



**VOLNEI ÂNGELO FRIGERI JÚNIOR**

**ANÁLISE DE SISTEMAS INTELIGENTES EVOLUTIVOS  
PARA CLASSIFICAÇÃO DE FLUXO DE DADOS DE  
ELETROENCEFALOGRAFIA JUNTO A INTERFACES  
CÉREBRO-COMPUTADOR**

**LAVRAS – MG**

**2021**

**VOLNEI ÂNGELO FRIGERI JÚNIOR**

**ANÁLISE DE SISTEMAS INTELIGENTES EVOLUTIVOS PARA CLASSIFICAÇÃO  
DE FLUXO DE DADOS DE ELETROENCEFALOGRAFIA JUNTO A INTERFACES  
CÉREBRO-COMPUTADOR**

Monografia apresentada à Universidade Federal  
de Lavras, como parte das exigências da matéria  
PRG222 - Trabalho de conclusão de curso, para  
a obtenção do título de Bacharel em Engenharia  
de Controle e Automação

Prof. Daniel Furtado Leite

Orientador

**LAVRAS – MG**

**2021**

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca  
Universitária da UFLA, com dados informados pelo próprio autor.**

Frigeri Júnior, Volnei Ângelo

Análise de Sistemas Inteligentes Evolutivos para Classificação  
de Fluxo de Dados de Eletroencefalografia junto a Interfaces  
Cérebro-Computador / Volnei Ângelo Frigeri Júnior. – 2021.

57 p. : il.

Orientador: Daniel Furtado Leite.

Monografia(graduação)–Universidade Federal de Lavras,  
2021.

Bibliografia.

1. Interface Cérebro-Computador. 2. Fuzzy 3. Eletroencefa-  
lografia. 4. Sistemas Inteligentes. I. Leite, Daniel Furtado. II.  
Título.

**VOLNEI ÂNGELO FRIGERI JÚNIOR**

**ANÁLISE DE SISTEMAS INTELIGENTES EVOLUTIVOS PARA CLASSIFICAÇÃO  
DE FLUXO DE DADOS DE ELETROENCEFALOGRAFIA JUNTO A INTERFACES  
CÉREBRO-COMPUTADOR**

**ANALYSIS OF INTELLIGENT EVOLUTIONARY SYSTEMS FOR  
CLASSIFICATION OF ELECTROENCEPHALOGRAPHY DATA FLOW WITH  
BRAIN-COMPUTER INTERFACES**

Monografia apresentada à Universidade Federal de Lavras, como parte das exigências da matéria PRG222 - Trabalho de conclusão de curso, para a obtenção do título de Bacharel em Engenharia de Controle e Automação

APROVADA em 26 de Novembro de 2021.

Prof. Daniel Furtado Leite	Universidade Federal de Lavras
Profa. Silvia Costa Ferreira	Universidade Federal de Lavras
Prof. Cristiano Mesquita Garcia	Instituto Federal de Santa Catarina

Prof. Daniel Furtado Leite  
Orientador

**LAVRAS – MG  
2021**

*Dedico esse trabalho para minha família, minha mãe, meu pai e meu irmão, por sempre acreditarem em mim e me apoiarem. Dedico também à minha namorada, pelo seu incentivo e compreensão durante todo esse tempo.*

## **AGRADECIMENTOS**

Agradeço aos meus pais, Ivanete Rinaldi e Volnei Frigeri pelo apoio incondicional e por sempre se preocuparem com minha educação e me incentivarem. Agradeço ao meu irmão, Francis Rinaldi por estar sempre disponível para conversar e me ajudar quando precisei.

Agradeço também à minha namorada, Laura Scaldaferrri, por me incentivar em tantas coisas durante o tempo de universidade, por me estimular a sempre ir além, também pelo seu carinho, afeto, paciência, compreensão e companheirismo por todos esses anos.

Agradeço também aos meus amigos, especialmente à Natanael Sindou, Patrick Zanzarini e César Camillo por se manterem perto por todos esses anos e conseguirem me distrair dos problemas e estresses diários.

Agradeço aos meus Professores e Professoras pelas valiosas contribuições dadas durante meu processo de formação.

Por fim, agradeço ao meu Professor Orientador, Daniel Leite pela paciência, ajuda e oportunidade de executar tanto uma iniciação científica como um trabalho de conclusão de curso em sua supervisão.

*The most exciting phrase to hear in science, the one that heralds new discoveries, is not  
“Eureka!” (I found it!) but “That’s funny . . .”  
(Isaac Asimov)*

## RESUMO

São descritos dois algoritmos fuzzy evolutivos para aprendizado de máquina online, viz., *evolving Granular Fuzzy Classifier* (eGFC) e *Dynamic Evolving Neural-Fuzzy Inference System* (DENFIS). O objetivo é processar fluxos de dados de eletroencefalografia (EEG) e construir modelos classificadores de emoções. Uma base de dados bem conhecida, chamada *DEAP*, é considerada. Os dados proveem de 32 sujeitos que assistem 40 vídeo-clipes musicais de 1 minuto cada. Após cada vídeo, preenchem formulários. Estes são usados para definir 8 rótulos de um problema de classificação de padrões. Os rótulos são definidos de acordo com quadrantes do modelo Excitação-Valência-Dominância. Analisou-se os efeitos de canais EEG individuais e de janelas de tempo. Um experimento multicanal visando comparar o desempenho dos dois algoritmos foi realizado. Conclui-se que todas as 4 bandas de frequência analisadas, entre 4 e 45Hz, contribuem para o desempenho de classificação. O lobo parietal se mostrou a região mais promissora para auxiliar a classificação. A velocidade de processamento de amostras de ambos os algoritmos é alta, em torno de milissegundos ou menos. A maior acurácia entre os dois algoritmos foi de 32,68% (eGFC) usando atributos espaciais provenientes do espectro de Fourier apenas. É notável que há aprendizado ao longo do tempo visto que a expectativa de acurácia de um classificador aleatório em um conjunto de dados balanceado é de 12,50%. Conclui-se que padrões temporais em dados EEG predominam em relação aos padrões espaciais. A transformada de Fourier, embora interessante, não é a transformação mais adequada para a busca de novos padrões visto a perda de parte da informação temporal.

**Palavras-chave:** Sistemas Inteligentes. Interface Cérebro-Computador. Aprendizado de Máquina.

## ABSTRACT

Two evolving fuzzy algorithms for online machine learning are described, viz., evolving Granular Fuzzy Classifier (eGFC) and Dynamic Evolving Neural-Fuzzy Inference System (DENFIS). The objective is to process electroencephalogram (EEG) data streams, and build emotion classification models. A well-known dataset, namely *DEAP*, is considered. The data is provided by 32 subjects that are exposed to 40 musical videos of 1 minute. After each video, the subjects fill in some forms, which are used to define 8 labels of a pattern classification problem. The labels are defined according to the quadrants of the Arousal-Valence-Dominance sphere. Individual EEG channels and time-window lengths were evaluated. A multi-channel experiment, aiming to compare the performance of both evolving algorithms, was also carried out. We conclude that the 4 frequency bands under analysis, from 4 to 45Hz, contribute to the classification performance. The parietal lobe has shown to be the most significant region of the brain to assist classification. The processing speed of both algorithms is fast, around milliseconds or even less. The greatest accuracy was reached by eGFC, 32.68%, using spatial attributes from the Fourier spectrum only. Model learning over time is notable since the expected accuracy of a random classifier in a balanced dataset is 12.50%. We conclude that temporal patterns in EEG data are predominant over spatial patterns, and, therefore, the Fourier transform, although helpful, is not the most appropriate transformation to search for new patterns.

**Keywords:** Intelligent Systems. Brain-Computer Interface. Machine Learning.

## LISTA DE FIGURAS

Figura 4.1 – Posição dos Eletrodos no Sistema Internacional 10-20 e 10-10 . . . . .	34
Figura 4.2 – Posição dos Eletrodos da base de dados <i>DEAP</i> . . . . .	34
Figura 4.3 – Sistema de quadrantes de emoções no modelo Excitação-Valência . . . . .	35
Figura 4.4 – Modelo Excitação-Valência-Dominância com as seis emoções básicas re- presentadas . . . . .	36
Figura 4.5 – Exemplo do Espectro de Fourier gerado da Janela de Tempo de 3s . . . . .	38
Figura 5.1 – Incidência dos canais no rank de 175 melhores atributos e suas posições no couro cabeludo . . . . .	46

## LISTA DE TABELAS

Tabela 4.1 – Classes para classificação no Sistema Excitação-Valência-Dominância . . .	36
Tabela 5.1 – Tempo de processamento médio por amostra individual em janelas de tempo	41
Tabela 5.2 – Resultado eGFC por canal individual de EEG para janelas de 60 segundos .	42
Tabela 5.3 – Resultado eGFC por canal individual de EEG para janelas de 3 segundos .	43
Tabela 5.4 – Resultado DENFIS por canal individual de EEG para janelas de 60 segundos	44
Tabela 5.5 – Resultado DENFIS por canal individual de EEG para janelas de 3 segundos	45
Tabela 5.6 – Ranking dos 175 melhores atributos . . . . .	47
Tabela 5.7 – Comparação de Acurácia, grânulos e tempo por amostra com o método <i>Leave-n-Out</i> para janela de tempo de 3 segundos . . . . .	48
Tabela 5.8 – Comparação de Acurácia, grânulos e tempo por amostra com o método <i>Leave-n-Out</i> para janela de tempo de 60 segundos . . . . .	48

## SUMÁRIO

<b>1</b>	<b>Introdução</b>	<b>11</b>
<b>1.1</b>	<b>Objetivos</b>	<b>13</b>
<b>1.2</b>	<b>Organização do Texto</b>	<b>13</b>
<b>2</b>	<b>Redes Neurais Artificiais e Sistemas Fuzzy em Interface Cérebro-Computador</b>	<b>15</b>
<b>2.1</b>	<b>Fundamentos de ICC</b>	<b>15</b>
<b>2.2</b>	<b>Rede Neural Aplicada a ICC</b>	<b>17</b>
<b>2.3</b>	<b>Sistemas Fuzzy Aplicados a ICC</b>	<b>18</b>
<b>2.4</b>	<b>Outros algoritmos de aprendizado de máquinas aplicados a ICC</b>	<b>19</b>
<b>3</b>	<b>Sistemas Inteligentes Evolutivos</b>	<b>21</b>
<b>3.1</b>	<b>Conceitos Básicos</b>	<b>21</b>
<b>3.2</b>	<b>eGFC</b>	<b>22</b>
<b>3.2.1</b>	<b>Regras eGFC</b>	<b>22</b>
<b>3.2.2</b>	<b>Inserção de Regras</b>	<b>23</b>
<b>3.2.3</b>	<b>Atualização Incremental</b>	<b>24</b>
<b>3.2.4</b>	<b>Adaptação do Nível <math>\rho</math></b>	<b>25</b>
<b>3.2.5</b>	<b>Mescla de Regras</b>	<b>26</b>
<b>3.2.6</b>	<b>Remoção de Regras</b>	<b>26</b>
<b>3.2.7</b>	<b>Algoritmo eGFC</b>	<b>27</b>
<b>3.3</b>	<b>DENFIS</b>	<b>27</b>
<b>3.3.1</b>	<b>Método de Agrupamento Evolutivo (ECM)</b>	<b>28</b>
<b>3.3.2</b>	<b>Sistema de Inferência de Takagi-Sugeno</b>	<b>28</b>
<b>3.3.3</b>	<b>Aprendizado Online do modelo DENFIS</b>	<b>29</b>
<b>4</b>	<b>Metodologia</b>	<b>33</b>
<b>4.1</b>	<b>Base da Dados</b>	<b>33</b>
<b>4.2</b>	<b>Posição dos Eletrodos</b>	<b>33</b>
<b>4.3</b>	<b>Sistema de Excitação-Valência e Dominância</b>	<b>34</b>
<b>4.4</b>	<b>Extração dos Dados</b>	<b>36</b>
<b>4.5</b>	<b>Pré-Processamento</b>	<b>37</b>
<b>4.6</b>	<b>Experimentos</b>	<b>38</b>
<b>4.7</b>	<b>Medidas de Desempenho</b>	<b>39</b>
<b>5</b>	<b>Resultados</b>	<b>41</b>

<b>5.1</b>	<b>Experimento de Canais Individuais . . . . .</b>	<b>41</b>
<b>5.2</b>	<b>Experimento Multicanal . . . . .</b>	<b>44</b>
<b>6</b>	<b>Conclusão . . . . .</b>	<b>49</b>
	<b>REFERÊNCIAS . . . . .</b>	<b>50</b>

## 1 INTRODUÇÃO

A interface cérebro-computador (ICC), também chamada de interface cérebro-máquina, é um sistema de controle e comunicação que permite a interação do cérebro humano com dispositivos externos, por meio de sinais de controles gerados por ondas cerebrais. Essa tecnologia permite uma pessoa controlar o ambiente externo sem uso da habilidade física da pessoa. A ICC é um sistema dependente de um classificador, isso é, de uma *inteligência artificial*, que possa analisar os dados das ondas cerebrais, as diferenciar e classificar. O processo completo do funcionamento de uma ICC é: i) aquisição de sinal; ii) pré-processamento; iii) extração de atributos; iv) reconhecimento e classificação de padrões; e v) envio de sinais de controle para um dispositivo físico ou agente virtual (NICOLAS-ALONSO; GOMEZ-GIL, 2012; MAK; WOLPAW, 2009).

Um dos meios mais comuns de se adquirir o sinal é através da eletroencefalografia (EEG) não-invasiva. Esta capta a atividade elétrica do cérebro pelo couro cabeludo. Por ser um método não invasivo, pode ser aplicado em crianças e adultos com praticamente nenhum risco ou limitação (TEPLAN, 2002). Os sensores de EEG medem a diferença de potencial de um ponto da cabeça em relação a outro ponto, usado como referência. Seus sinais se caracterizam como sendo rítmicos, espontâneos e de baixa amplitude (da ordem de dezenas de  $\mu V$ ). Além disso, os sinais são diferentes para cada indivíduo; e dependem do estado físico, psicológico e comportamental (CANTARELLI; MENDES JÚNIOR; STEVAN JUNIOR, 2016). O sistema de aquisição consiste de eletrodos, que podem ser à seco ou com gel. Os eletrodos são feitos de ligas de prata, ouro, aço inoxidável ou estanho; amplificadores de sinais; conversores analógicos digitais; e de um sistema de gravação de dados. Assim, o sinal é adquirido do couro cabeludo. Há amplificação do sinal para que a digitalização via conversor A/D seja mais precisa, e por fim o sinal é exibido e/ou gravado em um dispositivo, como um computador (NICOLAS-ALONSO; GOMEZ-GIL, 2012; MAK; WOLPAW, 2009).

O desenvolvimento da tecnologia de ICC e o acesso fácil a dispositivos comerciais de eletroencefalografia seca não-invasiva evoluiu a pesquisa dos sinais cerebrais para uso além de uso clínico. Combinado com o uso de redes neurais e ferramentas de aprendizado, a leitura de ondas cerebrais tem seguido caminhos para acessibilidade, como controle de cadeira de rodas (VOZHENKO; CHEPIN; URVANOV, 2018), de movimento de próteses para pessoas com deficiência (HOCHBERG et al., 2006), podem ser usadas para digitar (KÜBLER et al., 2009), mover mouse (MCFARLAND et al., 2008), controlar avatares virtuais (AN; KIM; LEE,

2016), controlar veículos (ZHUANG; GENG; YIN, 2019), dentre várias outras aplicações. O desafio dessa área é a complexidade do sinal estudado, o mapeamento e a detecção de padrões para o uso dessas aplicações, já que além da grande quantidade de dados sendo transmitidos, tem-se que lidar com a não-linearidade, alta dimensionalidade, variação temporal do modelo e tempo de processamento dos dados para serem usados em tempo real (LEITE et al., 2012).

É nesse aspecto que ferramentas como redes neurais e inteligência artificial podem auxiliar no desenvolvimento da área. Os modelos tradicionais de classificação e de redes neurais geralmente são supervisionados, têm treinamento longo e necessitam de uma grande quantidade de dados para terem boas acurácias na sua tarefa (NICOLAS-ALONSO; GOMEZ-GIL, 2012), o que nem sempre é possível dependendo da situação do usuário. Sendo assim, é necessário desenvolver um método que possa suprir todos os requisitos apresentados e que se adapte ao usuário de maneira simples e menos exaustiva, trazendo uma maior flexibilidade na integração do ICC em situações cotidianas e no auxílio de pessoas portadoras de deficiências motoras.

