 0,08	0,60 ± 0,07
KNN 15	0,73 ± 0	0,73 ± 0	0,73 ± 0,01	0,73 ± 0,04	0,73 ± 0,04
KNN 16	0,73 ± 0	0,73 ± 0	0,73 ± 0,01	0,73 ± 0,04	0,73 ± 0,04
KNN 17	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0
KNN 18	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0
KNN 19	0,56 ± 0,07	0,73 ± 0,17	0,60 ± 0,07	0,73 ± 0,15	0,60 ± 0,12
KNN 20	0,56 ± 0,07	0,73 ± 0,17	0,60 ± 0,07	0,73 ± 0,15	0,60 ± 0,12
KNN 21	0,65 ± 0,09	0,73 ± 0,04	0,65 ± 0,07	0,73 ± 0,04	0,69 ± 0,07
KNN 22	0,65 ± 0,09	0,73 ± 0,04	0,65 ± 0,07	0,73 ± 0,04	0,69 ± 0,07
KNN 23	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0
KNN 24	0,73 ± 0,02	0,73 ± 0,01	0,73 ± 0,04	0,73 ± 0	0,73 ± 0,02
KNN 25	0,73 ± 0	0,78 ± 0,08	0,73 ± 0	0,65 ± 0,08	0,73 ± 0
KNN 26	0,73 ± 0	0,78 ± 0,08	0,73 ± 0	0,65 ± 0,08	0,73 ± 0

Tabela 47 Valores de acurácia treino, grupamento C, análise 1 – 100 Hz.

(continua)

Modelos	Todos	Fre	Freq + D	Temp	Temp + D
KNN 27	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0,04	0,73 ± 0
KNN 28	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0,04	0,73 ± 0
KNN 29	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0
KNN 30	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0	0,73 ± 0
SVM 1	0,84 ± 0,02	0,86 ± 0,02	0,84 ± 0,02	0,84 ± 0,03	0,84 ± 0,03
SVM 2	0,86 ± 0,01	0,88 ± 0,02	0,88 ± 0,02	0,81 ± 0,04	0,8 ± 0,04
SVM 3	0,86 ± 0,01	0,86 ± 0,02	0,86 ± 0,02	0,81 ± 0,05	0,82 ± 0,03
SVM 4	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0
SVM 5	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0
SVM 6	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0
SVM 7	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0
SVM 8	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0
SVM 9	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0
SVM 10	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0
SVM 11	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0
SVM 12	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0
SVM 13	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0
SVM 14	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0,00	0,85 ± 0
SVM 15	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0,01	0,85 ± 0
SVM 16	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0,01	0,85 ± 0,00

Tabela 47 Valores de acurácia treino, grupamento C, análise 1 – 100 Hz.

(conclusão)

Modelos	Todos	Fre	Freq + D	Temp	Temp + D
SVM 17	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0
SVM 18	0,84 ± 0,01	0,82 ± 0,01	0,82 ± 0,01	0,85 ± 0	0,85 ± 0
SVM 19	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0
SVM 20	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0
SVM 21	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0
SVM 22	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0
SVM 23	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0
SVM 24	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0
LR	0,78 ± 0,09	0,81 ± 0,07	0,8 ± 0,06	0,72 ± 0,09	0,66 ± 0,09
KNN 1	0,76 ± 0,04	0,78 ± 0,06	0,78 ± 0,03	0,77 ± 0,07	0,77 ± 0,08
KNN 2	0,76 ± 0,04	0,78 ± 0,06	0,78 ± 0,03	0,77 ± 0,07	0,77 ± 0,08
KNN 3	0,84 ± 0,02	0,85 ± 0,02	0,85 ± 0,03	0,84 ± 0,03	0,84 ± 0,04
KNN 4	0,84 ± 0,02	0,85 ± 0,02	0,85 ± 0,03	0,82 ± 0,03	0,82 ± 0,04
KNN 5	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0
KNN 6	0,85 ± 0,01	0,85 ± 0,01	0,85 ± 0,01	0,85 ± 0	0,85 ± 0,00
KNN 7	0,84 ± 0,05	0,82 ± 0,03	0,85 ± 0,03	0,76 ± 0,05	0,72 ± 0,04
KNN 8	0,84 ± 0,05	0,82 ± 0,03	0,85 ± 0,03	0,76 ± 0,05	0,72 ± 0,04
KNN 9	0,87 ± 0,03	0,87 ± 0,03	0,87 ± 0,03	0,86 ± 0,02	0,85 ± 0,02
KNN 10	0,86 ± 0,03	0,87 ± 0,04	0,87 ± 0,04	0,83 ± 0,02	0,83 ± 0,03
KNN 11	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0
KNN 12	0,85 ± 0,01	0,85 ± 0,01	0,85 ± 0,01	0,84 ± 0,01	0,85 ± 0,01
KNN 13	0,86 ± 0,03	0,85 ± 0,05	0,85 ± 0,03	0,77 ± 0,06	0,74 ± 0,06
KNN 14	0,86 ± 0,03	0,85 ± 0,05	0,85 ± 0,03	0,77 ± 0,06	0,74 ± 0,06
KNN 15	0,85 ± 0	0,85 ± 0	0,85 ± 0,00	0,85 ± 0,02	0,85 ± 0,02
KNN 16	0,85 ± 0	0,85 ± 0	0,85 ± 0,00	0,84 ± 0,02	0,85 ± 0,03
KNN 17	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0
KNN 18	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0
KNN 19	0,66 ± 0,08	0,85 ± 0,22	0,70 ± 0,06	0,85 ± 0,21	0,75 ± 0,15
KNN 20	0,66 ± 0,08	0,85 ± 0,22	0,70 ± 0,06	0,85 ± 0,21	0,75 ± 0,15
KNN 21	0,78 ± 0,08	0,85 ± 0,03	0,78 ± 0,05	0,85 ± 0,03	0,8 ± 0,05
KNN 22	0,78 ± 0,08	0,85 ± 0,03	0,78 ± 0,05	0,85 ± 0,03	0,8 ± 0,05
KNN 23	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0
KNN 24	0,85 ± 0,02	0,85 ± 0,00	0,84 ± 0,03	0,85 ± 0	0,85 ± 0,02
KNN 25	0,85 ± 0	0,85 ± 0,05	0,85 ± 0	0,77 ± 0,06	0,85 ± 0
KNN 26	0,85 ± 0	0,85 ± 0,05	0,85 ± 0	0,77 ± 0,06	0,85 ± 0
KNN 27	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0,02	0,85 ± 0
KNN 28	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,84 ± 0,02	0,85 ± 0
KNN 29	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0
KNN 30	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0	0,85 ± 0

Como tem sido feito para as demais análises, os dez melhores modelos foram testados e os valores de acurácia, sensibilidade, especificidade, e F-macro foram calculados, como

mostrado na Tabela 48 a Tabela 51, respectivamente. Considerando os resultados para a medida acurácia, nota-se que eles variam entre 0,50 e 0,80. Os modelos que utilizaram LR como classificador foram os que apresentaram pior desempenho em relação à essa métrica. Nota-se ainda que quando analisados apenas os atributos no domínio da frequência, há tendência desses valores serem mais elevados.

Os resultados de sensibilidade e especificidade médios estão em cerca de 0,80 e 0,11 respectivamente. Os baixos índices de especificidade estão relacionados à dificuldade do problema uma vez que os desfechos são óbitos, e ainda a quantidade de registros da classe OME é de apenas 24% do total dos dados.

Tabela 48 Valores de acurácia teste, grupamento C, análise 1 – 100 Hz.

Modelos	Todos	Fre	Freq + D	Temp	Temp + D	Média
SVM 1	0,7 ± 0,1	0,7 ± 0,11	0,7 ± 0,11	0,8 ± 0,09	0,7 ± 0,14	0,72
SVM 2	0,8 ± 0,07	0,8 ± 0,07	0,8 ± 0,07	0,7 ± 0	0,7 ± 0	0,76
SVM 3	0,8 ± 0,05	0,8 ± 0,05	0,8 ± 0,05	0,7 ± 0,12	0,7 ± 0,07	0,76
SVM 15	0,8 ± 0	0,8 ± 0	0,8 ± 0	0,8 ± 0	0,8 ± 0	0,80
LR	0,6 ± 0,12	0,8 ± 0,12	0,7 ± 0,13	0,5 ± 0,09	0,5 ± 0,16	0,62
KNN1	0,8 ± 0,05	0,8 ± 0,05	0,8 ± 0,05	0,6 ± 0,07	0,7 ± 0,07	0,74
KNN9	0,8 ± 0,05	0,8 ± 0	0,8 ± 0,05	0,8 ± 0	0,8 ± 0	0,80
KNN13	0,8 ± 0,07	0,8 ± 0,07	0,8 ± 0,07	0,7 ± 0,11	0,6 ± 0,11	0,74
KNN21	0,8 ± 0	0,8 ± 0	0,8 ± 0	0,8 ± 0	0,8 ± 0	0,80
KNN25	0,8 ± 0	0,8 ± 0,07	0,8 ± 0	0,7 ± 0,11	0,8 ± 0	0,78
Média	0,77	0,79	0,78	0,71	0,71	

Tabela 49 Valores de sensibilidade teste, grupamento C, análise 1 – 100 Hz.