E é nesse contexto que o uso de lógica fuzzy se torna prominente. A lógica fuzzy, ou lógica difusa, é por definição, uma lógica multivalorada, capaz de trabalhar com incertezas e informações ambíguas que outros tipos de lógica. Assim, sendo muito usada em problemas onde as manifestações de incerteza são difíceis de serem capturadas e analisadas, tal como é o caso da análise de sinais cerebrais via eletroencefalografia (HERMAN; PRASAD; MCGINNITY, 2017). Outra característica importante dos sistemas fuzzy é que as regras podem representar valores linguísticos, tendo assim melhor interpretabilidade na análise de dados do modelo.

Combinado à lógica fuzzy para essas situações, outras técnicas são usadas, como sistemas evolutivos. Segundo Lemos, Caminhas e Gomide (2013), sistemas evolutivos inteligentes são sistemas altamente adaptativos, sendo usados onde os problemas de modelagem e controle são não-estacionários e de ambiente dinâmico. Eles se diferenciam de sistemas adaptativos pelo fato desses conseguirem alterar somente seus parâmetros, já sistemas evolutivos são capazes de adaptar sua própria estrutura em conjunto com seus parâmetros baseado no fluxo de dados que eles recebem ao longo do tempo. Kasabov (1999) define sete requerimentos principais para um sistema ser considerado um sistema inteligente, eles são:

- capacidade de aprender rapidamente a partir de grande quantidade de dados;
- ser capaz de se adaptar em tempo real e a partir de fluxo de dados online;
- ter estrutura aberta capaz de se adaptar a novas características;

- ser baseado em memória;
- ser capaz de aprender e se melhorar a partir de interações com outros sistemas inteligentes e com o ambiente;
- representar adequadamente espaço e tempo em suas escalas;
- capacidade de se auto-analisar em aspectos como: comportamento, erro global, e sucesso.

Junto a isso, Lemos, Caminhas e Gomide (2013) mostra diversos tipos de sistemas inteligentes evolutivos, principalmente com foco em sistemas fuzzy, sendo esses divididos em sistemas baseados em regras, em árvores e sistemas neuro-fuzzy. Kasabov e Filev (2006) completa dizendo que “sistemas fuzzy e suas múltiplas interpretações neuro-fuzzy fornecem a base natural para sistemas evolutivos”. Isso se dá devido ao funcionamento do algoritmo: enquanto novos dados chegam, criam novos modelos locais (grânulos), novos modelos locais geram novas regras fuzzy para se adaptar aos dados, e com novas regras, temos a evolução da estrutura do sistema. Essa capacidade constitui a característica básica de sistemas evolutivos.

## 1.1 Objetivos

O objetivo desta monografia é explorar o uso da abordagem de modelagem online eGFC (*evolving Gaussian Fuzzy Classifier*) em classificação de sinais de eletroencefalografia gerados por estímulos áudio-visuais relativos à clipes musicais junto a interfaces cérebro-computador. Ademais, espera-se comparar a performance de modelos eGFC àquela de uma abordagem neuro-fuzzy evolutiva alternativa chamada DENFIS (*Dynamic Evolving Neuro-Fuzzy Inference System*). Pretende-se validar e aprimorar os algoritmos para uso em desenvolvimentos futuros ligados à área de ICC.

## 1.2 Organização do Texto

Esse trabalho é organizado da seguinte maneira: no capítulo 2 são introduzidos os conceitos de interface cérebro-computador, suas vantagens, seus problemas, usos e fundamentações. É descrito o uso de redes neurais e de modelos fuzzy aplicados à interfaces cérebro-computador. No capítulo 3 descreve-se os sistemas inteligentes evolutivos. São enfatizadas duas abordagens: DENFIS e eGFC. Suas formulações e comentários sobre aplicabilidade aos problemas em ICC são apresentados. No capítulo 4 descreve-se a metodologia experimental, a

obtenção dos dados, os passos de pré-processamento, as medidas de avaliação de desempenho, e as especificações de hardware e software. No capítulo 5, os resultados são exibidos e discutidos, expondo em imagens e tabelas aqueles mais significativos. Por fim, o capítulo 6 sumariza a pesquisa e os resultados. Reforça-se as conclusões obtidas da avaliação dos experimentos, e indica-se direções de continuação deste trabalho.

## 2 REDES NEURAIAS ARTIFICIAIS E SISTEMAS FUZZY EM INTERFACE CÉREBRO-COMPUTADOR

### 2.1 Fundamentos de ICC

Interfaces cérebro-computador são sistemas especializados capazes de obter sinais neurais e estabelecer uma comunicação direta do cérebro com equipamentos externos a partir da leitura, análise, classificação e interpretação dos sinais cerebrais para sinais de controle. Esses sinais podem ser extraídos por magnetoencefalografia, ressonância magnética, eletrocortico-grafia, espectroscopia no infravermelho próximo, entre outros. Ademais, em ICCs comerciais e para pesquisa é mais comum que sejam usados sensores secos ou em gel e não invasivos de eletroencefalografia, que são mais baratos, oferecem alta precisão temporal e realizam uma medida direta da atividade neural. Em contraste, a eletroencefalografia não invasiva, além de possuir maior complexidade em seu sinal, não consegue detectar bem sinais emitidos pelas estruturas subcorticais, devido à sua distância física e possui resolução espacial menor que dispositivos invasivos (VEGA-ESCOBAR; CASTRO-OSPINA; DUQUE-MUÑOZ, 2015; LIN; JUNG; ONTON, 2015; VASILJEVIC; MIRANDA, 2019). Há também o problema do decaimento da qualidade do sinal, já que como a extração é feita diretamente no couro cabeludo, há obstáculos, como pele e crânio, que dificultam a leitura, provocando uma razão de sinal-ruído de cerca de 5% (ZHANG et al., 2020). Outro inconveniente é que o uso prolongado de equipamentos ICCs acabam causando uma fadiga mental alta devido a alta necessidade de concentração ou atenção para os estímulos, podendo, devido à fadiga, não operarem de forma correta caso o usuário não consiga focar o suficiente no uso do equipamento (FERREIRA et al., 2013).

Por meio dessa tecnologia várias pessoas podem ser beneficiadas. Segundo Mak e Wolpaw (2009) os possíveis usuários são divididos em três grupos: i) pessoas com paralisia total, ii) pessoas com capacidade de controle muscular muito limitadas e iii) pessoas sem deficiência muscular que usariam de forma assistiva a tecnologia. Nesses casos a tecnologia teria uso para comunicação, locomoção, controle de ambiente, neuro-reabilitação, controles de interfaces virtuais, dentre outros. As aplicações do ICC também podem ser divididas, segundo Vasiljevic e Miranda (2019) como: i) invasiva ou não invasiva, ii) estímulo endógeno ou exógeno, iii) de processamento síncrono ou assíncrono e iv) sinal de controle passivo, ativo ou reativo.

Para que a ICC capte sinais de controle aos dispositivos, é necessário que ela reconheça padrões cerebrais específicos. Todavia, reconhecer e classificar pensamentos muito específicos

como “ligar/desligar equipamento” ou também “mover braço para a direita” são tarefas extremamente complicadas (FERREIRA et al., 2013). Os padrões cerebrais podem ser captados por meio de ondas, que podem ser divididas em cinco espectros de frequência sendo: ondas delta (abaixo de 4Hz), teta (4 a 7Hz), alfa (8 a 12Hz), beta (12 a 30Hz), e gama (acima de 30Hz), onde, respectivamente, são geradas durante o sono profundo e meditação, durante momentos de sonolência, concentração meditativa e em uma grande gama de processos cognitivos como cálculos puramente mentais, durante relaxamento, durante atividades motoras e durante processamento simultâneo de informação (VASILJEVIC; MIRANDA, 2019). A partir dessas ondas, há três estados mentais que se pode reconhecer com precisão, Ferreira et al. (2013) os define como: i) concentração, usando as ondas alfa e beta; ii) resposta a estímulo visual e sonoros; iii) e imaginação de movimento, quando se imagina parte do corpo, como mãos ou braço se movendo.

A captação desses sinais, no caso do EEG não invasivo, é feita por eletrodos no couro cabeludo. A posição desses eletrodos são geralmente baseadas no sistema internacional de posição 10-20 para eletrodos, padronizado pela Sociedade Americana de Eletroencefalografia, o sistema usa de referência o nariz e íonion, onde a posição dos eletrodos é feita a partir de afastamentos de 10 e 20 graus no plano mediano e horizontal do crânio (NICOLAS-ALONSO; GOMEZ-GIL, 2012) e são fixados e nomeados de acordo com a área do cérebro adjacente: F para a área frontal, C para a central, T para a temporal, P para a posterior e O para a occipital. As letras ainda são acompanhadas por números, onde a parte direita do cérebro (do ponto de vista da pessoa que está com os eletrodos na cabeça) tem números pares e a parte esquerda com números ímpares (TEPLAN, 2002).

O reconhecimento de estímulos visuais ou sonoros se classifica em estímulos oscilatórios e transientes. O primeiro se dá quando há um mesmo estímulo que se executa repetidamente em uma mesma frequência, havendo diferenciação nos estímulos dependendo da frequência em que o estímulo oscila. No padrão transiente há mudança no que está sendo ouvido ou visto, como a mudança de uma tela preta para uma colorida, ou de um som grave contínuo para um agudo (MAK; WOLPAW, 2009; FERREIRA et al., 2013). A ativação cerebral por estímulos é chamada de potencial evocado, também conhecido como potencial relacionado a eventos. São flutuações altas na amplitude dos sinais cerebrais causadas por estímulos externos ou internos (TEPLAN, 2002). Essas variações são mensuráveis no instante que a pessoa recebe o estímulo ou gatilho, tendo variações temporais dependendo do tipo de estímulo apresentado, como o

N100, uma onda que tem seu pico negativo em 100ms, associada ao mecanismo de desencadeamento de atenção, geralmente seguida da P200, com amplitude positiva e pico em cerca de 200ms, ou a P300, onda positiva de pico em cerca de 300ms de longa amplitude ou latência, gerado devido ao estímulo de mudança repentina no padrão acostumado (LOTTE; BOUGRAIN; CLERC, 2015; CHIEN; HSIEH; GAU, 2019), essa última sendo muito estudada junto a ICC usando EEG.

Uma preocupação que se deve ter junto a obtenção de sinal de EEG é a tentativa de deixar o sinal o mais limpo possível, ou seja, sem ruídos. Os ruídos na leitura de EEG podem vir de diversas fontes, como piscar dos olhos, movimentos musculares do pescoço, movimento dos olhos, fechamento da mandíbula ou movimento da língua. Esse tipo de ruído é conhecido como artefato biológico (ANGHINAH et al., 2006) e são muito difíceis de serem evitados, principalmente pelas componentes ocorrerem nas frequências de onda cerebral. Também podem ser do ambiente, como interferência eletromagnética, de radiofrequência ou do ruído de rede (SWEENEY; WARD; MCLOONE, 2012). Além disso, a amplitude dos artefatos biológicos é maior do que a de potencial evocado, os sinais de EEG variam em dezenas de  $\mu V$ , enquanto os oculares (EOG) e musculares (EMG) são da ordem de centenas de  $\mu V$  (NOLAN; WHELAN; REILLY, 2010). Um dos meios de remover parte dos artefatos é com o uso de filtros, por exemplo um filtro passa-alta para remover sinais gerados por respiração, um passa-baixa com frequência de corte no sinal mais alto de interesse, como de 40 a 50 Hz pode ajudar também a remover o ruído de rede (TEPLAN, 2002; SWEENEY; WARD; MCLOONE, 2012). Há também o uso de análise de componentes independentes, filtros da Kalman, análise de correlação canônica, filtros bayesianos e diversos outros meios que dependem da qualidade dos sensores, quantidade de canais registrados, capacidade de operação online, dentre outros vários fatores para determinar os métodos de remoção de artefatos (SWEENEY; WARD; MCLOONE, 2012).

## 2.2 Rede Neural Aplicada a ICC

Redes neurais são modelos inspirados em como o cérebro processa informação, para poder processar tarefas de forma melhor que um programa normal de computador. Por serem capazes de aprender depois de treinadas e conseguir classificar com maior facilidade, são usadas nas ICC no intuito de verificar os padrões das intenções do usuário (NICOLAS-ALONSO; GOMEZ-GIL, 2012). Nisso, há uma gama gigantesca de redes neurais sendo aplicadas para uso em interfaces cérebro-computador, tendo em vista a possibilidade de se obter uma grande

quantidade de dados do usuário para conjuntos de treinamento e testes, aplicações como redes neurais tendem a funcionar bem.

Uma das vantagens das redes neurais é que elas podem ser usadas em sua forma clássica na literatura, como o uso de rede neural Multi-layer Perceptron (NNMLP) para classificação, demonstrada por Subasi e Erçelebi (2005), ou o uso de NNMLP combinada com clusterização k-means como exposto por Orhan, Hekim e Ozer (2011). Uma abordagem que vem sendo bastante estudada são as redes neurais convolucionais, muito aplicadas à análise e classificação de imagens, áudios e linguagem natural, têm ganhado campo nas interfaces cérebro-computador, como por exemplo em Maddula et al. (2017), Tattoli et al. (2014), Dose et al. (2018). Todavia, como é falado em Xu et al. (2019), há problemas ainda no uso de redes convolucionais, que são relacionadas ao fato dos dados de EEG não serem rotulados, dificultando o treinamento da rede neural, que por sua vez, é muito dispendioso em tempo e em capacidade computacional, o que faz a transferência de aprendizado ser uma das soluções para esses problemas.

Outros métodos incluem combinar redes neurais com soluções como otimização de enxames de partículas, onde é usada uma rede neural de bases radiais para minimizar o erro médio quadrático, e a otimização de enxames para alcançar o mínimo global mais rápido, chegando a resultados altos para identificação de epilepsia (SATAPATHY; DEHURI; JAGADEV, 2017). Outra alternativa proposta na literatura é usar redes neurais recorrentes (RNN), junto com expoentes de Lyapunov, para tratar a dinâmica temporal do EEG (GÜLER; ÜBEYLI; GÜLER, 2005). A customização e capacidade de agregação de múltiplas soluções faz das redes neurais ferramentas versáteis, adaptáveis e, que se bem parametrizadas consigam alta acurácia para os conjuntos de testes.

### **2.3 Sistemas Fuzzy Aplicados a ICC**

Vários estudos propõem sistemas fuzzy para uso em ICCs, principalmente devido as características de versatilidade da lógica fuzzy, como adaptabilidade a ambientes dinâmicos e não estacionários, capacidade de lidar com conjuntos complexos de dados e trabalhar bem com incerteza e, no final, poder prover interpretabilidade a partir das regras geradas. Todavia, os modelos fuzzy variam de aplicação a aplicação, tentando alcançar objetivos diferentes ao longo da abordagem desejada, tal como os usos do Fuzzy Tipo 2 analisando imaginação motora apresentados em Bhattacharyya et al. (2015), em Nguyen et al. (2015) e em Herman, Prasad e McGinnity (2017), onde é apresentado um algoritmo treinado para uso offline e online, que

no fim mostra resultados melhores que algoritmos convencionais, como Máquina de Vetores de Suporte (SVM) e k-Vizinhos mais Próximos (kNN) para o problema estabelecido.

Redes neuro-fuzzy também são comuns nas aplicações de ICC, com algoritmos que atuam de forma supervisionada ou não supervisionada, isso é, possuindo respostas conhecidas ou não para o conjunto de dados de entrada (CANO-IZQUIERDO; IBARROLA; ALMONACID, 2012), criadas como métodos para treinar mais rápido, minimizar erros (COYLE; PRASAD; MCGINNITY, 2009) e para aprimorar o conjunto de dados com técnicas fuzzy, como o uso de algoritmo de entropia fuzzy por Cao e Lin (2018), onde o parâmetro de entropia fuzzy é comparado a outros tipos de entropia na classificação de sinais de eletroencefalograma. A combinação com redes neurais leva a algoritmos que conseguem melhorar o aprendizado deles a cada passo e informação nova, dando um passo a mais, para algoritmos mais complexos como lógicas fuzzy adaptativas (ANFIS) e evolutivas, como demonstrado em Güler e Übeyli (2005) e Xydeas et al. (2006), nesse último, apresentando uma lógica fuzzy combinada com modelo oculto de Markov para melhorar a performance de classificação.

Outros métodos também acompanham a lógica fuzzy, a fim de deixá-la mais eficiente, como a otimização de enxames de partículas, discutida em Chai et al. (2014) e em Wu et al. (2017). O primeiro explora uma rede neural combinada a um método que chamam de “Otimização de Enxame de Partículas Fuzzy com Operação de Mutação Cruzada” para tentar achar o modelo ótimo global e não ficar preso a um ótimo local, onde os autores afirmam que a transformada de Hilbert-Huang consegue dar resultados melhores que a transformada de Fourier em ICCs com uso de EEG. Por outro lado, Wu et al. (2017) discute o uso de integrais fuzzy combinadas com a otimização de enxames para aprimorar os resultados e a confiabilidade do classificador.

Todos esses trabalhos levam a perceber uma evolução contínua de métodos de extração de parâmetros, processamento e classificação, com melhoras nos dados e nos próprios algoritmos, buscando resultados mais eficientes, mais acurados e mais rápidos para que essa tecnologia possa ser levada para fora do laboratório.

## **2.4 Outros algoritmos de aprendizado de máquinas aplicados a ICC**

Além dos algoritmos apresentados, vários outros métodos são usados para o aprendizado e classificação de dados EGG junto a ICC, tais como Máquina de Vetores de Suporte (SVM), Perceptron Multi-Camadas (MLP), Floretas de Decisão Aleatória (RF), k-Vizinhos mais Pró-

ximos (kNN) e Análise Linear Discriminante (LDA), alguns auxiliados de ferramentas como Análise de Componentes Principais (PCA), são ainda vistos em literaturas recentes e apresentam bons resultados (ALICKOVIC; KEVRIC; SUBASI, 2018; RICHHARIYA; TANVEER, 2018; SUBASI; GURSOY, 2010; RAHMAN et al., 2020).

A relevância desses classificadores fica maior quando são usados algoritmos conhecidos de formas aprimoradas, como em Xue, Gu e Ni (2020) que usa um método chamado, em tradução livre, de “Método de Aprendizado Métrico Discriminativo de Multivisualização Ponderado Automaticamente (AMDML), com o Discriminante de Fisher”. Onde o autor busca usar algoritmos como kNN e SVM, já aprimorados com o AMDML para classificação e também compara com vários métodos de classificação e aprendizado *multi-view* - onde os dados vem de diversas fontes diferentes, como de eletroencefalografia, rastreamento ocular e eletromiografia - e *single-view* - onde os dados vem de um mesmo tipo de fonte, como eletroencefalografia-, obtendo melhores performances em todos os casos.

E mesmo com uma predominância de técnicas, ainda surgem novos meios de decomposição de dados e classificação, como em Li et al. (2020), no que o autor chama de “aprendizado de máquina quântico”, que extrai parâmetros usando a “transformação de pacotes wavelets quânticos”, onde o classificador é uma máquina de vetor de suporte quântica aprimorada. Esse tipo de estudo combina princípios da mecânica quântica e da computação quântica e traz para o aprendizado de máquina, para tentar achar métodos que sejam superiores aos métodos convencionais, mostrando que há muito espaço para técnicas novas tanto no aprendizado de máquina quanto em interfaces cérebro-computador.

### 3 SISTEMAS INTELIGENTES EVOLUTIVOS

#### 3.1 Conceitos Básicos

Os Sistemas Inteligentes Evolutivos (EIS), são sistemas baseados em técnicas fuzzy e neuro-fuzzy que permitem que a estrutura e a funcionalidade de um sistema se desenvolvam e evoluam a partir dos dados recebidos. São diferentes de modelos adaptativos e modelos tradicionais de aprendizado de máquina, onde normalmente se assume que os processos têm distribuição gaussiana e natureza aleatória. Os EIS representam uma mistura difusa de sistemas mais simples válidos localmente, que em combinação são altamente não lineares e não gaussianos. Eles podem ser considerados misturas fuzzy de gaussianas, mas essas misturas não são pré-fixadas e estão se adaptando/evoluindo para capturar a distribuição de densidade de dados real. É importante ressaltar que os sistemas inteligentes a qual se falam, diferem dos sistemas que são chamados comercialmente de inteligentes, já que esses param de aprender/evoluir quando são produzidos e comercializados, os EIS são sistemas que têm ênfase em auto-adaptação durante todo seu período de uso/funcionamento, isso é, os EIS são capazes de abordar problemas de modelagem, controle, previsão, classificação, processamento de dados e seleção de recursos em um ambiente não estacionário e dinâmico em constante mudança (LEMOS; CAMINHAS; GOMIDE, 2013; ANGELOV; FILEV; KASABOV, 2010).

Um dos meios desenvolvidos para que os EIS fossem eficientes e pudessem lidar com a problemática apresentada são os sistemas evolutivos baseados em regras. Esse tipo de modelo usa as informações que podem estar presentes em uma nova amostra de dados que chega ao classificador como gatilho para atualizar sua base de regras, garantindo generalidade das mudanças estruturais. O mecanismo de evolução desses sistemas conta com agrupamento, adição e deleção de regras. Os modelos geram novas regras se houver novas informações que sejam significativas em uma nova amostra, e, se os novos dados que são aceitos como pontos focais de uma nova regra estiverem muito próximos de uma regra existente, a regra antiga é substituída pela nova. Quando há uma nova regra adicionada, significa que mais uma região no espaço, antes sem regras, agora possui um modelo matemático a representando dentro do sistema de classificação. Também é de se notar que esses sistemas podem começar sem informações *a priori* e irem se adaptando com a chegada de novas amostras de dados (ANGELOV; FILEV, 2004)

Este trabalho aprofundará em dois modelos evolutivos baseado em regras, o eGFC e o DENFIS.

### 3.2 eGFC

O evolving Gaussian Fuzzy Classifier (eGFC) é um classificador semi-supervisionado, capaz de construir e adaptar sua estrutura e parâmetros ao longo do fluxo de dados. O modelo foi proposto em Leite et al. (2020) e é derivado do modelo fuzzy evolutivo granular apresentado em Leite et al. (2012). O eGFC usa funções de pertinência Gaussianas para cobrir o espaço dos dados com grânulos fuzzy (modelos locais) e associa novos dados à rótulos de classe. Grânulos são espalhados (abordagem *scattering*) sempre que necessário para representar novas informações locais. A estimativa global do modelo eGFC vem da agregação fuzzy de respostas locais. Um algoritmo recursivo constrói sua base de regras e atualiza grânulos para lidar com novidades. O método lida com quantidades ilimitadas de dados e escalabilidade computacional (LEITE, 2012; DECKER et al., 2020).

Modelos locais são criados caso os novos dados sejam suficientemente diferentes do conhecimento atual expresso em regras fuzzy. O algoritmo de aprendizado pode expandir, comprimir, deletar e mesclar grânulos. As regras podem ser revistas a partir de relações inter-grânulos. O eGFC fornece fronteiras fuzzy entre classes. Tais fronteiras são não-lineares, não-abruptas e não-estacionárias.

#### 3.2.1 Regras eGFC

O aprendizado de um modelo eGFC não depende de regras iniciais. As regras são criadas e atualizadas dependendo do comportamento do sistema ao longo do tempo. Quando uma amostra de dados está disponível, uma regra pode ser adicionada, ou os parâmetros de uma regra muito ativa podem ser adaptados. Uma regra  $R^i$  tem a forma:

$$\begin{aligned} &\text{SE } (x_1 \text{ é } A_1^i) \text{ E } \dots \text{ E } (x_n \text{ é } A_n^i) \\ &\text{ENTÃO } (y \text{ é } C^i) \end{aligned}$$

em que  $x_j$ ,  $j = 1, \dots, n$ , são atributos, e  $y$  é uma classe. O fluxo de dados é  $(\mathbf{x}, y)^{[h]}$ ,  $h = 1, \dots$ . Além disso,  $A_j^i$ ,  $\forall j$ ; são funções Gaussianas; e  $C^i$  é o rótulo de classe da  $i$ -ésima regra. As regras  $R^i$ ,  $\forall i$ , formam uma base. O número de regras,  $c$ , é variável, o que é uma característica notável da abordagem, pois a suposição de quantas partições existem é dispensável (SKRJANC et al., 2019; LEITE, 2012).

Uma função Gaussiana normal,  $A_j^i = G(\mu_j^i, \sigma_j^i)$ , é caracterizada pelo valor modal  $\mu_j^i$  e dispersão  $\sigma_j^i$ . As características que tornam esta representação atrativa são: (i) facilidade de aprendizado, i.e., valores modais e dispersões são atualizados diretamente a partir do fluxo; (ii) suporte infinito, i.e., o suporte de Gaussianas se estende por todo o domínio; e (iii) curvas de nível suave de grânulos fuzzy,  $\gamma^i = A_1^i \times \dots \times A_n^i$ , no espaço Cartesiano  $n$ -dimensional – obtido pela extensão cilíndrica de Gaussianas unidimensionais e uso da T-norma *min* (PEDRYCZ; GOMIDE, 2007).

### 3.2.2 Inserção de Regras

Regras eGFC são criadas a medida que os dados são disponibilizados. Um novo grânulo  $\gamma^{c+1}$  e a regra  $R^{c+1}$  são criados se nenhuma das regras existentes  $\{R^1, \dots, R^c\}$  são suficientemente ativadas por  $\mathbf{x}^{[h]}$ . Seja  $\rho^{[h]} \in [0, 1]$  um valor limiar. Sendo:

$$T\left(A_1^i(x_1^{[h]}), \dots, A_n^i(x_n^{[h]})\right) \leq \rho^{[h]}, \forall i, i = 1, \dots, c, \quad (3.1)$$

em que  $T$  é a norma *min*, então a estrutura do modelo é expandida. Se  $\rho^{[h]} = 0$ , então o modelo tem estrutura estável. Se  $\rho^{[h]} = 1$ , o modelo acrescenta uma regra para cada nova amostra. Um balanço entre adaptabilidade estrutural e paramétrica é obtido para valores intermediários (compromisso estabilidade-plasticidade) (LEITE; COSTA; GOMIDE, 2013).

Um novo grânulo  $\gamma^{c+1}$  é inicialmente representado pelas funções de pertinência,  $A_j^{c+1}$ ,  $j = 1, \dots, n$ , em que:

$$\mu_j^{c+1} = x_j^{[h]}, \quad \text{e} \quad \sigma_j^{c+1} = 1/2\pi. \quad (3.2)$$

A Equação (3.2) é a abordagem de Stigler para funções Gaussianas padrões (STIGLER, 1982; LEITE et al., 2020). A ideia é inicializar grânulos ‘grandes’ e deixar suas dispersões reduzirem quando novas amostras os ativam. Em geral, a classe  $C^{c+1}$  da regra  $R^{c+1}$  é indefinida, e.g., a  $(c + 1)$ -ésima regra permanece sem rótulo até que uma amostra rotulada seja fornecida. Se a saída correspondente,  $y^{[h]}$ , associada a  $\mathbf{x}^{[h]}$ , está disponível, então:

$$C^{c+1} = y^{[h]}. \quad (3.3)$$

Caso contrário, a primeira amostra rotulada que surgir e ativar a regra  $R^{c+1}$  é usada para definir sua classe,  $C^{c+1}$ .

Caso uma amostra rotulada ativar uma regra rotulada, mas seus rótulos forem diferentes, um novo grânulo (parcialmente sobreposto) e uma regra são criados para representar a nova informação. Grânulos parcialmente sobrepostos, com rótulos diferentes, tendem a ter dispersão reduzida ao longo do tempo. Os valores modais tendem a se afastar para gerar uma fronteira adequada. Modelos eGFC executam o princípio da granularidade balanceada (WANG et al., 2016; LEITE et al., 2020).

### 3.2.3 Atualização Incremental

Atualizar o modelo eGFC consiste em: (i) reduzir ou expandir  $A_j^{i*} \forall j$ , do grânulo mais ativo  $\gamma^{i*}$ ; (ii) mover o grânulo em direção a regiões de maior volume de dados; e (iii) rotular regras quando dados rotulados surgem. A adaptação busca desenvolver modelos locais mais específicos (YAGER, 2008) e envolver os dados.

A regra  $R^i$  é candidata a ser atualizada se é suficientemente ativada por uma amostra  $\mathbf{x}^{[h]}$  a partir de:

$$\min \left( A_1^i(x_1^{[h]}), \dots, A_n^i(x_n^{[h]}) \right) > \rho^{[h]}. \quad (3.4)$$

Neste caso,  $\mathbf{x}^{[h]}$  pertence a uma região muito influenciada pelo grânulo  $\gamma^i$ . Apenas a regra mais ativa,  $R^{i*}$ , é escolhida para adaptação. Para uma amostra rotulada, *i.e.*, dado  $(\mathbf{x}, y)^{[h]}$ , a regra  $R^{i*}$  mais ativa deve ter a mesma classe para ser escolhida. De outro modo, a segunda regra mais ativa dentre aquelas que alcançaram o nível  $\rho^{[h]}$  é escolhida para adaptação, e assim por diante. Se nenhuma das regras for apta, uma nova regra é criada.

Para incluir  $\mathbf{x}^{[h]}$  em  $R^{i*}$ , o algoritmo eGFC atualiza os valores modais e dispersões de  $A_j^{i*} \forall j$  segundo:

$$\mu_j^{i^*}(novo) = \frac{(\varpi^{i^*} - 1)\mu_j^{i^*}(velho) + x_j^{[h]}}{\varpi^{i^*}}, \quad (3.5)$$

e

$$\begin{aligned} \sigma_j^{i^*}(novo) = & \left( \frac{(\varpi^{i^*} - 1)}{\varpi^{i^*}} \left( \sigma_j^{i^*}(velho) \right)^2 + \right. \\ & \left. + \frac{1}{\varpi^{i^*}} \left( x_j^{[h]} - \mu_j^{i^*}(velho) \right)^2 \right)^{1/2}, \end{aligned} \quad (3.6)$$

em que  $\varpi^{i^*}$  é o número de vezes que a  $i^*$ -ésima regra foi escolhida. Como  $\sigma^{i^*}$  define uma região convexa ao redor de  $\mu^{i^*}$ , valores muito grandes ou muito pequenos induzem um único ou vários grânulos por classe. Assim, mantemos  $\sigma_j^{i^*}$  entre limites inferior,  $1/4\pi$ , e de Stigler,  $1/2\pi$ .

### 3.2.4 Adaptação do Nível $\rho$

Seja  $\rho^{[h]} \in [0, 1]$  variante no tempo. Seja a dispersão média global do mapa granular dada por:

$$\sigma_{avg}^{[h]} = \frac{1}{cn} \sum_{i=1}^c \sum_{j=1}^n \sigma_j^{i[h]}; \quad (3.7)$$

$c$  e  $n$  são a quantidade de regras e atributos. Logo:

$$\rho(novo) = \frac{\sigma_{avg}^{[h]}}{\sigma_{avg}^{[h-1]}} \rho(velho). \quad (3.8)$$

Como mencionado, a ativação das regras para uma entrada  $\mathbf{x}^{[h]}$  é comparada a  $\rho^{[h]}$  para decisão entre mudança paramétrica ou estrutural do modelo eGFC. Em geral, o modelo começa a aprender sem qualquer regra. A prática sugere  $\rho^{[0]} = 0, 1$  como valor inicial. O parâmetro tende a convergir para um valor adequado, e a estrutura do classificador se tornar estável. Novidades levam  $\rho^{[h]}$  a valores que melhor refletem o ambiente atual.

### 3.2.5 Mescla de Regras

Duas regras com o mesmo rótulo podem ser similares, e sugerir apenas uma é suficiente.

Seja:

$$d(\gamma^{i1}, \gamma^{i2}) = \frac{1}{n} \left( \sum_{j=1}^n |\mu_j^{i1} - \mu_j^{i2}| + \sigma_j^{i1} + \sigma_j^{i2} - 2\sqrt{\sigma_j^{i1} \sigma_j^{i2}} \right); \quad (3.9)$$

$d(\cdot)$  é a distância entre  $\gamma^{i1}$  e  $\gamma^{i2}$ . Essa medida considera a especificidade da informação, que, por vez, é inversamente proporcional à dispersão (LEITE et al., 2020).

O algoritmo pode mesclar o par de regras de menor  $d(\cdot)$ . As regras devem ter o mesmo rótulo ou não possuírem um. A decisão é baseada no limiar  $\Delta$ . Para dados re-escalados em  $[0, 1]^n$ , é sugerido  $\Delta = 0, 1$  como valor padrão.