Modelos	Todos	Fre	Freq + D	Temp	Temp + D	Média
SVM 1	0,78 ± 0,06	0,78 ± 0,06	0,78 ± 0,06	0,8 ± 0,06	0,78 ± 0,08	0,78
SVM 2	0,8 ± 0,05	0,8 ± 0,05	0,8 ± 0,05	0,86 ± 0,06	0,78 ± 0,06	0,81
SVM 3	0,8 ± 0,01	0,8 ± 0,01	0,8 ± 0,01	0,8 ± 0,06	0,78 ± 0,06	0,80
SVM 15	0,8 ± 0	0,8 ± 0	0,8 ± 0	0,8 ± 0	0,8 ± 0	0,80
LR	0,86 ± 0,11	1 ± 0,14	0,86 ± 0,13	0,75 ± 0,07	0,75 ± 0,09	0,84
KNN1	0,8 ± 0,01	0,8 ± 0,01	0,8 ± 0,01	0,78 ± 0,12	0,78 ± 0,12	0,79
KNN9	0,8 ± 0,01	0,8 ± 0	0,8 ± 0,01	0,8 ± 0	0,8 ± 0	0,80
KNN13	0,8 ± 0,02	0,8 ± 0,02	0,8 ± 0,02	0,78 ± 0,04	0,83 ± 0,05	0,80
KNN21	0,8 ± 0	0,8 ± 0	0,8 ± 0	0,8 ± 0	0,8 ± 0	0,80
KNN25	0,8 ± 0	0,8 ± 0,02	0,8 ± 0	0,78 ± 0,04	0,8 ± 0	0,80
Média	0,80	0,82	0,80	0,79	0,79	

Tabela 50 Valores de especificidade teste, grupamento C, análise 1 – 100 Hz.

Modelos	Todos	Fre	Freq + D	Temp	Temp + D	Média
SVM 1	$0 \pm 0,5$	$0 \pm 0,58$	$0 \pm 0,58$	$0,25 \pm 0,5$	$0 \pm 0,71$	0,05
SVM 2	$0,5 \pm 0,71$	$0,5 \pm 0,71$	$0,5 \pm 0,71$	$0,33 \pm 0,24$	$0 \pm 0,24$	0,37
SVM 3	0 ± 0	0 ± 0	0 ± 0	$0,2 \pm 0,25$	$0 \pm 0,28$	0,04
SVM 15	0 ± 0	0 ± 0	0 ± 0	0 ± 0	0 ± 0	-
LR	$0,33 \pm 0,25$	$0,5 \pm 0,27$	$0,33 \pm 0,26$	$0 \pm 0,14$	$0 \pm 0,1$	0,23
KNN1	0 ± 0	0 ± 0	0 ± 0	$0 \pm 0,21$	$0 \pm 0,24$	0,00
KNN9	0 ± 0	0 ± 0	0 ± 0	0 ± 0	0 ± 0	0,00
KNN13	0 ± 0	0 ± 0	0 ± 0	$0 \pm 0,19$	$0,25 \pm 0,22$	0,05
KNN21	0 ± 0	0 ± 0	0 ± 0	0 ± 0	0 ± 0	-
KNN25	0 ± 0	0 ± 0	0 ± 0	$0 \pm 0,19$	0 ± 0	0,00
Média	0,12	0,14	0,12	0,11	0,04	

Com variação entre 0,38 e 0,69, os valores de F-macro, mostrados na Tabela 51, indicam a dificuldade dos modelos em acertar ambas as classes. Existe tendência em que os acertos ocorram pra classe majoritária, contudo, nota-se que alguns modelos conseguem resultados médios melhores de F-macro, como ocorre nos modelos gerados pelo classificador LR.

Tabela 51 Valores de F-macro teste, grupamento C, análise 1 – 100 Hz.

Modelos	Todos	Fre	Freq + D	Temp	Temp + D	Média
SVM 1	$0,41 \pm 0,2$	$0,41 \pm 0,2$	$0,41 \pm 0,2$	$0,44 \pm 0,22$	$0,41 \pm 0,28$	0,42
SVM 2	$0,44 \pm 0,18$	$0,44 \pm 0,18$	$0,44 \pm 0,18$	$0,6 \pm 0,13$	$0,41 \pm 0,13$	0,47
SVM 3	$0,44 \pm 0,02$	$0,44 \pm 0,02$	$0,44 \pm 0,02$	$0,45 \pm 0,17$	$0,41 \pm 0,15$	0,44
SVM 15	$0,44 \pm 0$	$0,44 \pm 0$	$0,44 \pm 0$	$0,44 \pm 0$	$0,44 \pm 0$	0,44
LR	$0,58 \pm 0,17$	$0,69 \pm 0,18$	$0,6 \pm 0,21$	$0,38 \pm 0,08$	$0,38 \pm 0,09$	0,52
KNN1	$0,44 \pm 0,02$	$0,44 \pm 0,02$	$0,44 \pm 0,02$	$0,41 \pm 0,1$	$0,41 \pm 0,14$	0,43
KNN9	$0,44 \pm 0,02$	$0,44 \pm 0$	$0,44 \pm 0,02$	$0,44 \pm 0$	$0,44 \pm 0$	0,44
KNN13	$0,44 \pm 0,02$	$0,44 \pm 0,02$	$0,44 \pm 0,02$	$0,41 \pm 0,1$	$0,52 \pm 0,12$	0,45
KNN21	$0,44 \pm 0$	$0,44 \pm 0$	$0,44 \pm 0$	$0,44 \pm 0$	$0,44 \pm 0$	0,44
KNN25	$0,44 \pm 0$	$0,44 \pm 0,02$	$0,44 \pm 0$	$0,41 \pm 0,1$	$0,44 \pm 0$	0,44
Média	0,46	0,47	0,46	0,44	0,43	

7.4 Discussão

Assim como realizado no Capítulo 6, é importante verificar o comportamento geral dos tipos de modelos testados, para associar classificadores com bons índices de medidas de desempenho. Na Figura 7 é possível identificar aqueles modelos com piores desempenhos médios. O modelo KNN21 apresentou mediana geral inferior a 0,50 sendo considerado o pior

modelo para a análise do sinal EEG considerando frequências de 1 a 100 Hz. Já o modelo SVM1 foi o que apresentou mediana geral de medidas de desempenho mais elevada, em torno de 0,67. Considerando comparações estatísticas, nota-se que os modelos gerados a partir de classificadores de LR e KNN são diferentes dos modelos gerados a partir do classificador SVM (valor- $p < 0,05$).




Figura 7 Valores obtidos nas medidas de desempenho conforme o tipo de modelo testado, análise 1 – 100 Hz. Fonte: autoria própria.

Para verificar se houve alguma combinação de atributos de entradas dos modelos com comportamento médio melhor, a Figura 8 foi elaborada. Trata-se também de gráficos contendo boxplots com o resumo geral dos valores de medidas de desempenho obtidos considerando todos os grupamentos analisados, bem como todos os modelos. No geral nota-se que aqueles modelos cujo atributos de entrada estavam apenas no domínio do tempo apresentaram medianas abaixo de 0,60 (valor- $p < 0,05$). Já quando considera-se todos os atributos e as demais combinações de atributos na frequência os valores de mediana são em torno de 0,60. Não há na literatura analisada estudos que evidenciam melhora ou piora de modelos prognósticos a partir de análises dos ritmos gama e supergama do sinal EEG.




Figura 8 Comportamento estatístico dos modelos considerando as combinações de atributos, análise 1 – 100 Hz. Fonte: autoria própria.

Capítulo 8

COMPARAÇÕES ESTATÍSTICAS: ANALISAR SINAL EEG DE 1 – 100 Hz PRODUZ MELHORA NOS RESULTADOS?

Nesse capítulo serão comparados os resultados obtidos nas análises de modelos gerados por sinais EEG em frequências de 1 a 30 Hz com sinais EEG em frequências de 1 a 100 Hz

8.1 Introdução

As análises dos modelos prognósticos gerados a partir de informações do sinal EEG, especificamente para frequências clínicas, possibilitou que fossem obtidos resultados médios dos valores de acurácia, sensibilidade, especificidade e F-macro. Na Tabela 52 estão os valores médios das medidas de desempenho acurácia, sensibilidade, especificidade e F-macro considerando os dez melhores modelos prognósticos, independentemente dos atributos de entrada considerados e dos classificadores utilizados nos modelos. Nota-se que, em termos de acurácia, o grupamento A foi o mais complexo na classificação. Considerando os valores obtidos de F-macro, nota-se que o grupamento B, que aborda os desfechos ativo e OME, apresentou valor médio maior que os demais grupamento.

Tabela 52 Desempenho médio $\pm$ desvio padrão obtidos nos grupamento A, B e C, análise 1 – 30 Hz.

Grupamentos	Acurácia	Sensibilidade	Especificidade	F-macro
Grupamento A	0,56 $\pm$ 0,07	0,38 $\pm$ 0,14	0,64 $\pm$ 0,06	0,48 $\pm$ 0,09
Grupamento B	0,71 $\pm$ 0,12	0,76 $\pm$ 0,08	0,57 $\pm$ 0,3	0,58 $\pm$ 0,16
Grupamento C	0,74 $\pm$ 0,09	0,8 $\pm$ 0,03	0,26 $\pm$ 0,25	0,49 $\pm$ 0,09

A fim de resumir os valores médios das medidas de desempenho obtidas para os dez melhores modelos em cada grupamento observado no Capítulo 7, a Tabela 53 foi elaborada. A partir dessa tabela é possível conhecer de modo geral como os modelos tem se comportado levando em conta as quatro medidas aqui observadas: acurácia, sensibilidade, especificidade e F-macro, quando considerado o sinal EEG em frequências de 1 a 100 Hz. Em termos de acurácia, no geral, o grupamento A foi o que apresentou maiores dificuldades em classificar os desfechos a partir do sinal EEG. Contudo, observando a medida F-macro, nota-se que para os três grupamentos o valor médio obtido foi menor que 0,50, o que corrobora a ideia da dificuldade em gerar modelos capazes de atingir índices maiores de acertos em classificações.

Tabela 53 Desempenho médio $\pm$ desvio padrão obtidos nos grupamento A, B e C, análise 1 – 100 Hz.

Grupamentos	Acurácia	Sensibilidade	Especificidade	F-macro
Grupamento A	0,53 $\pm$ 0,08	0,52 $\pm$ 0,1	0,56 $\pm$ 0,12	0,49 $\pm$ 0,12
Grupamento B	0,75 $\pm$ 0,09	0,79 $\pm$ 0,05	0,39 $\pm$ 0,35	0,49 $\pm$ 0,12
Grupamento C	0,75 $\pm$ 0,09	0,8 $\pm$ 0,05	0,19 $\pm$ 0,3	0,47 $\pm$ 0,1

Como observado no Capítulo 4, os valores de acurácia e AUC obtidos no geral são elevados. Contudo, diversos fatores podem afetar esse cálculo. Dos 19 estudos relatados na literatura, 11 não relatam segmentação entre dados de treino e de teste, o que pode influenciar nos resultados de acurácia e AUC medidos. Comparando os valores obtidos pelos estudos que deixam claro separação dos dados com os aqui obtidos, nota-se que apenas um deles utiliza classificador SVM e LR como classificador (WANG et al., 2020), sendo o mais comum por eles utilizado o classificador floresta aleatória (AMORIM et al., 2019; MÜLLER et al., 2020; NAGARAJ et al., 2018; TJEPKEMA-CLOOSTERMANS et al., 2017). Observa-se que em termos de acurácia o valor médio obtido foi em torno de 0,86 na literatura, para o bom prognóstico versus 0,64 obtido no presente estudo, tanto considerando apenas ritmos clínicos quanto considerando ritmos clínicos e rápidos simultaneamente. Essa alta variação pode estar associada a diversas situações como: a) Quantidade de dados baixa; b) Componentes desbalanceados nas classes; c) Tipo de quantificação do sinal EEG. Com relação aos valores de sensibilidade e especificidade obtidos por tais estudos na literatura, a média foi de 0,74 e 0,80

respectivamente, confrontados com os valores médios aqui obtidos iguais a 0,66 e 0,48 respectivamente.

É comum na literatura abordagens em sinais EEG nos ritmos clínicos, ou seja, variando de delta a beta. Estudos que avaliam esse sinal em ritmos com frequências maiores, como no caso dos ritmos gama e supergama ainda são escassos. Nesse estudo foram realizadas diversas análises considerando os sinais EEG em ambas situações. Portanto, nesse capítulo os resultados obtidos em cada grupamento serão comparados utilizando ferramentas estatísticas.

8.2 Comparação para o grupamento A: Ativo x OC

Nas duas situações de análise, aqui denominadas baixa frequência (sinais EEG que contém informações de 1 a 30 Hz) e alta frequência (sinais EEG que contém informações de 1 a 100 Hz), o grupamento A envolve modelos prognósticos cujas duas classes são os desfechos ativo e OC. O interessante nessa seção é verificar se, na presença de sinais EEG em alta frequência, o comportamento dos modelos é diferente estatisticamente quando comparado ao comportamento obtido utilizando sinais EEG em frequências de 1 a 30 Hz. Para isso, teste de Mann Whitney foi utilizado em cada situação possível de comparação. É bom lembrar nesse momento que tem-se:

- i. Quatro medidas de desempenho calculadas: Acurácia, Sensibilidade, Especificidade e F-macro.
- ii. Cinco combinações diferentes de atributos de entradas: Todos os atributos, Apenas atributos no domínio da frequência, Atributos no domínio da frequência adicionadas informações demográficas dos pacientes, Apenas atributos no domínio do tempo, e por fim Atributos no tempo adicionadas informações demográficas.

Foram consideradas apenas as medidas de desempenho acurácia e F-macro para esse tipo de comparação. Portanto, para cada medida e cada combinação de atributos de entrada, foram comparados os valores de desempenho obtidos na situação de “baixa frequência” versus situação de “alta frequência”. Do total de 50 comparações realizadas considerando a medida acurácia, apenas os modelos SVM15, KNN9, KNN21 e KNN25 apresentaram pelo menos uma situação comparada resultando em valor-p significativo, ou seja, menor que 5%. Já considerando as 50 comparações feitas para a medida F-macro, os modelos SVM1, SVM15, KNN21 e KNN25 apresentaram pelo menos uma das comparações possíveis diferenças significativas.

Objetivando demonstrar graficamente os comportamentos obtidos nas duas situações de comparação, bem como, o comportamento verificado tanto para a medida acurácia quanto para F-macro, a Figura 9 foi elaborada. Nela encontram-se dois gráficos a) e b), com comportamentos das medidas de desempenho acurácia e F-macro respectivamente, considerando os melhores modelos prognósticos bem como as combinações de atributos de entradas. Considerando os modelos SVM2, SVM3, LR e KNN1, os valores obtidos nos processamentos de baixa frequência são estatisticamente semelhantes aos medidos na situação de alta frequência (valor- $p > 0,05$; $\alpha = 95\%$). Já para os demais modelos o que fica entendido é que analisar os sinais EEG de 1 a 100 Hz provoca alteração nos resultados tanto de acurácia, quanto de F-macro. Em torno de 20 e 26% das comparações realizadas entre os resultados de baixa versus de alta frequência foram estatisticamente diferentes (valor- $p < 0,05$; $\alpha = 95\%$) para a medida de acurácia e a medida de F-macro respectivamente. Os modelos SVM15 e KNN21 foram os que mais apresentaram diferenças significativas apontando que os modelos gerados com atributos de EEG de 1 a 30 Hz são melhores que quando considerado o sinal EEG de 1 a 100 Hz.




Figura 9 Medidas de desempenho gerais do grupamento A (ativo x OC) nas situações de baixa frequência (barras 1, 3, 5, 7 e 9) versus alta frequência (barras 2, 4, 6, 8 e 10). a) Valores de acurácia. b) Valores de F-macro.