O novo grânulo  $\gamma^i$ , resultado da mescla de  $\gamma^{i1}$  e  $\gamma^{i2}$ , é construído por Gaussianas com valor modal:

$$\mu_j^i = \frac{\frac{\sigma_j^{i1}}{\sigma_j^{i2}} \mu_j^{i1} + \frac{\sigma_j^{i2}}{\sigma_j^{i1}} \mu_j^{i2}}{\frac{\sigma_j^{i1}}{\sigma_j^{i2}} + \frac{\sigma_j^{i2}}{\sigma_j^{i1}}}, \quad j = 1, \dots, n, \quad (3.10)$$

e dispersão:

$$\sigma_j^i = \sigma_j^{i1} + \sigma_j^{i2}, \quad j = 1, \dots, n. \quad (3.11)$$

A mescla de regras eGFC minimiza redundâncias (SKRJANC et al., 2019; LEITE, 2012).

### 3.2.6 Remoção de Regras

Uma regra é removida do modelo eGFC se ela é inconsistente com o ambiente atual. Em outras palavras, se a regra não é ativada por um número de passos de tempo,  $h_r$ , então a regra é apagada da base de regras. Contudo, se a classe for rara, então pode ser o caso de considerar

$h_r = \infty$ , e manter a regra inativa no modelo. Remover regras pode ajudar a manter o modelo atualizado.

### 3.2.7 Algoritmo eGFC

O procedimento de aprendizado para construir e atualizar modelos eGFC pode ser descrito pelo seguinte pseudo-algoritmo:

---

#### Algoritmo 1 - eGFC: Aprendizado Online

---

- 1: Número de regras,  $c^{[0]} = 0$ ;
  - 2: Parâmetros iniciais,  $\rho^{[0]} = 0, 1; \Delta = 0, 1; h_r = 200$ ;
  - 3: Ler amostra  $\mathbf{x}^{[h]}$ ,  $h = 1$ ;
  - 4: Criar grânulo  $\gamma^{c+1}$  (Eqs. (3.2)), classe  $C^{c+1}$  indef.;
  - 5: **FOR**  $h = 2, \dots$  **DO**
  - 6:   Ler  $\mathbf{x}^{[h]}$ , calcular ativação de regras (Eq. (3.1));
  - 7:   Determinar a regra mais ativa  $R^{i^*}$ ;
  - 8:   Fornecer classe estimada  $C^{i^*}$ ;
  - 9:   **IF**  $T(A_1^i(x_1^{[h]}), \dots, A_n^i(x_n^{[h]})) \leq \rho^{[h]} \forall i, i = 1, \dots, c$
  - 10:     **IF** classe  $y^{[h]}$  está disponível
  - 11:       Criar grânulo  $\gamma^{c+1}$ , classe def. (Eqs. (3.2)-(3.3));
  - 12:     **ELSE**
  - 13:       Criar grânulo  $\gamma^{c+1}$ , classe indef. (Eqs. (3.2));
  - 14:     **END**
  - 15:   **ELSE**
  - 16:     **IF** classe  $y^{[h]}$  está disponível
  - 17:       Atualizar grânulo mais ativo  $\gamma^{i^*}$  cuja classe  $C^{i^*}$  é igual a  $y^{[h]}$  (Eqs. (3.5)-(3.6));
  - 18:       Rotular grânulos ativos sem rótulo;
  - 19:     **ELSE**
  - 20:       Atualizar grânulo  $\gamma^{i^*}$  mais ativo (Eqs. (3.5)-(3.6));
  - 21:     **END**
  - 22:   **END**
  - 23:   Atualizar nível  $\rho$  (Eqs. (3.7)-(3.8));
  - 24:   Remover regras inativas baseado em  $h_r$ ;
  - 25:   Mesclar regras baseado em  $\Delta$  (Eqs. (3.9)-(3.11));
  - 26: **END**
- 

### 3.3 DENFIS

O Dynamic Evolving Neural-Fuzzy Inference System (DENFIS) é um algoritmo fuzzy evolutivo proposto por Kasabov e Song (2002). O modelo usa em seu processo de aprendizagem o sistema de inferência fuzzy de Takagi-Sugeno, assim como o estimador linear de mínimos quadrados (LSE) também é usado para a seleção de regras fuzzy. Tanto no modelo de operação

online como no offline as funções de pertinência são triangulares e dependentes dos parâmetros dados na Equação (3.12), onde  $b$  é o valor do centro do *cluster* na dimensão  $x$ ,  $a = b - d \times D_{thr}$  e  $c = b + d \times D_{thr}$ ,  $d = 1.2 \sim 2$ ; e  $D_{thr}$  é o parâmetro de agrupamento.

$$\mu(x) = mf(x, a, b, c) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a \leq x \leq b \\ \frac{c-x}{c-b}, & b \leq x \leq c \\ 0, & c \leq x \end{cases} \quad (3.12)$$

### 3.3.1 Método de Agrupamento Evolutivo (ECM)

O método de agrupamento (*clustering*) evolutivo (*Evolving Clustering Method*) é usado no DENFIS para calcular dinamicamente os grupos (*clusters*) e os centros desses grupos dentro do conjunto de dados. Esse método é baseado no método de distância Euclidiana apresentado em (3.13).

$$\|x - y\| = \frac{\left(\sum_{i=1}^q |x_i - y_i|^2\right)^{\frac{1}{2}}}{q^{\frac{1}{2}}}, \quad (3.13)$$

onde  $x, y \in R^q$

No processo de agrupamento, os dados vêm de um fluxo. Esse processo começa com um conjunto vazio de grupos. Quando um novo *cluster* é criado, o centro do *cluster* é definido e seu raio é inicialmente zero. Com mais exemplos apresentados um após o outro, alguns *cluster* criados serão atualizados por meio da alteração das posições de seus centros e aumentando seus raios. Qual *cluster* será atualizado e o quanto será alterado depende da posição do exemplo atual no espaço de entrada. Um *cluster* não será mais atualizado quando seu raio atingir o valor que é igual a um valor limite,  $D_{thr}$ .

### 3.3.2 Sistema de Inferência de Takagi-Sugeno

O sistema de inferência utilizado no DENFIS é baseado nos modelos de Takagi-Sugeno (TAKAGI; SUGENO, 1985; SUGENO; KANG, 1988), e atua de acordo com (3.14). Além de criar e atualizar regras difusas de forma dinâmica, o modelo online DENFIS tem algumas

outras diferenças importantes em relação aos outros sistemas de inferência. Primeiro, para cada vetor de entrada, o modelo escolhe regras dentre todas do conjunto para formar um sistema de inferência atual. Esta operação depende da posição do vetor de entrada atual no espaço de entrada. No caso de dois vetores de entrada muito próximos, especialmente no modelo DENFIS offline, o sistema de inferência pode ter o mesmo grupo de inferência de regras fuzzy. No modelo online DENFIS, entretanto, mesmo que dois vetores de entrada sejam exatamente iguais, seus sistemas de inferência correspondentes podem ser diferentes. Isso ocorre porque esses dois vetores de entrada são apresentados ao sistema em momentos diferentes e as regras fuzzy usadas para o primeiro vetor de entrada podem ter sido atualizadas antes da chegada do segundo vetor de entrada. Em segundo lugar, dependendo da posição do vetor de entrada atual no espaço de entrada, os antecedentes das regras fuzzy escolhidas para formar um sistema de inferência para esse vetor de entrada podem variar (KASABOV; SONG, 2002). Considere as regras fuzzy conforme:

$$\left\{ \begin{array}{l} \text{se } x_1 \text{ é } R_{11} \text{ e } x_2 \text{ é } R_{12} \text{ e...e } x_q \text{ é } R_{1q}; \text{ então } y \text{ é } f_1(x_1, x_2, \dots, x_q) \\ \text{se } x_1 \text{ é } R_{21} \text{ e } x_2 \text{ é } R_{22} \text{ e...e } x_q \text{ é } R_{2q}; \text{ então } y \text{ é } f_2(x_1, x_2, \dots, x_q) \\ \text{se } x_1 \text{ é } R_{m1} \text{ e } x_2 \text{ é } R_{m2} \text{ e...e } x_q \text{ é } R_{mq}; \text{ então } y \text{ é } f_m(x_1, x_2, \dots, x_q) \end{array} \right. \quad (3.14)$$

Onde  $x_j \text{ é } R_{ij}, i = 1, 2, \dots, m; j = 1, 2, \dots, q$ ; são  $m \times q$  proposições fuzzy que formam  $m$  antecedentes para  $m$  regras fuzzy.  $x_j, j = 1, 2, \dots, m$  são variáveis antecedentes definidas sobre o domínio da quantificação (universo de discurso,  $\mathbb{D}$ )  $X_j, j = 1, 2, \dots, q$  e  $R_{ij}, i = 1, 2, \dots, m; j = 1, 2, \dots, q$  são conjuntos fuzzy definidos pela sua função de pertinência  $\mu_{R_{ij}} : X \rightarrow [0, 1], i = 1, 2, \dots, m; j = 1, 2, \dots, q$ . Nas partes subsequentes das regras fuzzy,  $y$  é a variável consequente, e as funções *crisp*  $f_i, i = 1, 2, \dots, m$  são empregadas.

### 3.3.3 Aprendizado Online do modelo DENFIS

Para o processo de aprendizagem, o modelo do DENFIS usa o processo de interferência de Takagi-Sugeno descrito em 3.3.2 e as funções lineares podem ser criadas e atualizadas pelo estimador linear de mínimos quadrados (LSE) a partir dos dados de aprendizagem, o estimador é descrito em Zhu (2001). No DENFIS online é usado o estimador de mínimos quadrados ponderados (GOODWIN; SIN, 1984). A função linear pode ser descrita da seguinte forma:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_q x_q. \quad (3.15)$$

Para obter estas funções um conjunto de dados de aprendizagem é utilizado, o qual é composto de  $p$  pares de dados  $\{(x_{i1}, x_{i2}, \dots, x_{iq})y_i, i = 1, 2, \dots, p\}$ , e o LSE de  $\beta = [b_0 \ b_1 \ b_2 \ \dots \ b_q]^T$  são calculados como os coeficientes  $mbib = [b_0 \ b_1 \ b_2 \ \dots \ b_q]^T$  aplicando a Fórmula (3.16).

$$b = (A^T A)^{-1} A^T y, \quad (3.16)$$

onde

$$A = \begin{pmatrix} 1 & x_{11} & x_{12} & \dots & x_{1q} \\ 1 & x_{21} & x_{22} & \dots & x_{2q} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{p1} & x_{p2} & \dots & x_{pq} \end{pmatrix} \quad (3.17)$$

$$y = [y_1 \ y_2 \ \dots \ y_p]^T. \quad (3.18)$$

O estimador de mínimos quadrados ponderados é definido como:

$$b_w = (A^T W A)^{-1} A^T W y, \quad (3.19)$$

onde

$$W = \begin{pmatrix} w_1 & 0 & \dots & 0 \\ 0 & w_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & \dots & \dots & w_p \end{pmatrix} \quad (3.20)$$

e  $w_j$  é a distância entre o  $j$ -ésimo exemplo e o centro do *cluster* correspondente,  $j = 1, 2, \dots, p$ . As equações (3.16) e (3.19) podem ser reescritas como:

$$\begin{cases} P = (A^T A)^{-1} \\ b = P A^T y \end{cases} \quad (3.21)$$

$$\begin{cases} P_w = (A^T W A)^{-1} \\ b_w = P_w A^T W y \end{cases} \quad (3.22)$$

No modelo online, as regras são criadas e atualizadas ao mesmo tempo que o particionamento do espaço de entrada usando ECM. Se nenhuma inserção de regra for aplicada, as etapas a seguir são usadas para a criação da primeira  $m$  regra fuzzy e para o cálculo dos valores iniciais de  $P$  e  $b$  da função.

1. Pegar os primeiros  $n_0$  pares de dados de aprendizagem a partir dos dados disponíveis
2. Implementar agrupamento usando ECM com esses dados para obtenção de centros de *cluster*.
3. Para cada centro de *cluster*  $C_i$ , encontrar  $p_i$  pontos de dados cujas posições no espaço de entrada estão mais próximas do centro  $i = 1, 2, \dots, m$ .
4. Para obter uma regra fuzzy correspondente a um centro de *cluster*, crie os antecedentes da regra usando a posição do centro do cluster e (3.12). Usando (3.21) nos pares de dados  $p_i$ , calcule os valores de  $P$  e  $b$  das funções consequentes. As distâncias entre os pontos de dados  $p_i$  e o centro do *cluster* são consideradas como pesos em (3.22).

Onde  $m, n_0$  e  $p$  são parâmetros do modelo de aprendizagem online e o valor de  $p_i$  deve ser maior que o número de entradas  $q$ .

Conforme novos pares de dados são apresentados ao sistema, novas regras fuzzy podem ser criadas e algumas regras existentes são atualizadas. Uma nova regra é criada se um novo centro de *cluster* for encontrado pelo ECM. O antecedente da nova regra fuzzy é formado usando (3.12) com a posição do centro do *cluster*. Para cada par de dados, várias regras fuzzy existentes são atualizadas usando (3.23) se a distância entre o nó da regra para o ponto de dados

no espaço de entrada não são maiores que  $2 \times D_{thr}$ . As distâncias entre esses nós de regras e o ponto de dados no espaço de entrada são tomadas como os pesos em (3.23). Além disso, uma dessas regras também pode ser atualizada alterando seu antecedente de forma que, se sua posição do nó de regra for alterada pelo ECM, a regra fuzzy terá um novo antecedente calculado através de (3.12).

$$\begin{cases} b_{k+1} = b_k + w_{k+1} P_{k+1} a_{k+1} (y_{k+1} - a_{k+1}^T b_k) \\ P_{k+1} = \frac{1}{\lambda} \left( P_k - \frac{w_{k+1} P_k a_{k+1} a_{k+1}^T P_k}{\lambda + a_{k+1}^T P_k a_{k+1}} \right), \end{cases} \quad k = n, n+1, \dots, p-1 \quad (3.23)$$

onde  $w$  é o peso definido em (3.19) e  $\lambda$  é o fator de esquecimento, um parâmetro que tem valor típico entre 0.8-1.

## 4 METODOLOGIA

Aborda-se o problema de classificar emoções a partir de fluxos de dados de EEG. Descreve-se os métodos de extração de características, medidas de avaliação e experimentos baseados em classificações de excitação, valência e dominância ligado as emoções.

### 4.1 Base da Dados

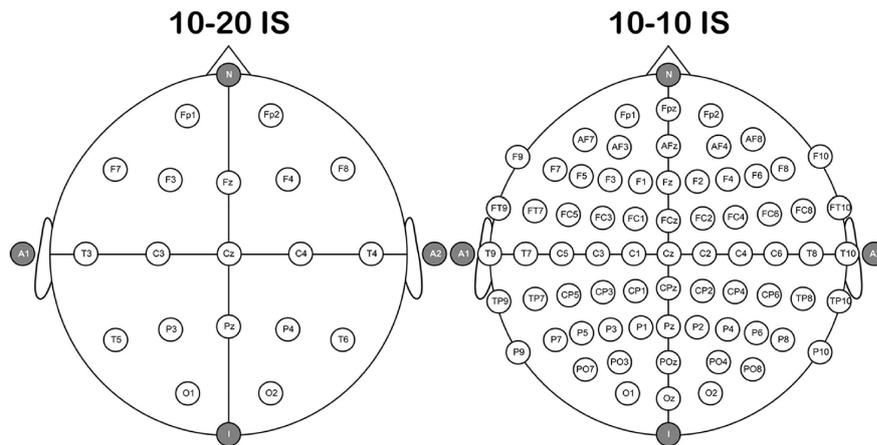
Escolheu-se uma base de dados de sinais fisiológicos para análise de estado afetivo humano a partir de estímulos áudio-visuais de clipes musicais. A *DEAP* é uma base de dados que contém sinais de eletroencefalografia (EEG), eletro-oculografia (EOG) e eletromiografia (EMG), além de sinais auxiliares como temperatura, circulação sanguínea, atividade eletrodérmica e respiração. 32 canais são usados para medições de EEG, 2 para EOG e 2 para EMG, enquanto um canal é usado para cada medição auxiliar, resultando em um total de 40 canais de informação, extraídos a 512Hz. Os dados originais considerados foram aqueles de Koelstra et al. (2011).

A base de dados também é muito usada em estudos e artigos, como pode ser visto na pesquisa de Alarcão e Fonseca (2017), onde cerca de 20% de outros artigos e pesquisas em EEG relacionado a emoções avaliados pelos autores usavam a *DEAP* como base de dados.