8.3 Comparação para o grupamento B: Ativo x OME

A mesma análise estatística foi feita considerando o grupamento B, em que os desfechos considerados foram ativo e óbito por morte encefálica. A Figura 10 tem estrutura semelhante à Figura 9, contudo os modelos representados nessa são diferentes uma vez que a análise estatística apontou que os modelos que apresentaram diferença significativa foram SVM2, SVM3, SVM15, KNN1, KNN9 e KNN21 para a medida acurácia, e todos com exceção dos modelos LR e KNN1 para a medida F-macro. Considerando a acurácia, apenas quatro dos dez

modelos analisados não tiveram diferença estatística significativa (valor- $p > 0,05$; $\alpha = 95\%$). Nota-se que em torno de 40% das comparações realizadas foram estatisticamente diferentes. Analisando os valores de F-macro tanto para os modelos gerados a partir de sinais EEG com frequências de 1 a 30 Hz quanto para sinais EEG com frequências de 1 a 100 Hz nota-se que cerca de 48% das comparações são estatisticamente diferentes (valor- $p < 0,05$; $\alpha = 95\%$).

Os modelos SVM15 e KNN21 apresentaram diferença estatística em todas as comparações, tanto para acurácia quanto para F-macro. Observando esses dois modelos, nota-se que os valores medianos de cada uma dessas medidas de desempenho foi maior nas situações em que o sinal EEG considerado na análise foi o de 1 a 100 Hz (alta frequência). Para esse grupamento portanto, foi considerável a presença dos ritmos gama e supergama no sucesso dos modelos prognósticos implementados.




Figura 10 Medidas de desempenho gerais do grupamento B (ativo x OME) nas situações de baixa frequência (barras 1, 3, 5, 7 e 9) versus alta frequência (barras 2, 4, 6, 8 e 10). a) Valores de acurácia. b) Valores de F-macro.

8.4 Comparação para o grupamento C: OC x OME

Considerando agora o grupamento C, composto pelos dois desfechos de óbitos, OC e OME, a Figura 11 foi elaborada com a mesma estrutura da Figura 9. Nota-se que, observando os valores de p obtidos a partir dos testes de comparações, no caso da acurácia apenas 12% das comparações foram significativamente diferentes, e para F-macro essa diferença estatística foi de 8%. Esse foi o grupamento com mais semelhança entre os resultados obtidos considerando o sinal EEG de 1 a 30 Hz versus sinal EEG de 1 a 100 Hz. Tanto os modelos gerados para sinais EEG de baixa frequência, quanto aqueles compostos por atributos em alta frequência tendem a apresentar o mesmo comportamento, seja em relação a acurácia, seja considerando a F-macro.




Figura 11 Medidas de desempenho gerais do grupamento C (OC x OME) nas situações de baixa frequência (barras 1, 3, 5, 7 e 9) versus alta frequência (barras 2, 4, 6, 8 e 10). a) Valores de acurácia. b) Valores de F-macro.

8.5 Conclusão

Considerando a Figura 9, referente as classes ativo e OC, e as informações que ela apresenta é notável que, tanto para acurácia quanto para F-macro, não são evidenciadas diferenças significativas entre análise do sinal EEG de 1 – 30 Hz e análise desse sinal de 1 – 100 Hz. O que pode ser constatado é que, levando em consideração apenas as comparações em que o valor de p obtido foi menor que 0,05 (indicando diferença estatística significativa), os valores de mediana de acurácia e F-macro são maiores quando consideradas informações apenas de 1 – 30 Hz do sinal EEG.

Já com relação a Figura 11, que trata-se das classes OC e OME, é possível perceber que no geral, não há diferenças quando analisa-se o sinal EEG em baixa frequência ou em alta frequência. Das poucas comparações estatísticas que resultaram em valor de p menor que 0,05, para acurácia a mediana foi maior quando considerou-se EEG de 1 – 100 Hz. Em contrapartida, para a medida F-macro a mediana obtida foi maior quando considerou-se EEG de 1 – 30 Hz apenas.

A Figura 10 que trouxe a análise das classes ativo e OME foi a que evidenciou maiores diferenças significativas quando comparadas as contribuições do sinal EEG. Nota-se que para acurácia foi nítido que acrescentar gama e supergama na análise do sinal EEG resultou na melhora de desempenho dos modelos prognósticos de modo geral. Em relação à medida F-macro não é possível constatar melhora ou não com a inserção desses dois ritmos nas análises.

Capítulo 9

CONCLUSÃO, CONTRIBUIÇÕES, TRABALHOS FUTUROS

Esse é o capítulo de finalização do trabalho com a conclusão final, contribuições da autora e trabalhos futuros.

9.1 Conclusão Final

O registro do sinal EEG em pacientes comatosos dispõe de desafios principalmente relacionados aos variados motivos pelos quais os pacientes encontram-se no estado comatoso. O presente estudo analisou sinais EEG de pacientes comatosos e a partir de informações quantitativas de processamento digital de sinais estipulou a criação de modelos prognósticos, utilizando tanto conhecimentos em aprendizado de máquina quanto conhecimentos estatísticos, a fim de tentar identificar desfechos favoráveis ou não desse indivíduo.

A primeira abordagem desse estudo foi segmentar os sinais EEG em dois desfechos: ativo e OC. Foram então observados os comportamentos gerais obtidos pelos modelos criados, tanto quando considerou-se sinais EEG de 1 a 30 Hz, como também quando foram consideradas informações do sinal EEG 1 a 100 Hz. No geral, inserir informações acima de 30 Hz para essa análise em especial não agregou melhora ou piora no comportamento dos modelos gerados. Os melhores valores medianos de acurácia e F-macro obtidos nesse grupamento foram iguais a 0,62 e 0,57 respectivamente.

A segunda análise considerou os desfechos ativo e OME, também para sinais EEG de 1 – 30 Hz e sinais EEG de 1 – 100 Hz. Notou-se que, para essa abordagem, inserir informações de sinal EEG acima de 30 Hz (ritmos gama e supergama) influenciou estatisticamente na

melhora dos resultados de acurácia dos modelos prognósticos obtidos. Os melhores valores medianos tanto de acurácia quanto de F-macro obtidos nessa segunda observação foram de 0,78 e 0,68 respectivamente. Além disso, notou-se que quando foram considerados atributos no domínio do tempo mais informações demográficas do paciente (como nível de Glasgow ou RASS e etiologia do coma) o desempenho de F-macro geral foi melhor que o desempenho quando considerados todos os atributos.

A terceira forma de agrupar os pacientes com relação aos desfechos levou em consideração as classes OC e OME. A análise estatística inferiu que não houve diferenças significativas quando acrescentou-se informações acima de 30 Hz nas análises do sinal EEG. Os melhores valores de acurácia e F-macro obtidos foram iguais a 0,80 e 0,52 respectivamente. Percebe-se que, analisando os resultados de desempenho para sinais EEG com informações de 1 a 100 Hz, os atributos apenas no domínio da frequência produzem resultados tanto de acurácia quanto de F-macro melhores.

Portanto, nota-se que, diante dos resultados expostos nos Capítulos 6, 7 e 8, existem combinações de parâmetros matemáticos bem como de atributos de entradas, para que o modelo prognóstico apresente melhor desempenho. Percebeu-se que, de modo geral, os modelos gerados utilizando o classificador SVM apresentaram melhores desempenhos gerais para os sinais EEG de pacientes comatosos analisados no presente trabalho.

As principais diferenças entre o que foi desenvolvido aqui e o que consta na literatura, resumida no Capítulo 4 desse documento foram basicamente: o tipo de paciente considerado nas análises, que na literatura a maioria dos estudos aborda pacientes em coma pós parada cardiorrespiratória e, diferentemente desse cenário, o que se observou dos dados coletados é que os pacientes internados no HCU-UFU têm pelo menos três grandes classes de etiologias de coma (acidente vascular encefálico, trauma, causas hipóxicas); o tipo de análise do sinal EEG onde, na literatura além de cálculos quantitativos utilizando ferramentas do processamento de sinais biológicos houve ainda quantificação a partir de padrões neurológicos, definidos portanto por médicos neurologistas, e no presente estudo os sinais EEG foram totalmente quantificados, de forma objetiva; as medidas de desempenho aqui calculadas consideraram também a informação de F-macro, uma medida que não foi calculada pelos estudos abordados na revisão mostrada no Capítulo 4, mas que fornece informações mais confiáveis que o próprio valor de acurácia; e ainda, o presente estudo considerou análises do sinal EEG nos ritmos gama e supergama, o que não havia sido ainda contemplado na literatura. É importante destacar ainda que em nenhum estudo da literatura foi evidenciada a criação de modelos prognósticos cujo

objetivo foi o de identificar possíveis pacientes com desfecho de morte encefálica, como o que ocorre no presente estudo.

O maior desafio dessa pesquisa foi lidar com a quantidade desbalanceada dos dados EEG, principalmente considerando a classe de registros em óbito por morte encefálica. Além desse fator, como princípio inicial da pesquisa foi de penalizar os modelos matemáticos elaborados a fim de gerar resultados mais confiáveis, toda análise dos resultados e tomadas de decisão mantiveram-se baseados nos valores da medida F-macro. Comparando os resultados aqui obtidos com os encontrados na literatura apresentada no Capítulo 4 é evidente que os valores das medidas de desempenho são menores devido às divergências metodológicas aqui adotadas em relação à literatura. Nota-se que o contexto das UTIs brasileiras é tratado no presente estudo uma vez que os pacientes considerados nas análises tiveram o coma provocado por diversas etiologias.

No estudo de (SCARPINO et al., 2020), cujo objetivo foi comparar alguns escores de EEG e identificar qual(is) apresentaria(iam) melhor(es) resultado(s) prognósticos, notou-se que analisar o sinal EEG considerando as terminologias padronizadas pela *American Clinical Neurophysiology Society* (ACNS) gerou um valor de AUC para o bom prognóstico igual a 0,79, considerado o melhor desempenho do estudo. Nota-se que esse valor é próximo a alguns resultados aqui obtidos, porém a partir de sinais EEG quantificados por ferramentas corriqueiras, por exemplo o cálculo da potência espectral, do processamento digital de sinais.

Analisar apenas sinal EEG com o objetivo de prognóstico do paciente comatoso é tarefa complexa. Em (HERMANN et al., 2021) a utilização de informações obtidas por meio de exames de imagens (tomografia por emissão de pósitrons - PET) para fins de diagnóstico do nível de consciência do paciente foram confrontadas com informações obtidas por meio de dados de sinais EEG. Notou-se que, dos 52 pacientes considerados (sendo 21 em estado vegetativo), a medida de desempenho AUC obtida quando considerados apenas dados de imagens comparada ao valor AUC obtido na consideração apenas do sinal EEG não apresentou diferença significativa. Concluíram portanto que ao associar informações de PET com as captadas no sinal EEG o desempenho prognóstico do paciente em desordem de consciência é otimizado, chegando a valores de acurácia em torno de 0,83.

9.2 Contribuições da autora

Entre agosto de 2017 e dezembro de 2021 foram produzidas as contribuições em parceria da autora com a equipe multidisciplinar e seu orientador:

Periódicos:

- RAMOS, C.D. and DESTRO-FILHO, J-B. Measurements of coherence in eeg signal in Brazilian people: a comparison of diferent consciousness states. Bioscience Journal. 2021, 37, e37065. <https://doi.org/10.14393/BJ-v37n0a2021-49454>
- COSTA, A.C.P.R., et al. Electroencephalogram patterns with the presence of an unknown musical stimulus. Bioscience Journal. 2021, 37, e37066. <https://doi.org/10.14393/BJ-v37n0a2021-49455>.
- RAMOS, C. D., et al. Analysis of electroencephalography brain rhythms in the reading process. Einstein (São Paulo). 2020, 18.
- LADEIRA, G., et al. Frequency spectrum recurrence analysis. Scientific Reports. 2020, 10.
- CAMPOS, M., et al. Computational processing of electroencephalographic signal as an auxiliary tool in differential diagnosis of co-morbidities in children with learning disabilities. Psychology & Neuroscience. 2019, 12.
- CAMPOS, M., et al. Electrophysiological Profile in Learning Disabilities Children with and Without Mild Cognitive Impairment. International Journal of Interdisciplinary Research and Innovations. 2018, 6.
- RAMOS, C. D., et al. Quantitative Analysis of EEG Records in Distinct States of Consciousness: A Case Study on Brazilian Patient. IEEE Latin America Transactions. 2018, 16.

9.3 Trabalhos Futuros

A quantidade de resultados obtidos ao longo dos anos de pesquisa, tanto na dissertação de mestrado quanto na tese de doutorado motivam tanto a autora quanto os demais membros da equipe a continuarem o trabalho relacionado a análise do sinal EEG empregado em diversos âmbitos da área da saúde: paciente comatoso; padronização de quantificadores de EEG medidos

em voluntários saudáveis; análise do sinal EEG durante o processo de meditação; entre outros tópicos.

A aquisição de registros EEG bem como informações de pacientes comatosos é algo que deve ser continuado uma vez que quanto mais sinais EEG coletados, melhores e mais precisos estatisticamente serão os modelos prognósticos elaborados. Além disso, é necessário que os modelos gerados no presente estudo sejam testados a partir de novos dados coletados a fim de verificar o desempenho desses modelos.

Empregar ferramentas de aprendizado de máquina no pré-processamento de sinais EEG a fim de detectar trechos de interesse é de fato um dos trabalhos futuros previstos. Essa adaptação pode não só agilizar a questão da separação de épocas, que atualmente trata-se de um trabalho totalmente dependente de médicos neurologistas e, portanto, principalmente no cenário pandêmico dos anos de 2020 e 2021, como ainda pode ser selecionadas mais de dez épocas de interesse (quantidade definida atualmente) com mais ou menos duração.

Outra possível atividade futura é a implementação dessa análise no contexto da telemedicina principalmente na teleconsultoria e assim auxiliar médicos intensivistas nas tomadas de decisão a respeito de pacientes comatosos.

Por fim, novas ferramentas quantitativas do processamento de sinais biomédicos devem ser testadas. Ferramentas não lineares podem influenciar na melhoria direta do desempenho dos modelos prognósticos elaborados. A união de ferramentas não lineares com informações de frequências para além de 30 Hz, ou seja, considerando ritmos gama e supergama, pode fornecer aos modelos prognósticos maior desempenho, principalmente referente ao cálculo da medida F-escore.

REFERÊNCIAS

ALIREZA ALA et al. **Validity and Predictive Value of the FOUR Score Coma Scale in Stroke Patients: A Systematic Review**. Journal of Experimental & Clinical NeuroSciences, v. 7, n. 2, p. 1-6, 2020.

AMORIM, E. et al. **Quantitative EEG reactivity and machine learning for prognostication in hypoxic-ischemic brain injury**. Clinical Neurophysiology, v. 130, n. 10, p. 1908-1916, 2019. <https://doi.org/10.1016/j.clinph.2019.07.014>

ANDRADE, A. F. DE et al. **Coma and other consciousness disorders**. Rev Med, v. 86, n. 3, p. 123-131, 2007. <https://doi.org/10.11606/issn.1679-9836.v86i3p123-131>

ANDRESEN, J. M. et al. **Burst suppression on processed electroencephalography as a predictor of postcoma delirium in mechanically ventilated ICU patients**. Critical Care Medicine, v. 42, n. 10, p. 2244-2295, 2014. <https://doi.org/10.1097/CCM.0000000000000522>

ANGHINAH, R. et al. **Eletroencefalograma Quantitativo e Topográfico**. Arquivos de Neuro-Psiquiatria, v. 56, n. 1, p. 59-63, 1998. <https://doi.org/10.1590/S0004-282X1998000100009>

BAGNATO, S. et al. **Clinical Neurophysiology EEG predictors of outcome in patients with disorders of consciousness admitted for intensive rehabilitation**. CLINICAL NEUROPHYSIOLOGY, 2014. <https://doi.org/10.1016/j.clinph.2014.08.005>

BENGHANEM, S. et al. **Value of EEG reactivity for prediction of neurologic outcome after cardiac arrest : Insights from the Parisian registry**. v. 2, n. June, p. 5-11, 2019.

BISHOP, C. M. **Pattern Recognition and Machine Learning**. 1st. ed. [s.l: s.n.].

BUZSAKI, G. **Rhythms of the Brain**. 1. ed. [s.l.] Oxford University Press, 2009.

CAVALCANTI, S. P. et al. **Electroencephalogram in Intensive Care Unit**. International Archives of Medicine, v. 8, n. 85, p. 1-6, 2016.