### 4.2 Posição dos Eletrodos

Há 3 sistemas mais conhecidos de posicionamento de eletrodos para encefalografia, esses sistemas são chamados de sistemas 10-20, 10-10 e 10-5. Recebem esse nome devido ao afastamento angular do posicionamento dos sensores de eletroencefalografia, sendo os mais usados os sistemas 10-20 e 10-10, representados na Figura 4.1. Segundo Jurcak, Tsuzuki e Dan (2007) o sistema 10-20 tem sido o sistema padrão por meio-século para EEG. Esse tipo de sistema foi planejado para acomodar geralmente 21 eletrodos onde havia pouca necessidade de resolução espacial. Com o desenvolvimento de sistemas mais rebuscados, o sistema 10-10 vinha ganhando força, apresentando uma maior densidade de eletrodos e permitindo acomodar até 81 eletrodos em sua configuração. Pelas próprias palavras do autor "o sistema 10-20 tem ganhado importância como um método de posicionamento baseado na superfície da cabeça relativa padrão para vários métodos de mapeamento cerebral transcraniano".

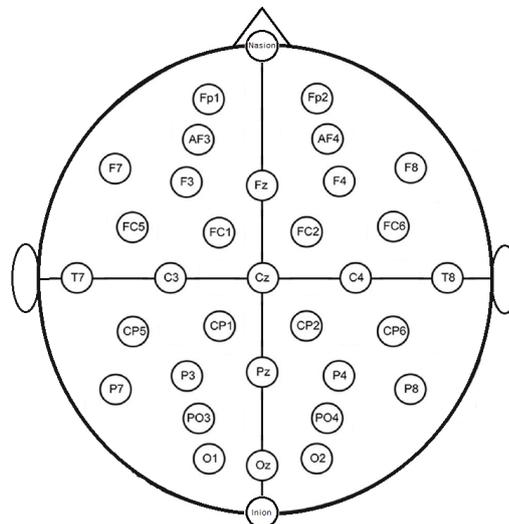
Figura 4.1 – Posição dos Eletrodos no Sistema Internacional 10-20 e 10-10



Fonte: Balconi e Crivelli (2018)

Em sua pesquisa, Alarcão e Fonseca (2017) constatam que cerca de  $\frac{1}{3}$  dos artigos usam o sistema 10-20, enquanto apenas 5% usam o sistema 10-10. Há relatos de diferentes sistemas de posicionamento, todavia esses são minorias nas pesquisas. O *DEAP* usa um sistema intermediário, baseado no 10-20, os eletrodos são posicionados de acordo com a Figura 4.2.

Figura 4.2 – Posição dos Eletrodos da base de dados *DEAP*



Fonte: Do autor

### 4.3 Sistema de Excitação-Valência e Dominância

A representação de emoções humanas, no âmbito da classificação de sinais de eletroencefalografia geralmente é dividida nos quadrantes de excitação e valência. O modelo de excitação-valência é um modelo proposto por Russell (1980) que divide as emoções em quatro

quadrantes como demonstrado na Figura 4.3. Cada quadrante representa um estado, por exemplo, o primeiro quadrante representa o estado de alta excitação e valência positiva que é relativo a emoções de felicidade, satisfação, entre outras. O terceiro quadrante é o oposto, valência negativa e excitação baixa, onde emoções de solidão, tristeza e outras similares se manifestam. Estudos mais novos em eletroencefalografia buscaram também incluir mais variáveis a esse modelo para melhorar o poder de classificação e explorar seus efeitos sobre as emoções, essa variável é a dominância. Uma representação do modelo tridimensional - estendendo de quatro para oito quadrantes - pode ser visto na Figura 4.4.

Figura 4.3 – Sistema de quadrantes de emoções no modelo Excitação-Valência



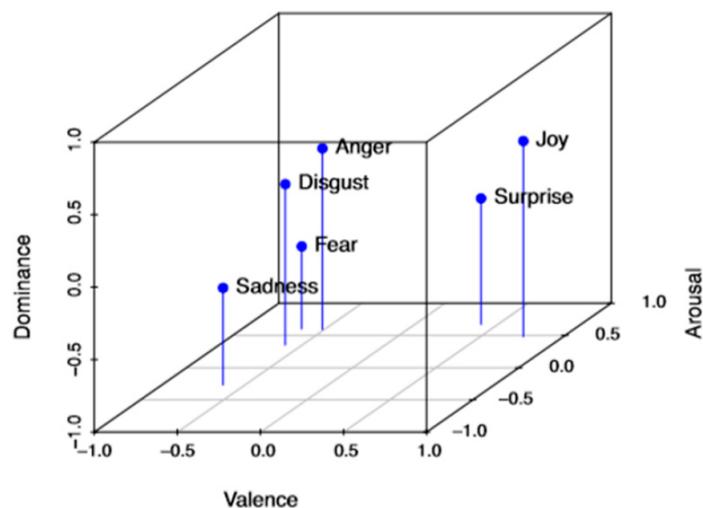
Fonte: Do autor

Pode-se definir as três variáveis desse conjunto segundo Verma e Tiwary (2017) como:

- **Excitação:** Uma escala de emoções mais calmas para mais estimulantes ou excitantes.
- **Valência:** Uma escala de emoções mais tristes e negativas para emoções mais felizes, mais positivas.
- **Dominância:** Uma escala de quão submissivo (ou sem controle) até o quão dominante (ou com controle) a pessoa se sente sobre o estímulo que está recebendo.

A partir do modelo de Excitação-Valência-Dominância, há um conjunto de 3 variáveis para a classificação que foram separados em grupos de excitação baixa e alta, valência negativa e positiva, dominância baixa e alta. A divisão, numeração e quantidade de ocorrência das classes pode ser vista na Tabela 4.1.

Figura 4.4 – Modelo Excitação-Valência-Dominância com as seis emoções básicas representadas



Fonte: Mitruț et al. (2019)

Tabela 4.1 – Classes para classificação no Sistema Excitação-Valência-Dominância

Excitação	Valência	Dominância	Classe (Y)	Ocorrências
Baixa	Negativa	Baixa	1	180
Baixa	Negativa	Alta	2	80
Baixa	Positiva	Baixa	3	75
Baixa	Positiva	Alta	4	191
Alta	Negativa	Baixa	5	172
Alta	Negativa	Alta	6	124
Alta	Positiva	Baixa	7	58
Alta	Positiva	Alta	8	400

Fonte: Do autor

#### 4.4 Extração dos Dados

O método de aprendizado online e classificação dos sistemas estudados é avaliado a partir do fluxo de dados de eletroencefalografia produzido pelo grupo de indivíduos expostos ao estímulos áudio-visuais de clipes musicais. Cada estímulo representa reações fisiológicas diferentes, que são classificadas nos quadrantes do sistema de Excitação-Valência-Dominância. O objetivo se torna atribuir as amostras de EEG coletadas à um rótulo único. Isso é, a partir da análise dos dados obtidos, se faz necessário classificá-los dentro de uma das possíveis classes dos experimentos.

Os dados foram obtidos a partir de 32 indivíduos saudáveis entre 19 e 37 anos de idade, sendo a idade média de 26,9 anos, 16 homens e 16 mulheres. Cada participante foi submetido a 40 testes, cada um com vídeos diferentes, onde foi exibido durante 2 segundos o número do

teste e o progresso, 5 segundos para fixação do indivíduo e 60 segundos do vídeo musical onde haveria destaque do estímulo musical. A posição dos 32 eletrodos de EEG seguiu o padrão internacional 10-20, sendo os eletrodos colocados nas posições: AF3, F3, F7, FC5, FC1, C3, T7, CP5, CP1, P3, P7, PO3, O1, Oz, Pz, Fp2, AF4, Fz, F4, F8, FC6, FC2, Cz, C4, T8, CP6, CP2, P4, P8, PO4, O2, de acordo com a Figura 4.2. A taxa de amostragem foi de 512Hz, durante 67 segundos de gravação, resultando em um total de 34.304 amostras por vídeo por indivíduo, e um total de 43.909.120 amostras de sinais de EEG (KOELSTRA et al., 2011).

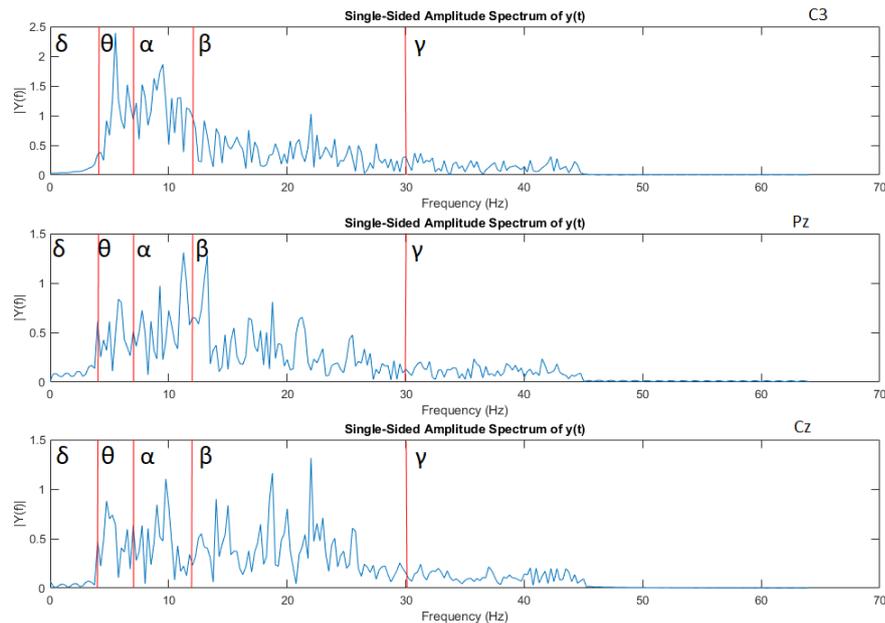
A extração de dados foi feita usando o sistema Biosemi ActiveTwo em um computador dedicado com processamento de 3.2GHz. Os estímulos foram apresentados em outro computador com as mesmas configurações que enviava marcadores de sincronização diretamente para o computador no qual os sinais estavam sendo gravados. Após a exibição do vídeo, um formulário de auto-avaliação era preenchido com os valores de excitação, valência, gosto e dominância. Uma pausa foi realizada com todos participantes após 20 testes para evitar fadiga do uso do equipamento (KOELSTRA et al., 2011).

#### 4.5 Pré-Processamento

As amostras dos participantes foram reduzidas de 512Hz para 128Hz, o que não prejudica as operações já que a frequência máxima das ondas cerebrais analisadas não passaria de 64Hz, um filtro passa banda de 4 à 45Hz foi aplicado pelos próprios autores do banco de dados. A média dos dados foi calculada para a referência comum dos sensores, normalizando as amostras. Dados que não eram dos 60 segundos de exibição de vídeo foram removidos. Canais que não eram de eletroencefalografia também foram descartados. Isso resulta em 32 canais por candidatos e um total de 9.830.400 (128 amostras por segundo, 60 segundos gravação de 32 candidatos em 40 vídeos com 32 eletrodos) amostras, representando uma redução de cerca de 77,6% dos dados.

Os dados de cada vídeo foram reunidos e foram extraídos os valores máximos, médios e de moda de quatro bandas do espectro de Fourier. Depois, as amostras foram separadas em janelas de tempo 1 minuto, 30 segundos, 15 segundos, 10 segundos, 5 segundos e 3 segundos. As amostras foram submetidas aos dois algoritmos na mesma ordem para garantir que o mesmo fluxo de dados seja alimentado aos algoritmos. Um exemplo da extração de Fourier é visto na Figura 4.5, onde é possível observar um maior nível de energia nas bandas  $\theta$ ,  $\alpha$  e  $\beta$  dos exemplos citados.

Figura 4.5 – Exemplo do Espectro de Fourier gerado da Janela de Tempo de 3s



Fonte: Do autor

As classes foram definidas de acordo com as notas dadas pelos participantes nos valores de Excitação, Valência e Dominância. As notas são valores reais entre 1 e 9. Valores maiores e iguais a 5 foram classificados como "Alta" para excitação e dominância e "Positiva" para valência, valores menores que 5 foram classificados como "Baixa" para excitação e dominância e "Negativa" para valência. A partir dos três, determinou-se a classe que o participante classificou o estímulo de acordo com a Tabela 4.1. As classes foram usadas somente como critério de acurácia e não foram usadas no aprendizado direto dos algoritmos, isso é, os algoritmos não sabiam a resposta esperada da classificação em nenhum momento durante o processo de chegada dos dados e não se corrigiam por erros da resposta como é comum em métodos de treinamentos de redes neurais.

## 4.6 Experimentos

Propõe-se analisar a performance temporal e a acurácia dos dois classificadores, eGFC e DENFIS, a partir de dois experimentos. No primeiro, analisa-se os dados processados de cada um dos 32 canais de modo individual, onde são extraídos os valores de máximo, moda e média do espectro de Fourier nas frequências  $\theta$  (4 a 7Hz),  $\alpha$  (8 a 12Hz),  $\beta$  (12 a 30Hz),  $\gamma$  (acima de 30Hz) em seis janelas de tempo: de 60, 30, 15, 10, 5 e 3 segundos. Isso cria um total de 12 atributos para cada janela de tempo, que possuem respectivamente 1, 2, 4, 6, 12 e 20

amostras por canal por vídeo. Como cada canal é analisado individualmente, tem-se um total de 1280 amostras para a janela de tempo de 60 segundos, 2560 amostras para janela de tempo de 30 segundos, 5120 amostras para a janela de tempo de 15 segundos, 7680 amostras para a janela de tempo de 10 segundos, 15360 amostras para a janela de tempo de 5 segundos e 25600 amostras para a janela de tempo de 3 segundos. É importante ressaltar que a cada divisão de janela de tempo, aumentam-se as ocorrências de cada classe, então nas janelas de 30 segundos, há duas vezes mais ocorrências de cada classe do que a apresentada na Tabela ?? e com janelas de 3 segundos, 20 vezes mais.

Para o segundo experimento, analisa-se cada vídeo com um conjunto único de informações fornecidas pelos seus canais para a menor janela de tempo estudada. Cada amostra contém a informação de 32 canais e 12 atributos para cada canal, gerando 384 atributos para cada amostra. Com intuito de diminuir atributos altamente correlacionados dois métodos foram adotados: Os atributos foram comparados com a saída esperada pelo método de Score, definido por Soares et al. (2018), assim, classificaram-se os atributos que teriam mais influência na acurácia do algoritmo. A partir dos melhores atributos, retiraram-se os atributos altamente correlacionados, isso é, atributos com valores absolutos obtidos pela correlação de Pearson, definida pela Equação 4.1, maiores que 0.85. De 384 atributos, restaram 175, mostrados na Tabela 5.6. Analisou-se também o efeito da redução contínua desse atributos na acurácia e tempo de processamento a partir da técnica *Leave-n-Features-Out*, com  $n=20$ . Esse experimento é realizado na janela de tempo de 3 segundos.

$$\rho(a, b) = \frac{\sum_{i=1}^n (X_{a,i} - \bar{X}_a)(Y_{b,i} - \bar{Y}_b)}{\left\{ \sum_{i=1}^n (X_{a,i} - \bar{X}_a)^2 \sum_{j=1}^n (Y_{b,i} - \bar{Y}_b)^2 \right\}^{1/2}}; \quad (4.1)$$

Sendo:

$$\bar{X}_a = \frac{\sum_{i=1}^n X_{a,i}}{n};$$

$$\bar{Y}_a = \frac{\sum_{i=1}^n X_{b,j}}{n}.$$

#### 4.7 Medidas de Desempenho

Três medidas de desempenho foram adotadas para comparar os algoritmos: acurácia, número de regras e tempo de processamento de amostra. A acurácia é definida pela Equação 4.2,

o número de regras é devolvido individualmente por cada algoritmo e o tempo de processamento de amostra é definido pela Equação 4.3. Todos os testes foram aplicados em um computador com as seguintes configurações: Intel i5-7300HQ, 2.5GHz, quadcore, 16GB de memória RAM com uma placa de vídeo NVidia GeForce GTX 1050.

$$Acc_{new} = \frac{h-1}{h} Acc_{old} + \frac{1}{h} \tau. \quad (4.2)$$

Onde  $h$ =amostras, e  $\tau$  é 0 se  $\hat{Y}[h] \neq Y[h]$  e 1 se  $\hat{Y}[h] = Y[h]$ , sendo  $\hat{Y}$  a classe estimada e  $Y$  a classe real. Além disso:

$$t = \frac{t_{total}}{h}. \quad (4.3)$$

Onde  $t$ =tempo e  $h$ =amostras.