COMANDUCCI, A. et al. **Clinical and advanced neurophysiology in the prognostic and diagnostic evaluation of disorders of consciousness : review of an IFCN-endorsed expert group**. Clinical Neurophysiology, 2020. <https://doi.org/10.1016/j.clinph.2020.07.015>

CORCHS, S. et al. **Computational methods for resting-state EEG of patients with disorders of consciousness**. Frontiers in Neuroscience, v. 13, n. JUL, p. 1-7, 2019. <https://doi.org/10.3389/fnins.2019.01323>

DAUBE, J. R.; RUBIN, D. I. **Clinical Neurophysiology**. 3rd. ed. New York: Oxford,

2009. <https://doi.org/10.1093/med/9780195385113.001.0001>

DE PESTERS, A. et al. **Alpha power indexes task-related networks on large and small scales: A multimodal ECoG study in humans and a non-human primate.** *NeuroImage*, v. 134, p. 122-131, 2016. <https://doi.org/10.1016/j.neuroimage.2016.03.074>

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern Classification**. 2nd. ed. [s.l: s.n.].
EBERSOLE, J. S.; PEDLEY, T. A. **Current Practice of Clinical Electroencephalography**. 3. ed. [s.l.] Lippincott Williams & Wilkins, 2003. <https://doi.org/10.1046/j.1468-1331.2003.00643.x>

ENGEL-JR, J.; PEDLEY, T. A. **Epilepsy a Comprehensive Textbook**. 2 ed. ed. Philadelphia: Lippincott Williams & Wilkins, 2008. v. 2

ENGEL, J. J.; SILVA, F. L. **HIGH-FREQUENCY OSCILLATIONS - WHERE WE ARE AND WHERE WE NEED TO GO**. v. 98, n. 3, p. 316-318, 2012. <https://doi.org/10.1016/j.pneurobio.2012.02.001>

ESTRANEO, A. et al. **Multi-center prospective study on predictors of short-term outcome in disorders of consciousness.** *American Academy of Neurology*, v. 95, n. 11, p. 1488-1499, 2020. <https://doi.org/10.1212/WNL.00000000000010254>

FATUZZO, D. et al. **Does continuous EEG influence prognosis in patients after cardiac arrest?** *Resuscitation*, v. 132, p. 29-32, 2018. <https://doi.org/10.1016/j.resuscitation.2018.08.023>

FAWCETT, T. **An introduction to ROC analysis.** *Pattern Recognition Letters*, v. 27, n. 8, p. 861-874, 2006. <https://doi.org/10.1016/j.patrec.2005.10.010>

FREEMAN, W. J.; QUIROGA, R. Q. **Imaging Brain Function With EEG**. [s.l: s.n.].
GASPARD, N. et al. **Interrater agreement for Critical Care EEG Terminology.** *Epilepsia*, v. 55, n. 9, p. 1366-1373, 2014. <https://doi.org/10.1111/epi.12653>

GAUDÊNCIO, T. G.; LEÃO, G. DE M. **A epidemiologia do Traumatismo Crânio-Encefálico: Um Levantamento bibliográfico no Brasil.** *Revista Neurociencias*, v. 21, n. 3, p. 427-434, jun. 2013. <https://doi.org/10.34024/rnc.2013.v21.8261>

GOLKOWSKI, D. et al. **Simultaneous EEG-PET-fMRI measurements in disorders of consciousness: an exploratory study on diagnosis and prognosis.** *Journal of Neurology*, v. 264, n. 9, p. 1986-1995, 2017. <https://doi.org/10.1007/s00415-017-8591-z>

GUYTON, A. C.; HALL, J. E. **Tratado de Fisiologia Médica**. 11. ed. [s.l.] Elsevier, 2006.

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. **The Elements of Statistical Learning: Data Mining, Inference, and Prediction**. 2. ed. [s.l.] Springer, 2009.

<https://doi.org/10.1007/978-0-387-84858-7>

HAUPT, W. F. et al. **Coma and cerebral imaging**. SpringerPlus, v. 4, n. 1, 2015.
<https://doi.org/10.1186/s40064-015-0869-y>

HEALEY, C. et al. **Improving the Glasgow Coma Scale score: motor score alone is a better predictor**. The Journal of Trauma, v. 54, n. 4, p. 671-679, 2003.
<https://doi.org/10.1097/01.TA.0000058130.30490.5D>

HERMAN, S. T. et al. **Consensus Statement on Continuous EEG in Critically Ill Adults and Children, Part I: Indications**. Journal of Clinical Neurophysiology, v. 32, n. 2, p. 87-95, 2015. <https://doi.org/10.1097/WNP.0000000000000166>

HERMANN, B. et al. **Multimodal FDG-PET and EEG assessment improves diagnosis and prognostication of disorders of consciousness**. NeuroImage: Clinical, v. 30, n. October 2020, 2021. <https://doi.org/10.1016/j.nicl.2021.102601>

HERRMANN, C. S. et al. **EEG oscillations: From correlation to causality**. International Journal of Psychophysiology, v. 103, p. 12-21, 2016.
<https://doi.org/10.1016/j.ijpsycho.2015.02.003>

HOFMEIJER, J. et al. **Early EEG contributes to multimodal outcome prediction of postanoxic coma**. Neurology, v. 85, n. 2, p. 137-143, 2015.
<https://doi.org/10.1212/WNL.0000000000001742>

HOFMEIJER, J.; PUTTEN, M. J. A. M. VAN. **Value of electroencephalography for prognosis and treatment of comatose patients after circulatory arrest**. Netherlands Journal of Critical Care, v. 29, n. 1, p. 6-13, 2020.

HOFMEIJER, J.; TJEPKEMA-CLOOSTERMANS, M. C.; VAN PUTTEN, M. J. A. M. **Burst-suppression with identical bursts: A distinct EEG pattern with poor outcome in postanoxic coma**. Clinical Neurophysiology, v. 125, n. 5, p. 947-954, 2014.
<https://doi.org/10.1016/j.clinph.2013.10.017>

JIANG, M. et al. **Predicting the non-survival outcome of large hemispheric infarction patients via quantitative electroencephalography: Superiority to visual electroencephalography and the Glasgow Coma Scale**. Neuroscience Letters, v. 706, n. 45, p. 88-92, 2019. <https://doi.org/10.1016/j.neulet.2019.05.007>

KANG, X. GANG et al. **Predictive value of EEG-awakening for behavioral awakening from coma**. Annals of Intensive Care, v. 5, n. 1, p. 1-8, 2015.
<https://doi.org/10.1186/s13613-015-0094-4>

KOIRALA, A. et al. **Deep learning - Method overview and review of use for fruit detection and yield estimation**. Computers and Electronics in Agriculture, v. 162, n. January,

p. 219-234, 2019. <https://doi.org/10.1016/j.compag.2019.04.017>

LAMBLIN, M. D.; WALLS ESQUIVEL, E.; ANDRÉ, M. **The electroencephalogram of the full-term newborn: Review of normal features and hypoxic-ischemic encephalopathy patterns.** *Neurophysiologie Clinique*, v. 43, n. 5-6, p. 267-287, 2013. <https://doi.org/10.1016/j.neucli.2013.07.001>

LAUREYS, S.; OWEN, A. M.; SCHIFF, N. D. **Brain function in coma, vegetative state, and related disorders.** *Lancet Neurology*, v. 3, n. 9, p. 537-546, 2004. [https://doi.org/10.1016/S1474-4422\(04\)00852-X](https://doi.org/10.1016/S1474-4422(04)00852-X)

LÉVESQUE, M. et al. **High-frequency (80-500 Hz) oscillations and epileptogenesis in temporal lobe epilepsy.** *Disabil Rehabil.*, v. 42, n. 3, p. 231-241, 2011. <https://doi.org/10.1016/j.nbd.2011.01.007>

LIU, G. et al. **Predicting Outcome in Comatose Patients: The Role of EEG Reactivity to Quantifiable Electrical Stimuli.** *Evidence-based Complementary and Alternative Medicine*, v. 2016, 2016. <https://doi.org/10.1155/2016/8273716>

LUCA., C. J. DE et al. **Filtering the surface EMG signal: Movement artifact and baseline noise contamination.** *Journal of Biomechanics*, v. 43, n. 8, p. 1573-1579, 2010. <https://doi.org/10.1016/j.jbiomech.2010.01.027>

MIKOLA, A. et al. **Prediction of Outcome in Traumatic Brain Injury Patients Using Long-term qEEG Features.** p. 1532-1535, 2015. <https://doi.org/10.1109/EMBC.2015.7318663>

MITCHELL, T. M. **Machine learning.** 1. ed. [s.l.] McGraw-Hill Science/Engineering/Math, 1997.

MONTENEGRO, M. A. et al. **EEG - NA PRATICA CLINICA.** 2. ed. [s.l.] Revinter, 2011.