## 5 RESULTADOS

### 5.1 Experimento de Canais Individuais

Busca-se analisar a eficiência dos canais separados de EEG, tentando descobrir áreas do cérebro mais promissoras para classificação de emoções de estímulos áudio-visuais, além de analisar o tempo gasto por amostra a fim de observar a capacidade dos algoritmos de aprendizado online e tempo computacional para gerar uma resposta válida. As Tabelas 5.2, 5.3, 5.4 e 5.5 mostram os valores individuais do eGFC e do DENFIS para as janelas de tempo onde cada um dos algoritmos performou melhor, apresentando os resultados de canal, acurácia (Acc) e regras ( $c$ ) para o DENFIS e média de regras ( $c_{avg}$ ) para o eGFC. A Tabela 5.1 mostra o tempo médio de processamento por amostras considerando as amostras de todos os canais na janela de tempo proposta. As tabelas de acurácia das janelas intermediária, de 30, 15, 10 e 5 segundos, foram suprimidas, pois não apresentavam evolução ou informações relevantes a nenhum algoritmo que não pudessem ser feitas pela comparação da janela de 60 e de 3 segundos.

Tabela 5.1 – Tempo de processamento médio por amostra individual em janelas de tempo

Janela (s)	eGFC	DENFIS
	Tempo por amostra (ms)	
60	0,1594	1,7959
30	0,1577	2,0013
15	0,1949	2,0570
10	0,2028	2,4263
5	0,2602	2,4964
3	0,2518	2,8579

Fonte: Do autor

É observável a partir das Tabelas 5.2 e 5.3 que o eGFC possui dificuldade em achar padrões de maneira geral, tendo valores muito próximos ao valor estatístico de classificação aleatória de 12,5% se for levar em consideração um conjunto de dados balanceado. Todavia, como não há balanceamento no conjunto de dados, os valores representam algum aprendizado, mas insuficiente. Há exceção nos baixos valores como o canal Fp2 na janela de 60. Esse comportamento decai, onde o canal Fz passa a ter melhor acurácia na janela de 3 segundos, nessa última vê-se uma melhora no aprendizado do algoritmo, ainda continuando com resultados baixos. É visto também que os grânulos - ou seja, as regras - para a classificação vão diminuindo quanto menor a janela de tempo. Isso ocorre por dois fatores: há mais amostras para que o tempo de inatividade das regras possa ser passado mais vezes e assim excluídas e há

mais regras unindo-se devido a proximidade delas. Isso cria regras mais estáveis. Menos regras mais estáveis são melhores para o algoritmo do que muitas regras não-robustas, já que número menor de regras também significa um tempo computacional menor para obter um resultado de classificação. De maneira geral, não se observa um resultado individual conclusivo pelo eGFC, não possibilitando inferir sobre áreas ou canais mais ou menos promissores para a análise em questão.

Tabela 5.2 – Resultado eGFC por canal individual de EEG para janelas de 60 segundos

Hemisfério esquerdo			Hemisfério direito			Região Central		
Canal	Acc(%)	$c_{avg}$	Canal	Acc(%)	$c_{avg}$	Canal	Acc(%)	$c_{avg}$
Fp1	14,45	20,24	Fp2	18,04	19,94	Fz	13,98	19,12
Af3	14,38	19,11	Af4	14,06	20,16	Cz	13,52	20,23
F3	12,19	19,20	F4	13,05	26,59	Pz	15,70	20,72
F7	14,14	20,17	F8	14,22	21,69	Oz	13,83	20,44
Fc1	13,36	28,02	Fc2	13,44	22,60			
Fc5	15,00	23,16	Fc6	13,52	18,62			
T7	14,53	24,91	T8	14,92	20,57			
C3	14,61	20,45	C4	14,53	16,95			
Cp1	13,20	24,62	Cp2	12,97	19,52			
Cp5	11,72	19,21	Cp6	15,47	17,98			
P7	13,59	29,04	P8	12,89	18,52			
P3	14,45	24,10	P4	15,31	21,06			
Po3	14,84	15,14	Po4	11,88	25,82			
O1	13,44	20,35	O2	11,56	20,44			
<b>Avg.</b>	<b>13,85</b>	<b>21,98</b>	<b>Avg.</b>	<b>13,99</b>	<b>20,75</b>	<b>Avg.</b>	<b>14,26</b>	<b>20,13</b>

Fonte: Do autor

No DENFIS, vê-se um resultado peculiar pelas Tabelas 5.4 e 5.5. Isso se dá por haver uma acurácia maior e uma identificação de padrões em janelas de tempo grandes e acurácias muito baixas em janelas de tempo menores. Esse efeito é contrário ao esperado pois em janelas de tempo maiores, um sinal de maior amplitude ou até mesmo estímulos esporádicos como P300 e outras ondas referentes a potenciais relacionados a eventos tendem a ser perdidos, além de haver menos dados disponível para a detecção desses padrões. Além disso, é possível observar inconsistências nos números de regras criadas pelo DENFIS para avaliar a mesma quantidade de dados entre os canais, não refletindo uma correlação de número de regras com acurácia.

Também é possível observar uma relação do número de regras com o tempo de processamento de cada amostra, como visto na Tabela 5.1 onde vê-se que há um efeito o número

Tabela 5.3 – Resultado eGFC por canal individual de EEG para janelas de 3 segundos

Hemisfério esquerdo			Hemisfério direito			Região Central		
Canal	Acc(%)	$c_{avg}$	Canal	Acc(%)	$c_{avg}$	Canal	Acc(%)	$c_{avg}$
Fp1	13,93	11,95	Fp2	14,98	12,28	Fz	17,72	13,14
Af3	12,95	13,60	Af4	14,93	13,16	Cz	15,81	13,74
F3	16,74	13,53	F4	12,90	14,41	Pz	15,68	13,38
F7	14,00	14,34	F8	14,59	14,59	Oz	14,71	14,02
Fc1	14,04	14,64	Fc2	14,61	13,37			
Fc5	16,99	15,21	Fc6	14,52	13,23			
T7	14,54	11,65	T8	17,89	13,81			
C3	16,09	12,11	C4	16,48	12,42			
Cp1	16,24	12,98	Cp2	17,49	13,12			
Cp5	12,08	13,06	Cp6	15,01	13,24			
P7	17,43	14,69	P8	13,87	11,99			
P3	15,32	14,44	P4	17,59	13,01			
Po3	11,70	12,32	Po4	16,27	15,56			
O1	13,03	12,96	O2	11,86	13,85			
<b>Avg.</b>	<b>14,65</b>	<b>13,39</b>	<b>Avg.</b>	<b>15,21</b>	<b>13,43</b>	<b>Avg.</b>	<b>15,98</b>	<b>13,57</b>

Fonte: Do autor

de amostras e o número de regras geradas. O eGFC gasta quase o dobro do tempo para processar uma quantidade de 20 vezes mais amostras com um pouco mais da metade das regras, o DENFIS gasta também quase o dobro desse tempo. Todavia, como o DENFIS não exclui regras, cada vez vão sendo criadas mais e mais regras, o que é visto quanto mais amostras são colocadas no algoritmo devido a diminuição do tempo da janela, aumentando o esforço computacional do algoritmo. Assim como é visto que o eGFC consegue, por amostra, ser cerca de 10 vezes mais rápido que o DENFIS, sendo mais viável para fluxos de dados muito maiores em janelas de tempo menores. Uma outra vantagem do eGFC sobre o DENFIS é a capacidade de excluir ou combinar regras, criando menores números ao longo do tempo e, com o intuito de um sistema que sempre está recebendo mais informação, a capacidade de aproveitar regras antigas para melhorar a robustez de novas regras e adaptar-se as amostras é preferível.

Nas janelas onde o DENFIS apresentou uma confiabilidade de aprendizado, vê-se pouca diferença entre a acurácia dos eletrodos, sem nenhum se sobressair muito como aconteceu com os eletrodos Fz, P7, Cp2 e P4 no eGFC. Na análise de canais individuais, esperava-se que houvesse uma tendência a resultados melhores no hemisfério direito - conhecido por lidar com interpretação emocional - do que no hemisfério esquerdo- conhecido por lidar com interpreta-

ção lógica das situações. Todavia, a pouca acurácia de classificação dos dois algoritmos torna inconclusiva a análise de emoções ou de regiões cerebrais, sendo possível afirmar somente nas características intrínseca aos algoritmos e compará-las.

Tabela 5.4 – Resultado DENFIS por canal individual de EEG para janelas de 60 segundos

Hemisfério esquerdo			Hemisfério direito			Região Central		
Canal	Acc(%)	<i>c</i>	Canal	Acc(%)	<i>c</i>	Canal	Acc(%)	<i>c</i>
Fp1	16,25	28	Fp2	17,5	30	Fz	16,88	26
Af3	17,00	25	Af4	16,41	29	Cz	17,81	27
F3	17,11	27	F4	16,17	44	Pz	18,12	37
F7	15,31	24	F8	15,58	36	Oz	15,94	26
Fc1	18,44	47	Fc2	15,55	28			
Fc5	16,09	28	Fc6	18,20	26			
T7	18,67	41	T8	18,44	27			
C3	16,25	29	C4	16,33	19			
Cp1	17,19	33	Cp2	18,28	30			
Cp5	16,25	28	Cp6	15,70	22			
P7	18,05	34	P8	17,27	20			
P3	15,78	45	P4	17,66	27			
Po3	15,39	20	Po4	16,56	36			
O1	15,86	25	O2	17,19	27			
<b>Avg.</b>	16,69	31	<b>Avg.</b>	16,92	28,64	<b>Avg.</b>	17,19	29

Fonte: Do autor

## 5.2 Experimento Multicanal

O experimento multicanal consiste em analisar, em uma janela de tempo baixa, o resultado dos algoritmos para o conjunto de todos os canais. Como descrito na metodologia, dos 384 atributos, 175 foram selecionados. Sua ordem é mostrada na Tabela 5.6, usando a notação {Canal, Banda, Atributo} para definir o atributo mais importante até o menos importante. A Tabela mostra informações relevantes quanto a análise de eletroencefalografia. É visto nela que todas as quatro bandas analisadas,  $\alpha$ ,  $\beta$ ,  $\gamma$  e  $\theta$  são importantes para a classificação e aparecem uma quantidade de 46, 45, 43 e 41 vezes respectivamente. Assim, não há uma real prevalência das bandas a não ser quando visto em regiões isoladas, como olhar os 10 primeiros e ver uma incidência de 50% do canal  $\beta$ . Também é visto uma dominância do atributo de moda sobre média e máximo, sendo 116 incidências para moda, 19 para média e 40 para máximo. Como a correlação entre atributos foi considerada, era esperado que ou moda ou média se sobressaíssem uma sobre a outra devido a terem resultados próximos se não houver picos de amplitude posi-

Tabela 5.5 – Resultado DENFIS por canal individual de EEG para janelas de 3 segundos

Hemisfério esquerdo			Hemisfério direito			Região Central		
Canal	Acc(%)	<i>c</i>	Canal	Acc(%)	<i>c</i>	Canal	Acc(%)	<i>c</i>
Fp1	12,33	31	Fp2	12,13	47	Fz	11,64	63
Af3	12,00	55	Af4	12,38	39	Cz	12,52	69
F3	12,19	61	F4	12,44	33	Pz	12,34	43
F7	12,13	68	F8	12,27	68	Oz	12,07	52
Fc1	12,07	58	Fc2	11,72	46			
Fc5	12,21	62	Fc6	12,26	39			
T7	12,24	49	T8	12,12	63			
C3	12,28	29	C4	11,97	67			
Cp1	12,72	49	Cp2	12,14	56			
Cp5	12,30	58	Cp6	11,98	67			
P7	12,49	69	P8	12,30	62			
P3	12,36	59	P4	12,10	57			
Po3	11,98	56	Po4	12,41	72			
O1	12,04	43	O2	12,38	77			
<b>Avg.</b>	12,24	53,36	<b>Avg.</b>	11,32	56,64	<b>Avg.</b>	12,14	56,75

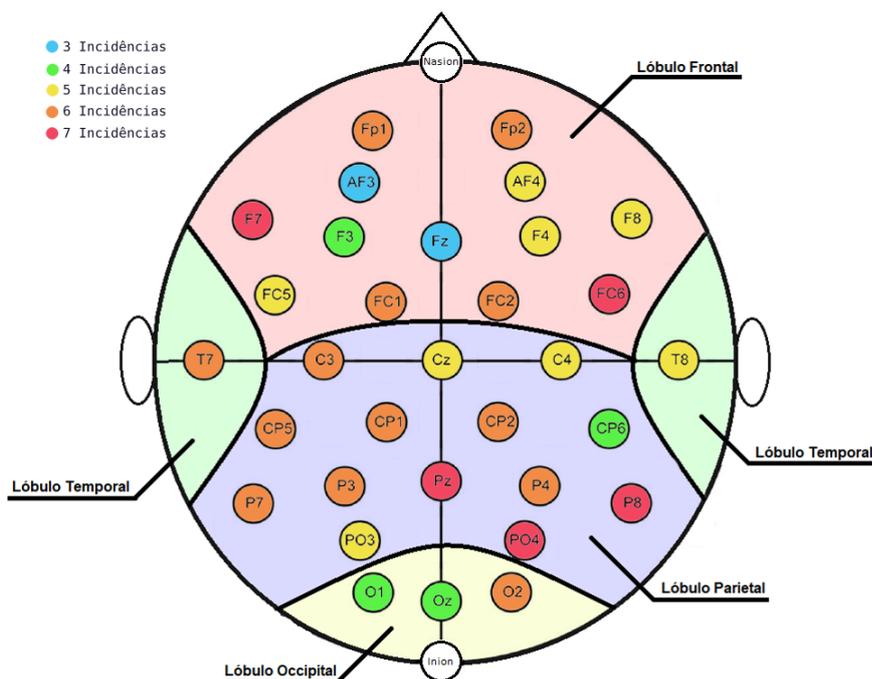
Fonte: Do autor

tiva ou negativa. Isso não tira a importância da média como um atributo a ser considerado, até porque entre os 10 melhores ranqueados, 5 deles são de média e os dois melhores ranqueados são medidas de média. Outro aspecto importante visto é a quantidade de incidência de cada canal, demonstrado na Figura 5.1. É importante notar que T7, Pz e C3 praticamente dominam como os canais mais importantes, além de que todas incidências de Pz como de C3 estão entre os 20 canais melhores ranqueados e as de T7 estão nos 50 melhores.

É visto na Figura 5.1 uma grande incidência de canais no lobo parietal. O lobo parietal é responsável pelo sistema somatossensorial, que é um conjunto de neurônios que responde a mudanças na superfície ou dentro do corpo. É a área que processa reações de toque, calor, dentre outros. Algumas dessas reações, como reação a estímulos aversivos está intimamente ligada ao sistema límbico, responsável por respostas emocionais. Além disso, o lobo parietal está ligado a algumas funções sensoriais como reconhecimento de estímulos - importante para a classificação de emoções advindas de estímulos áudio-visuais - processos motores finos, relacionamento de expressões faciais com emoções e também execução de linguagem e expressão corporal. Essas funções explicam a grande incidência dos canais dessa área, mostrando que ela é uma área cerebral relevante quando como um conjunto.

Com o ranking dos melhores atributos, o fluxo dos sinais foi rodado nos classificadores usando o método *leave-n-out* com  $n=20$ . Assim, nove execuções separadas foram feitas para

Figura 5.1 – Incidência dos canais no rank de 175 melhores atributos e suas posições no couro cabeludo



Fonte: Do autor

cada algoritmo, isso é, todo aprendizado feito de um ciclo foi descartado para que pudesse analisar a correlação da diminuição de atributos com a acurácia, o número de regras e o tempo de processamento de cada amostra. Esses valores podem ser vistos na Tabela 5.7. É possível ver um claro aprendizado dos dois algoritmos quando submetidos aos atributos dos canais combinados. Nesse caso, o eGFC chegou a 32,68% de acurácia no melhor caso e o DENFIS a 19,02% de acurácia. O eGFC retornou melhor desempenho com 95 atributos, quando começou a cair e teve uma queda drástica de acurácia de 35 para 15 atributos. O DENFIS abaixa gradativamente, tem um ponto fora do padrão de acurácia com 115 atributos e retorna uma melhor acurácia que as duas anteriores ao chegar em 15 atributos. O tempo por amostra também é similar nos dois algoritmos, com exceção de quando há 175 e 155 atributos, onde uma diferença mais significativa é vista.

Durante o processo de experimentação com multicanais, alguns outros testes foram aplicados para ver a diferenciação do acerto dos algoritmos. Um deles é descrito pois indica características importantes do sistema. Antes dos dados serem injetados nos algoritmos, eles foram aleatoriamente embaralhados. Isso causou o algoritmo a começar a errar muito e não conseguir generalizar. Analisando os parâmetros, a conclusão obtida é que mesmo que Fourier remova a dependência do tempo, ainda há uma dependência restante entre as janelas de tempo. Isso quer dizer que, na janela de tempo de 3s, há ainda uma correlação temporal entre a primeira janela

Tabela 5.6 – Ranking dos 175 melhores atributos

Número do Rank {Canal, Banda, Atributo}							
1	{T7, $\beta$ ,média}	36	{FC2, $\beta$ ,média}	71	{F3, $\theta$ ,max}	106	{F7, $\alpha$ ,moda}
2	{Pz, $\gamma$ ,média}	37	{F7, $\theta$ ,max}	72	{AF4, $\gamma$ ,moda}	107	{Cz, $\beta$ ,média}
3	{Pz, $\beta$ ,moda}	38	{T7, $\theta$ ,moda}	73	{FC5, $\gamma$ ,max}	108	{P7, $\gamma$ ,média}
4	{T7, $\beta$ ,moda}	39	{F3, $\alpha$ ,max}	74	{P7, $\theta$ ,max}	109	{FC1, $\gamma$ ,moda}
5	{C3, $\alpha$ ,max}	40	{P3, $\gamma$ ,média}	75	{P4, $\theta$ ,moda}	110	{Fp1, $\theta$ ,moda}
6	{Fp1, $\gamma$ ,max}	41	{Fp2, $\theta$ ,moda}	76	{F3, $\beta$ ,moda}	111	{T8, $\alpha$ ,moda}
7	{C3, $\beta$ ,média}	42	{P4, $\gamma$ ,moda}	77	{C4, $\alpha$ ,max}	112	{PO3, $\gamma$ ,moda}
8	{Pz, $\alpha$ ,média}	43	{Oz, $\theta$ ,max}	78	{Oz, $\alpha$ ,moda}	113	{PO3, $\beta$ ,moda}
9	{F7, $\alpha$ ,média}	44	{T7, $\theta$ ,max}	79	{CP1, $\beta$ ,max}	114	{CP5, $\alpha$ ,moda}
10	{C3, $\beta$ ,moda}	45	{F7, $\gamma$ ,moda}	80	{FC6, $\theta$ ,moda}	115	{PO4, $\alpha$ ,moda}
11	{Pz, $\theta$ ,max}	46	{FC1, $\alpha$ ,moda}	81	{CP2, $\alpha$ ,moda}	116	{P8, $\theta$ ,moda}
12	{F7, $\gamma$ ,max}	47	{Fp1, $\gamma$ ,moda}	82	{F7, $\theta$ ,moda}	117	{Cz, $\theta$ ,max}
13	{C3, $\theta$ ,moda}	48	{P4, $\beta$ ,moda}	83	{AF4, $\beta$ ,moda}	118	{PO4, $\gamma$ ,moda}
14	{T7, $\alpha$ ,moda}	49	{FC2, $\gamma$ ,moda}	84	{CP1, $\beta$ ,moda}	119	{P3, $\alpha$ ,média}
15	{C3, $\gamma$ ,moda}	50	{FC2, $\theta$ ,moda}	85	{CP5, $\beta$ ,max}	120	{F8, $\alpha$ ,média}
16	{Pz, $\alpha$ ,moda}	51	{FC6, $\gamma$ ,max}	86	{T8, $\beta$ ,moda}	121	{CP5, $\theta$ ,max}
17	{C3, $\alpha$ ,moda}	52	{Fp2, $\alpha$ ,moda}	87	{PO4, $\alpha$ ,max}	122	{Fp1, $\alpha$ ,moda}
18	{Pz, $\theta$ ,moda}	53	{Fp1, $\alpha$ ,max}	88	{FC6, $\alpha$ ,média}	123	{PO4, $\alpha$ ,max}
19	{Fp2, $\gamma$ ,max}	54	{Fp2, $\gamma$ ,moda}	89	{FC5, $\alpha$ ,moda}	124	{Oz, $\gamma$ ,moda}
20	{Pz, $\gamma$ ,moda}	55	{P4, $\alpha$ ,moda}	90	{CP1, $\theta$ ,max}	125	{P8, $\alpha$ ,max}
21	{Fp2, $\theta$ ,max}	56	{F3, $\gamma$ ,moda}	91	{P8, $\beta$ ,moda}	126	{AF3, $\beta$ ,moda}
22	{FC1, $\theta$ ,média}	57	{O1, $\alpha$ ,moda}	92	{FC1, $\beta$ ,max}	127	{F4, $\theta$ ,max}
23	{F7, $\beta$ ,moda}	58	{C4, $\gamma$ ,max}	93	{O2, $\beta$ ,max}	128	{FC5, $\gamma$ ,moda}
24	{FC1, $\theta$ ,moda}	59	{O1, $\theta$ ,média}	94	{AF4, $\theta$ ,max}	129	{F4, $\gamma$ ,moda}
25	{F4, $\gamma$ ,max}	60	{F4, $\beta$ ,moda}	95	{T8, $\alpha$ ,max}	130	{Cz, $\theta$ ,moda}
26	{Fp1, $\beta$ ,moda}	61	{CP2, $\alpha$ ,max}	96	{T8, $\theta$ ,moda}	131	{T8, $\gamma$ ,moda}
27	{P4, $\beta$ ,max}	62	{P3, $\beta$ ,moda}	97	{PO4, $\theta$ ,moda}	132	{Cz, $\beta$ ,moda}
28	{T7, $\gamma$ ,moda}	63	{FC6, $\alpha$ ,moda}	98	{CP6, $\alpha$ ,moda}	133	{C4, $\theta$ ,moda}
29	{P8, $\gamma$ ,max}	64	{Oz, $\beta$ ,moda}	99	{FC5, $\theta$ ,max}	134	{F8, $\gamma$ ,moda}
30	{P4, $\alpha$ ,média}	65	{FC2, $\alpha$ ,moda}	100	{CP2, $\theta$ ,moda}	135	{C4, $\gamma$ ,moda}
31	{Fp2, $\beta$ ,moda}	66	{AF4, $\beta$ ,média}	101	{P3, $\gamma$ ,moda}	136	{O1, $\gamma$ ,moda}
32	{FC2, $\alpha$ ,média}	67	{P8, $\beta$ ,max}	102	{P8, $\gamma$ ,moda}	137	{P8, $\alpha$ ,moda}
33	{CP2, $\theta$ ,max}	68	{C4, $\beta$ ,moda}	103	{PO4, $\beta$ ,max}	138	{O1, $\beta$ ,moda}
34	{FC2, $\beta$ ,moda}	69	{O2, $\alpha$ ,moda}	104	{FC5, $\beta$ ,moda}	139	{F4, $\alpha$ ,moda}
35	{O2, $\theta$ ,max}	70	{O2, $\theta$ ,moda}	105	{O2, $\beta$ ,moda}	140	{CP6, $\gamma$ ,moda}
						141	{AF3, $\alpha$ ,moda}
						142	{FC6, $\gamma$ ,moda}
						143	{FC1, $\beta$ ,moda}
						144	{CP5, $\theta$ ,moda}
						145	{Cz, $\gamma$ ,moda}
						146	{F8, $\alpha$ ,moda}
						147	{CP5, $\gamma$ ,moda}
						148	{FZ, $\gamma$ ,moda}
						149	{FC6, $\beta$ ,max}
						150	{CP6, $\theta$ ,média}
						151	{PO4, $\beta$ ,moda}
						152	{F8, $\beta$ ,moda}
						153	{P3, $\alpha$ ,moda}
						154	{CP1, $\alpha$ ,moda}
						155	{CP6, $\beta$ ,moda}
						156	{AF4, $\alpha$ ,moda}
						157	{P7, $\alpha$ ,moda}
						158	{CP5, $\beta$ ,moda}
						159	{FC6, $\beta$ ,moda}
						160	{F8, $\theta$ ,moda}
						161	{O2, $\gamma$ ,moda}
						162	{PO3, $\alpha$ ,média}
						163	{P3, $\theta$ ,moda}
						164	{P7, $\theta$ ,moda}
						165	{PO3, $\alpha$ ,moda}
						166	{FZ, $\alpha$ ,moda}
						167	{AF3, $\gamma$ ,moda}
						168	{PO3, $\theta$ ,moda}
						169	{P7, $\gamma$ ,moda}
						170	{CP1, $\gamma$ ,moda}
						171	{CP1, $\theta$ ,moda}
						172	{FZ, $\beta$ ,moda}
						173	{CP2, $\gamma$ ,moda}
						174	{CP2, $\beta$ ,moda}
						175	{P7, $\beta$ ,moda}

Fonte: Do autor

de tempo com a segunda, da segunda com a terceira e assim por diante. Isso indica que Fourier, para esse conjunto de dados, não é a operação de pré-processamento ideal. Idealmente quando há alta relação temporal, se faz necessário a obtenção de parâmetros pela transformada Wavelet em vez da transformada de Fourier. Devido a essa conclusão, um outro estudo, com a janela de 60 segundos, não embaralhada já que não faria diferença pois há somente uma amostra por vídeo, foi realizado, assim, todo efeito de correlação temporal que a transformada de Fourier pudesse suprimir seria isolado. Os resultados podem ser vistos na Tabela 5.8.

Na Tabela 5.8 é visto que o DENFIS ganha uma melhora de aprendizado, enquanto o eGFC já tem mais dificuldade para reconhecer padrões e classificar corretamente, diminuindo em mais de 10% sua acurácia. O pior resultado anterior do DENFIS, com 115, agora se torna

Tabela 5.7 – Comparação de Acurácia, grânulos e tempo por amostra com o método *Leave-n-Out* para janela de tempo de 3 segundos

# Atributos	eGFC			DENFIS		
	Acc (%)	$c_{avg}$	$t_h$ (ms)	Acc (%)	c	$t_h$ (ms)
175	32,16	16,42	19,73	19,02	97	26,63
155	32,28	15,58	16,76	17,68	95	22,88
135	32,55	15,09	19,46	14,57	88	19,09
115	32,50	14,48	15,93	9,61	89	14,22
95	32,68	14,13	12,99	14,69	80	11,12
75	31,63	13,57	9,92	13,93	73	8,94
55	31,30	13,53	7,38	11,35	73	7,01
35	30,36	11,97	4,30	10,83	60	5,78
15	26,73	10,85	1,89	12,38	36	2,78

Fonte: Do autor

Tabela 5.8 – Comparação de Acurácia, grânulos e tempo por amostra com o método *Leave-n-Out* para janela de tempo de 60 segundos

# Atributos	eGFC			DENFIS		
	Acc (%)	$c_{avg}$	$t_h$ (ms)	Acc (%)	c	$t_h$ (ms)
175	20,70	18,97	31,40	20,47	55	29,86
155	20,23	18,93	27,89	18,52	54	23,04
135	20,70	17,81	32,38	17,11	52	17,97
115	21,41	17,62	28,21	25,08	53	15,47
95	21,48	17,62	25,33	18,44	51	10,53
75	20,86	16,94	19,62	21,64	53	8,95
55	19,53	15,97	12,22	24,92	52	6,19
35	20,23	15,50	8,28	19,22	54	5,17
15	17,19	16,68	3,51	18,36	41	2,29

Fonte: Do autor

o melhor resultado e possui a maior acurácia entre os dois classificadores. O número de regras também é mais constante no DENFIS, enquanto o eGFC não manteve-se em média de 17 regras. O tempo foi similar para os dois algoritmos, como na Tabela 5.7, com a diferença que o DENFIS conseguiu melhor tempo de modo geral, principalmente com o conjunto de 135 até 55 atributos. Mesmo sem a correlação temporal, há um problema com a janela de tempo de 60 segundos, que é suprimir possíveis potenciais evocados, como explicado na discussão do experimento 1. Essa supressão é a provável causa da diminuição de acurácia do eGFC, enquanto vê-se que o DENFIS possui facilidade de lidar com uma quantidade menor de informação e de dados do que o eGFC.

## 6 CONCLUSÃO

Foram avaliados e comparados dois classificadores inteligentes - fuzzy e neuro-fuzzy - evolutivos, eGFC e DENFIS, a partir dos dados da base de emoções por estímulos áudio-visuais, conhecida como DEAP. Foram avaliados seus desempenhos em tempo de processamento, e acurácia quando da implementação de diferentes comprimentos de janela de tempo, e em experimentos de canais individuais e multi-canal.

Um grupo de 32 sujeitos foi apresentado a 40 vídeo-clipes musicais de 1 minuto cada, usando dispositivo EEG. Após verem e ouvirem cada vídeo-clipe, classificaram através de questionários como se sentiram durante o estímulo áudio-visual. Essa classificação foi usada para definir oito classes, relativas aos quadrantes da esfera do sistema de Excitação-Valência-Dominância. Os sinais EEG foram submetidos a pré-processamento. A partir da transformada de Fourier foram extraídos três atributos de cada banda de frequência, e para cada eletrodo.

Examinou-se a contribuição individual de cada eletrodo para a acurácia global, e o efeito de janelas de tempo sobre os dois algoritmos evolutivos estudados. Examinou-se a contribuição dos melhores atributos de todos os canais para um mesmo vídeo. Por fim, conclui-se:

i) Não é possível afirmar que existe diferença entre o desempenho dos algoritmos por região cerebral quando analisado canais individualmente. ii) O DENFIS possui comportamento oposto ao eGFC para acurácia dependendo da dimensionalidade dos dados. DENFIS tem melhor resultado para conjuntos menores de atributos. eGFC tem melhor resultado para um número maior de atributos. iii) eGFC, quando construído baseado em janelas de tempos menores e em conjuntos de dados com menos atributos é muito mais rápido do que DENFIS em velocidade de processamento. iv) O lobo parietal é a região do cérebro com maior correlação com as classes, visto os dados áudio-visuais em questão. Isso se enfatiza especialmente nos canais Pz e C3. v) Todas as bandas apresentaram relevância e contribuem na acurácia de classificação dos algoritmos, não havendo prevalência. vi) Dos três atributos analisados por banda, aquele mais discriminante é a moda. A moda aparece em cerca de  $\frac{2}{3}$  dos atributos melhores ranqueados. vii) No presente conjunto de dados EEG, a transformada de Fourier não é a melhor escolha devido a supressão da correlação temporal entre amostras. Nesse sentido, a transformada Wavelet é uma escolha interessante.