MÜLLER, M. et al. **Standardized visual EEG features predict outcome in patients with acute consciousness impairment of various etiologies.** *Critical Care*, v. 24, n. 1, p. 1-13, 2020. <https://doi.org/10.1186/s13054-020-03407-2>

NAGARAJ, S. B. et al. **The revised Cerebral Recovery Index improves predictions of neurological outcome after cardiac arrest.** *Clinical Neurophysiology*, v. 129, n. 12, p. 2557-2566, 2018. <https://doi.org/10.1016/j.clinph.2018.10.004>

NASSAR-JUNIOR, A. P. et al. **Validity, reliability and applicability of Portuguese versions of sedation-agitation scales among critically ill patients.** *Sao Paulo Medical Journal*, v. 126, n. 4, p. 215-219, 2008. <https://doi.org/10.1590/S1516-31802008000400003>

NENADOVIC, V. **Brain Coordination Dynamics in Altered States of**

Consciousness in Children. [s.l.] University of Toronto, 2013.

NIEDERMEYER, E.; SILVA, F. L. DA. **Electroencephalography : basic principles, clinical applications, and related fields.** 5. ed. Philadelphia: Lippincott Williams & Wilkins, 2005.

NOOR, N. S. E. M.; IBRAHIM, H. **Machine Learning Algorithms and Quantitative Electroencephalography Predictors for Outcome Prediction in Traumatic Brain Injury: A Systematic Review.** IEEE Access, v. 8, p. 102075-102092, 2020. <https://doi.org/10.1109/ACCESS.2020.2998934>

NUNES, R. R.; ALMEIDA, M. P. DE; SLEIGH, J. W. **Spectral entropy: A new method for anesthetic adequacy.** Revista Brasileira de Anestesiologia, v. 54, n. 3, p. 404-422, 2004. <https://doi.org/10.1590/S0034-70942004000300013>

NUNEZ, P. L.; SRINIVASAN, R. **Electric Fields of the Brain: The Neurophysics of EEG.** 2. ed. [s.l.] Oxford University Press, 2005.

OBIAKO, O. R.; OPARAH, S. K.; OGUNNIYI, A. **Prognosis and outcome of acute stroke in the University College Hospital Ibadan, Nigeria.** Nigerian Journal of Clinical Practice, v. 14, n. 3, p. 359-362, 2011. <https://doi.org/10.4103/1119-3077.86784>

OLIVEIRA, C. C. DE. **ESTUDO DA VARIAÇÃO DA FREQUÊNCIA CEREBRAL E RELAÇÃO ENTRE RITMOS LENTOS E RÁPIDOS EM REGISTROS DE EEG COMATOSOS E CONTROLES.** [s.l.] Universidade Federal de Uberlândia, 2018.

PACHORI, R. B.; BAJAJ, V. **Analysis of normal and epileptic seizure EEG signals using empirical mode decomposition.** Computer Methods and Programs in Biomedicine, v. 104, n. 3, p. 373-381, 2011. <https://doi.org/10.1016/j.cmpb.2011.03.009>

PEREIRA, R. P.; TOLEDO, R. N.; GUILHERME, A. **Qualificação e quantificação da exposição sonora ambiental em uma unidade de terapia intensiva geral.** Revista Brasileira De Otorrinolaringologia, v. 69, n. 6, p. 766-771, 2003. <https://doi.org/10.1590/S0034-72992003000600007>

POSNER, J. B. et al. **Diagnosis of stupor and coma.** 4th. ed. [s.l.] Oxford University Press, 2007. <https://doi.org/10.1093/med/9780195321319.003.0145>

PUGGINA, A. C. G. et al. **A percepção auditiva nos pacientes em estado de coma : uma revisão bibliográfica.** Acta Paul Enferm, v. 18, n. 3, p. 313-319, 2005. <https://doi.org/10.1590/S0103-21002005000300013>

PUTTEN, M. J. A. M. VAN et al. **Deep Learning for outcome prediction of postanoxic coma.** EMBEC: European Medical and Biological Engineering Conference, v. 65, p. 1089-1090, 2017.

RAMOS, C. D. **Characterization of the normal electroencephalogram in wakefulness: elaboration of the database and quantitative analysis.** [s.l.] Federal University of Uberlandia, 2017.

RUIJTER, B. J. et al. **The prognostic value of discontinuous EEG patterns in postanoxic coma.** Clinical Neurophysiology, v. 129, n. 8, p. 1534-1543, 2018. <https://doi.org/10.1016/j.clinph.2018.04.745>

SANDRONI, C. et al. **Prediction of poor neurological outcome in comatose survivors of cardiac arrest: a systematic review.** [s.l.] Springer Berlin Heidelberg, 2020. v. 46 <https://doi.org/10.1007/s00134-020-06198-w>

SCARPINO, M. et al. **EEG and Coma Recovery Scale-Revised prediction of neurological outcome in Disorder of Consciousness patients.** Acta Neurologica Scandinavica, n. December 2019, p. 1-8, 2020.

SCHOMER, D. L.; SILVA, F. H. L. DA. **Niedermeyer's Electroencephalography: Basic Principles, Clinical Applications, and Related Fields.** 6. ed. [s.l.] Lippincott Williams & Wilkins, 2011.

SENDERS, J. T. et al. **Machine Learning and Neurosurgical Outcome Prediction: A Systematic Review.** World Neurosurg, v. 109, p. 476-486, 2018. <https://doi.org/10.1016/j.wneu.2017.09.149>

SESSLER, C. N. et al. **The Richmond Agitation-Sedation Scale: validity and reliability in adult intensive care unit patients.** American journal of respiratory and critical care medicine, v. 166, n. 10, p. 1338-1382, 2002. <https://doi.org/10.1164/rccm.2107138>

SIVARAJU, A. et al. **Prognostication of post-cardiac arrest coma: early clinical and electroencephalographic predictors of outcome.** Intensive Care Medicine, v. 41, n. 7, p. 1264-1272, 2015. <https://doi.org/10.1007/s00134-015-3834-x>

SONDAG, L. et al. **Early EEG for outcome prediction of postanoxic coma: Prospective cohort study with cost-minimization analysis.** Critical Care, v. 21, n. 1, p. 1-8, 2017.

SONG, M. et al. **Prognostic models for prolonged disorders of consciousness : an integrative review.** Cellular and Molecular Life Sciences, n. 0123456789, 2020. <https://doi.org/10.1007/s00018-020-03512-z>

SÖRNMO, L.; LAGUNA, P. **Bioelectrical Signal Processing in Cardiac and Neurological Applications.** 1. ed. [s.l.] Academic Press, 2005. <https://doi.org/10.1016/B978-012437552-9/50001-5>

TAN, P.-N. et al. **Introduction to Data Mining.** 2. ed. [s.l.] Pearson, 2018.

TEASDALE, G.; BRYAN, J. **Assessment of coma and impaired consciousness. A practical scale.** The Lancet, v. 304, n. 7872, p. 81-84, 1974. [https://doi.org/10.1016/S0140-6736\(74\)91639-0](https://doi.org/10.1016/S0140-6736(74)91639-0)

TELENCZUK, B. et al. **High-frequency EEG covaries with spike burst patterns detected in cortical neurons.** Journal of neurophysiology, v. 105, n. 6, p. 2951-2959, 2011. <https://doi.org/10.1152/jn.00327.2010>

TJEPKEMA-CLOOSTERMANS, M. C. et al. **Cerebral recovery index: Reliable help for prediction of neurologic outcome after cardiac arrest.** Critical Care Medicine, v. 45, n. 8, p. e789-e797, 2017. <https://doi.org/10.1097/CCM.0000000000002412>

TRAUB, S. J.; WIJDICKS, E. F. **Initial Diagnosis and Management of Coma.** Emergency Medicine Clinics of North America, v. 34, n. 4, p. 777-793, 2016. <https://doi.org/10.1016/j.emc.2016.06.017>

URRESTARAZU, E. et al. **Interictal high-frequency oscillations (10-500 Hz) in the intracerebral EEG of epileptic patients.** Brain, v. 130, n. 9, p. 2354-2366, 2007. <https://doi.org/10.1093/brain/awm149>

VESPA, P. **Continuous EEG Monitoring for the Detection of Seizures in Traumatic Brain Injury, Infarction, and Intracerebral Hemorrhage: To Detect and Protect.** Journal of Clinical Neurophysiology, v. 22, n. 2, p. 99-106, 2005. <https://doi.org/10.1097/01.WNP.0000154919.54202.E0>

WANG, F. et al. **Detecting Disorders of Consciousness in Brain Injuries From EEG Connectivity Through Machine Learning.** IEEE Transactions on Emerging Topics in Computational Intelligence, p. 1-11, 2020.

WASSERMAN, L. **All of Statistics.** 1. ed. [s.l.] Springer, New York, NY, 2004. <https://doi.org/10.1007/978-0-387-21736-9>

WESTHALL, E. et al. **Time to epileptiform activity and EEG background recovery are independent predictors after cardiac arrest.** Clinical Neurophysiology, v. 129, n. 8, p. 1660-1668, 2018. <https://doi.org/10.1016/j.clinph.2018.05.016>

WHITE, D. M.; VAN COTT, A. C. **EEG artifacts in the intensive care unit setting.** American journal of electroneurodiagnostic technology, v. 50, p. 8-25, 2010. <https://doi.org/10.1080/1086508X.2010.11079750>

WILSON, J. A.; NORDAL, H. J. **EEG in connection with coma.** Tidsskr Nor Legeforen, v. 133, n. 1, p. 53-7, 2013. <https://doi.org/10.4045/tidsskr.11.1432>

XIN, X. et al. **Correlation between the Revised Brain Symmetry Index, an EEG Feature Index, and Short-term Prognosis in Acute Ischemic Stroke.** Journal of Clinical

Neurophysiology, v. 34, n. 2, p. 162-167, 2017.
<https://doi.org/10.1097/WNP.0000000000000341>

YOUNG, B. et al. **A Novel EEG Artifact in the Intensive Care Unit.** Journal of Clinical Neurophysiology, v. 19, n. 5, p. 484-486, 2002. <https://doi.org/10.1097/00004691-200210000-00011>

ZUBLER, F. et al. **Clinical Neurophysiology Prognostic and diagnostic value of EEG signal coupling measures in coma.** Clinical Neurophysiology, 2015.
<https://doi.org/10.1016/j.clinph.2015.08.022>

ZUBLER, F. et al. **EEG synchronization measures are early outcome predictors in comatose patients after cardiac arrest.** Clinical Neurophysiology, v. 128, n. 4, p. 635-642, 2017a. <https://doi.org/10.1016/j.clinph.2017.01.020>

ZUBLER, F. et al. **Clinical Neurophysiology EEG synchronization measures are early outcome predictors in comatose patients after cardiac arrest.** v. 128, p. 635-642, 2017b. <https://doi.org/10.1016/j.clinph.2017.01.020>

ANEXOS

ANEXO I: AUTORIZAÇÃO CEP 369/11



Universidade Federal de Uberlândia
Pró-Reitoria de Pesquisa e Pós-Graduação
COMITÊ DE ÉTICA EM PESQUISA - CEP

Av. João Naves de Ávila, nº 2121 - Bloco A – sala 224 - Campus Santa Mônica - Uberlândia-MG –
CEP 38408-144 - FONE/FAX (34) 3239-4131

ANÁLISE FINAL Nº. 014/12 DO COMITÊ DE ÉTICA EM PESQUISA PARA O PROTOCOLO REGISTRO CEP/UFU
369/11

Projeto Pesquisa: “Aplicações clínicas do EEG quantitativo para o estudo de indivíduos normais, pacientes com déficit de aprendizagem e pacientes em estado de coma”.

Pesquisador Responsável: João Batista Destro Filho

De acordo com as atribuições definidas na Resolução CNS 196/96, o CEP manifesta-se pela aprovação do protocolo de pesquisa proposto.

O protocolo não apresenta problemas de ética nas condutas de pesquisa com seres humanos, nos limites da redação e da metodologia apresentadas.

O CEP/UFU lembra que:

a- segundo a Resolução 196/96, o pesquisador deverá arquivar por 5 anos o relatório da pesquisa e os Termos de Consentimento Livre e Esclarecido, assinados pelo sujeito de pesquisa.

b- poderá, por escolha aleatória, visitar o pesquisador para conferência do relatório e documentação pertinente ao projeto.

c- a aprovação do protocolo de pesquisa pelo CEP/UFU dá-se em decorrência do atendimento a Resolução 196/96/CNS, não implicando na qualidade científica do mesmo.

Data de entrega do 1º Relatório Parcial: **fevereiro de 2013**

Data de entrega do 2º Relatório Parcial: **fevereiro de 2014**

Data de entrega do Relatório Final: **fevereiro de 2015**

SITUAÇÃO: PROTOCOLO APROVADO

OBS.: O CEP/UFU LEMBRA QUE QUALQUER MUDANÇA NO PROTOCOLO DEVE SER INFORMADA IMEDIATAMENTE AO CEP PARA FINS DE ANÁLISE E APROVAÇÃO DA MESMA.

Uberlândia, 02 de fevereiro de 2012.

Profa. Dra. Sandra Terezinha de Farias Furtado
Coordenadora do CEP/UFU

**ANEXO II: AUTORIZAÇÃO CEP
2.570.022**

PARECER CONSUBSTANCIADO DO CEP

DADOS DO PROJETO DE PESQUISA

Título da Pesquisa: Estudo do efeito da estimulação musical baseada em eletroencefalografia (EEG)

Pesquisador: João Batista Destro Filho

Área Temática:

Versão: 1

CAAE: 82824017.5.0000.5152

Instituição Proponente: Faculdade de Engenharia Elétrica

Patrocinador Principal: Financiamento Próprio

DADOS DO PARECER

Número do Parecer: 2.570.022

Apresentação do Projeto:

O protocolo de pesquisa intitulado "Estudo do efeito da estimulação musical baseada em eletroencefalografia (EEG)" pretende estudar prospectivamente os efeitos de estimulação musical em pacientes da Unidade de Terapia Intensiva Adulta (UTIA) do

Hospital de Clínicas de Uberlândia, sem perturbar a rotina de tratamento dos mesmos, investigando a influência de tais estimulações através do EEG previsto no protocolo de tratamento, e através dos parâmetros de monitoramento contínuo (em termos de pressões arteriais e frequências cardíacas). O grupo de estudo receberá estimulação musical prolongada, ou seja, durante três dias consecutivos logo após a realização do EEG de rotina. Já o grupo controle não receberá estas estimulações. O Eletroencefalograma (EEG) mede a atividade elétrica do cérebro em diferentes locais do córtex cerebral, geralmente usando eletrodos colocados no couro cabeludo. Suas principais vantagens sobre as outras técnicas de gravação são a alta resolução temporal e o fato de que pode ser gravado de forma não-invasiva. Devido ao baixo custo, as gravações de EEG são amplamente utilizados tanto em ambientes clínicos quanto em pesquisas. Isso faz com que esse exame seja uma ferramenta muito acessível e útil, que é particularmente interessante para a análise dos processos cerebrais de alto nível. No contexto das Unidades de Terapia Intensiva (UTI), observa-se que existe uma tendência internacional em utilizar registros de EEG para monitorização contínua de pacientes neurologicamente críticos. Particularmente, no contexto de pacientes em coma, o EEG revelou recentemente resultados significativos, com impacto clínico

Endereço: Av. João Naves de Ávila 2121- Bloco "1A", sala 224 - Campus Sta. Mônica

Bairro: Santa Mônica

CEP: 38.408-144

UF: MG

Município: UBERLÂNDIA

Telefone: (34)3239-4131

Fax: (34)3239-4335

E-mail: cep@propp.ufu.br

Continuação do Parecer: 2.570.022

Outros	RAMETROS.pdf	16:27:08	Camila Davi Ramos	Aceito
Outros	ANEXO2_DADOS_MUSICOTERAPICO S.pdf	03/02/2018 16:26:31	Camila Davi Ramos	Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	TCLE_CORRIGIDO.pdf	03/02/2018 16:23:40	Camila Davi Ramos	Aceito
Projeto Detalhado / Brochura Investigador	PROJETO_V_SUBMISSAO_CORRIGID O.pdf	03/02/2018 16:22:47	Camila Davi Ramos	Aceito
Declaração de Pesquisadores	termo_compromisso_fev_2018.pdf	03/02/2018 16:21:45	Camila Davi Ramos	Aceito
Outros	link_lattes.docx	29/01/2018 13:33:03	Camila Davi Ramos	Aceito
Declaração de Instituição e Infraestrutura	Ints_COPARTICIPANTE_2.jpeg	10/10/2017 08:46:45	Camila Davi Ramos	Aceito
Declaração de Instituição e Infraestrutura	Inst_COPARTICIPANTE.jpeg	10/10/2017 08:45:35	Camila Davi Ramos	Aceito

Situação do Parecer:

Aprovado

Necessita Apreciação da CONEP:

Não

UBERLÂNDIA, 28 de Março de 2018

Assinado por:
Sandra Terezinha de Farias Furtado
(Coordenador)

Endereço: Av. João Naves de Ávila 2121- Bloco "1A", sala 224 - Campus Sta. Mônica
Bairro: Santa Mônica **CEP:** 38.408-144
UF: MG **Município:** UBERLÂNDIA
Telefone: (34)3239-4131 **Fax:** (34)3239-4335 **E-mail:** cep@propp.ufu.br