## REFERÊNCIAS

- ALARCÃO, S. M.; FONSECA, M. J. Emotions recognition using EEG signals: A survey. **IEEE Transactions on Affective Computing**, PP, 06 2017. Disponível em: <[https://www.researchgate.net/publication/316926791\\_Emotions\\_Recognition\\_Using\\_EEG\\_Signals\\_A\\_Survey](https://www.researchgate.net/publication/316926791_Emotions_Recognition_Using_EEG_Signals_A_Survey)>. Acesso em: 24 ago. 2021.
- ALICKOVIC, E.; KEVRIC, J.; SUBASI, A. Performance evaluation of empirical mode decomposition, discrete wavelet transform, and wavelet packed decomposition for automated epileptic seizure detection and prediction. **Biomedical Signal Processing and Control**, v. 39, p. 94 – 102, 2018. ISSN 1746-8094. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1746809417301544>>. Acesso em: 03 dez. 2020.
- AN, H.; KIM, J.; LEE, S. Design of an asynchronous brain-computer interface for control of a virtual avatar. In: **2016 4th International Winter Conference on Brain-Computer Interface (BCI)**. [s.n.], 2016. p. 1–2. Disponível em: <[https://www.researchgate.net/publication/301642207\\_Design\\_of\\_an\\_asynchronous\\_brain-computer\\_interface\\_for\\_control\\_of\\_a\\_virtual\\_Avatar](https://www.researchgate.net/publication/301642207_Design_of_an_asynchronous_brain-computer_interface_for_control_of_a_virtual_Avatar)>. Acesso em: 08 dez. 2020.
- ANGELOV, P.; FILEV, D. P.; KASABOV, N. Frontmatter. In: \_\_\_\_\_. **Evolving Intelligent Systems: Methodology and Applications**. [s.n.], 2010. p. i–xv. Disponível em: <[https://www.researchgate.net/publication/224672689\\_Evolving\\_Intelligent\\_Systems\\_Methods\\_Learning\\_Applications](https://www.researchgate.net/publication/224672689_Evolving_Intelligent_Systems_Methods_Learning_Applications)>. Acesso em: 05 dez. 2020.
- ANGELOV, P. P.; FILEV, D. P. An approach to online identification of takagi-sugeno fuzzy models. **IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)**, v. 34, n. 1, p. 484–498, 2004. Disponível em: <[https://www.researchgate.net/publication/8345809\\_An\\_Approach\\_to\\_Online\\_Identification\\_of\\_Takagi-Sugeno\\_Fuzzy\\_Models](https://www.researchgate.net/publication/8345809_An_Approach_to_Online_Identification_of_Takagi-Sugeno_Fuzzy_Models)>. Acesso em: 05 dez. 2020.
- ANGHINAH, R. et al. Artefatos biológicos no EEG quantitativo. **Arquivos De Neuropsiquiatria - ARQ NEURO-PSIQUIAT**, v. 64, 06 2006. Disponível em: <[https://www.researchgate.net/publication/247850743\\_Artefatos\\_biologicos\\_no\\_EEG\\_quantitativo](https://www.researchgate.net/publication/247850743_Artefatos_biologicos_no_EEG_quantitativo)>. Acesso em: 21 nov. 2020.
- BALCONI, M.; CRIVELLI, D. Fundamentals of electroencephalography and optical imaging for sport and exercise science from: Handbook of sport neuroscience and psychophysiology routledge. In: \_\_\_\_\_. **Handbook of Sport Neuroscience and Psychophysiology**. [s.n.], 2018. p. 40–69. Disponível em: <<https://www.routledgehandbooks.com/doi/10.4324/9781315723693-3>>. Acesso em: 19 set. 2021.
- BHATTACHARYYA, S. et al. An interval type-2 fuzzy approach for real-time EEG-based control of wrist and finger movement. **Biomedical Signal Processing and Control**, v. 21, p. 90 – 98, 2015. ISSN 1746-8094. Disponível em: <[https://www.researchgate.net/publication/278744544\\_An\\_interval\\_type-2\\_fuzzy\\_approach\\_for\\_real-time\\_EEG-based\\_control\\_of\\_wrist\\_and\\_finger\\_movement](https://www.researchgate.net/publication/278744544_An_interval_type-2_fuzzy_approach_for_real-time_EEG-based_control_of_wrist_and_finger_movement)>. Acesso em: 01 dez. 2020.
- CANO-IZQUIERDO, J.-M.; IBARROLA, J.; ALMONACID, M. Improving motor imagery classification with a new BCI design using neuro-fuzzy S-dFasArt. **IEEE transactions on neural systems and rehabilitation engineering : a publication of the IEEE Engineering in Medicine and Biology Society**, v. 20, p. 2–7, 01 2012. Disponível em: <[https://www.researchgate.net/publication/51715305\\_Improving\\_Motor\\_Imagery](https://www.researchgate.net/publication/51715305_Improving_Motor_Imagery)>

Classification\_With\_a\_New\_BCI\_Design\_Using\_Neuro-Fuzzy\_S-dFasArt>. Acesso em: 01 dez. 2020.

CANTARELLI, T.; MENDES JÚNIOR, J.; STEVAN JUNIOR, S. Fundamentos da medição do EEG: Uma introdução. In: . [s.n.], 2016. Disponível em: <[https://www.researchgate.net/publication/308400572\\_FUNDAMENTOS\\_DA\\_MEDICAO\\_DO\\_EEG\\_UMA\\_INTRODUCAO](https://www.researchgate.net/publication/308400572_FUNDAMENTOS_DA_MEDICAO_DO_EEG_UMA_INTRODUCAO)>. Acesso em: 10 nov. 2020.

CAO, Z.; LIN, C. Inherent fuzzy entropy for the improvement of eeg complexity evaluation. **IEEE Transactions on Fuzzy Systems**, v. 26, n. 2, p. 1032–1035, 2018. Disponível em: <[https://www.researchgate.net/publication/313692216\\_Inherent\\_Fuzzy\\_Entropy\\_for\\_the\\_Improvement\\_of\\_EEG\\_Complexity\\_Evaluation](https://www.researchgate.net/publication/313692216_Inherent_Fuzzy_Entropy_for_the_Improvement_of_EEG_Complexity_Evaluation)>. Acesso em: 01 dez. 2020.

CHAI, R. et al. Brain–computer interface classifier for wheelchair commands using neural network with fuzzy particle swarm optimization. **IEEE Journal of Biomedical and Health Informatics**, v. 18, n. 5, p. 1614–1624, 2014. Disponível em: <[https://www.researchgate.net/publication/265210931\\_Brain-Computer\\_Interface\\_Classifier\\_for\\_Wheelchair\\_Commands\\_Using\\_Neural\\_Network\\_With\\_Fuzzy\\_Particle\\_Swarm\\_Optimization](https://www.researchgate.net/publication/265210931_Brain-Computer_Interface_Classifier_for_Wheelchair_Commands_Using_Neural_Network_With_Fuzzy_Particle_Swarm_Optimization)>. Acesso em: 12 nov. 2020.

CHIEN, Y.-L.; HSIEH, M. H.; GAU, S. S.-F. P50-n100-p200 sensory gating deficits in adolescents and young adults with autism spectrum disorders. **Progress in Neuro-Psychopharmacology and Biological Psychiatry**, v. 95, p. 109683, 2019. ISSN 0278-5846. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0278584619303847>>. Acesso em: 21 nov. 2020.

COYLE, D.; PRASAD, G.; MCGINNITY, T. M. Faster self-organizing fuzzy neural network training and a hyperparameter analysis for a brain–computer interface. **IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)**, v. 39, n. 6, p. 1458–1471, 2009. Acesso em: 01 dez. 2020.

DECKER, L. et al. Real-time anomaly detection in data centers for log-based predictive maintenance using an evolving fuzzy-rule-based approach. In: **IEEE World Congress on Comput. Intell. (WCCI, FUZZ-IEEE), Glasgow**. [s.n.], 2020. p. 8p. Disponível em: <[https://www.researchgate.net/publication/340997268\\_Real-Time\\_Anomaly\\_Detection\\_in\\_Data\\_Centers\\_for\\_Log-based\\_Predictive\\_Maintenance\\_using\\_an\\_Evolving\\_Fuzzy-Rule-Based\\_Approach](https://www.researchgate.net/publication/340997268_Real-Time_Anomaly_Detection_in_Data_Centers_for_Log-based_Predictive_Maintenance_using_an_Evolving_Fuzzy-Rule-Based_Approach)>. Acesso em: 06 nov. 2020.

DOSE, H. et al. An end-to-end deep learning approach to MI-EEG signal classification for BCIs. **Expert Systems with Applications**, v. 114, p. 532 – 542, 2018. ISSN 0957-4174. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0957417418305359>>. Acesso em: 02 dez. 2020.

FERREIRA, A. L. S. et al. A survey of interactive systems based on brain- computer interfaces. **SBC Journal on Interactive Systems**, v. 4, p. 3–13, 2013. Disponível em: <[https://www.researchgate.net/publication/346817724\\_A\\_Survey\\_of\\_Interactive\\_Systems\\_based\\_on\\_Brain-Computer\\_Interfaces](https://www.researchgate.net/publication/346817724_A_Survey_of_Interactive_Systems_based_on_Brain-Computer_Interfaces)>. Acesso em: 11 nov. 2020.

GOODWIN, G. C.; SIN, K. S. **Fuzzy Systems Engineering: Toward Human-Centric Computing**. 1. ed. New Jersey: Englewood Cliffs: Prentice-Hall, 1984. Disponível em: <[https://www.researchgate.net/publication/220692625\\_Fuzzy\\_Systems\\_Engineering\\_Toward\\_Human-Centric\\_Computing](https://www.researchgate.net/publication/220692625_Fuzzy_Systems_Engineering_Toward_Human-Centric_Computing)>. Acesso em: 05 dez. 2020.

GÜLER, N. F.; ÜBEYLI, E. D.; GÜLER İnan. Recurrent neural networks employing lyapunov exponents for EEG signals classification. **Expert Systems with Applications**, v. 29, n. 3, p. 506 – 514, 2005. ISSN 0957-4174. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0957417405000679>>. Acesso em: 03 dez. 2020.

GÜLER İnan; ÜBEYLI, E. D. Adaptive neuro-fuzzy inference system for classification of EEG signals using wavelet coefficients. **Journal of Neuroscience Methods**, v. 148, n. 2, p. 113 – 121, 2005. ISSN 0165-0270. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0165027005001172>>. Acesso em: 01 dez. 2020.

HERMAN, P. A.; PRASAD, G.; MCGINNITY, T. M. Designing an interval type-2 fuzzy logic system for handling uncertainty effects in brain-computer interface classification of motor imagery induced EEG patterns. **IEEE Transactions on Fuzzy Systems**, v. 25, n. 1, p. 29–42, 2017. Disponível em: <<https://ieeexplore.ieee.org/document/7779090>>. Acesso em: 06 nov. 2020.

HOCHBERG, L. et al. Neuronal ensemble control of prosthetic devices by a human with tetraplegia. **Nature**, v. 442, p. 164–71, 08 2006. Disponível em: <<https://www.nature.com/articles/nature04970>>. Acesso em: 08 dez. 2020.

JURCAK, V.; TSUZUKI, D.; DAN, I. 10/20, 10/10, and 10/5 systems revisited: Their validity as relative head-surface-based positioning systems. **NeuroImage**, v. 34, p. 1600–11, 03 2007. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S1053811906009724>>. Acesso em: 19 set. 2021.

KASABOV, N. Evolving connectionist and fuzzy connectionist systems - theory and applications for adaptive, on-line intelligent systems. In: \_\_\_\_\_. [s.n.], 1999. p. 111–146. Disponível em: <[https://www.researchgate.net/publication/200734644\\_Evolving\\_connectionist\\_and\\_fuzzy\\_connectionist\\_systems\\_-\\_theory\\_and\\_applications\\_for\\_adaptive\\_on-line\\_intelligent\\_systems](https://www.researchgate.net/publication/200734644_Evolving_connectionist_and_fuzzy_connectionist_systems_-_theory_and_applications_for_adaptive_on-line_intelligent_systems)>. Acesso em: 22 nov. 2020.

KASABOV, N.; FILEV, D. Evolving intelligent systems: Methods, learning, & applications. **2006 International Symposium on Evolving Fuzzy Systems, United Kingdom, 8-18**, p. 8 – 18, 10 2006. Disponível em: <[https://www.researchgate.net/publication/224672689\\_Evolving\\_Intelligent\\_Systems\\_Methods\\_Learning\\_Applications](https://www.researchgate.net/publication/224672689_Evolving_Intelligent_Systems_Methods_Learning_Applications)>. Acesso em: 22 nov. 2020.

KASABOV, N. K.; SONG, Q. DENFIS: dynamic evolving neural-fuzzy inference system and its application for time-series prediction. **IEEE Transactions on Fuzzy Systems**, v. 10, n. 2, p. 144–154, 2002. Disponível em: <[https://www.researchgate.net/publication/3336037\\_DENFIS\\_Dynamic\\_Evolving\\_Neural-Fuzzy\\_Inference\\_System\\_and\\_Its\\_Application\\_for\\_Time-Series\\_Prediction](https://www.researchgate.net/publication/3336037_DENFIS_Dynamic_Evolving_Neural-Fuzzy_Inference_System_and_Its_Application_for_Time-Series_Prediction)>. Acesso em: 22 nov. 2020.

KOELSTRA, S. et al. Deap: A database for emotion analysis using physiological signals. **IEEE Transactions on Affective Computing**, v. 3, p. 18–31, 12 2011. Disponível em: <[https://www.researchgate.net/publication/232651717\\_DEAP\\_A\\_Database\\_for\\_Emotion\\_Analysis\\_Using\\_Physiological\\_Signals](https://www.researchgate.net/publication/232651717_DEAP_A_Database_for_Emotion_Analysis_Using_Physiological_Signals)>. Acesso em: 01 set. 2020.

KÜBLER, A. et al. A brain-computer interface controlled auditory event-related potential (P300) spelling system for locked-in patients. **Annals of the New York Academy of Sciences**, v. 1157, p. 90–100, 04 2009. Disponível em: <[https://www.researchgate.net/publication/24262320\\_A\\_Brain-Computer\\_Interface\\_Controlled\\_Auditory\\_Event-Related\\_Potential\\_P300\\_Spelling\\_System\\_for\\_Locked-In\\_Patients](https://www.researchgate.net/publication/24262320_A_Brain-Computer_Interface_Controlled_Auditory_Event-Related_Potential_P300_Spelling_System_for_Locked-In_Patients)>. Acesso em: 08 dez. 2020.

- LEITE, D. **Evolving Granular Systems**. Tese (Doutorado) — State University of Campinas (UNICAMP), 2012. Disponível em: <[https://www.researchgate.net/publication/334446175\\_Evolving\\_Granular\\_Systems](https://www.researchgate.net/publication/334446175_Evolving_Granular_Systems)>. Acesso em: 06 nov. 2020.
- LEITE, D. et al. Optimal rule-based granular systems from data streams. **IEEE Tran Fuzzy Syst**, v. 28, n. 3, p. 583–596, mar 2020. Disponível em: <[https://www.researchgate.net/publication/343404182\\_Optimal\\_Rule-Based\\_Granular\\_Systems\\_From\\_Data\\_Streams](https://www.researchgate.net/publication/343404182_Optimal_Rule-Based_Granular_Systems_From_Data_Streams)>. Acesso em: 06 set. 2020.
- LEITE, D. et al. Evolving fuzzy granular modeling from nonstationary fuzzy data streams. **Evolving Systems**, v. 3, 06 2012. Disponível em: <[https://www.researchgate.net/publication/257786757\\_Evolving\\_fuzzy\\_granular\\_modeling\\_from\\_nonstationary\\_fuzzy\\_data\\_streams](https://www.researchgate.net/publication/257786757_Evolving_fuzzy_granular_modeling_from_nonstationary_fuzzy_data_streams)>. Acesso em: 06 nov. 2020.
- LEITE, D.; COSTA, P.; GOMIDE, F. Evolving granular neural networks from fuzzy data streams. **Neural Networks**, v. 38, p. 1–16, nov 2013. Disponível em: <[https://www.researchgate.net/publication/233827871\\_Evolving\\_granular\\_neural\\_networks\\_from\\_fuzzy\\_data\\_streams](https://www.researchgate.net/publication/233827871_Evolving_granular_neural_networks_from_fuzzy_data_streams)>. Acesso em: 22 nov. 2020.
- LEITE, D. et al. EGFC: Evolving gaussian fuzzy classifier from never-ending semi-supervised data streams – with application to power quality disturbance detection and classification. p. 1–9, 2020. Disponível em: <[https://www.researchgate.net/publication/340822908\\_EGFC\\_Evolving\\_Gaussian\\_Fuzzy\\_Classifier\\_from\\_Never-Ending\\_Semi-Supervised\\_Data\\_Streams\\_-\\_With\\_Application\\_to\\_Power\\_Quality\\_Disturbance\\_Detection\\_and\\_Classification](https://www.researchgate.net/publication/340822908_EGFC_Evolving_Gaussian_Fuzzy_Classifier_from_Never-Ending_Semi-Supervised_Data_Streams_-_With_Application_to_Power_Quality_Disturbance_Detection_and_Classification)>. Acesso em: 06 nov. 2020.
- LEMOS, A.; CAMINHAS, W.; GOMIDE, F. Evolving intelligent systems: Methods, algorithms and applications. **Smart Innovation, Systems and Technologies**, v. 13, p. 117–159, 01 2013. Disponível em: <[https://www.researchgate.net/publication/285211892\\_Evolving\\_Intelligent\\_Systems\\_Methods\\_Algorithms\\_and\\_Applications](https://www.researchgate.net/publication/285211892_Evolving_Intelligent_Systems_Methods_Algorithms_and_Applications)>. Acesso em: 22 nov. 2020.
- LI, Y. et al. A quantum mechanics-based framework for EEG signal feature extraction and classification. **IEEE Transactions on Emerging Topics in Computing**, p. 1–1, 2020. Disponível em: <[https://www.researchgate.net/publication/342061634\\_A\\_quantum\\_mechanics-based\\_framework\\_for\\_EEG\\_signal\\_feature\\_extraction\\_and\\_classification](https://www.researchgate.net/publication/342061634_A_quantum_mechanics-based_framework_for_EEG_signal_feature_extraction_and_classification)>. Acesso em: 02 dez. 2020.
- LIN, Y.-P.; JUNG, T.-P.; ONTON, J. Toward affective brain-computer interface: Fundamentals and analysis of EEG-based emotion classification. In: \_\_\_\_\_. [s.n.], 2015. p. 315–341. ISBN 9781118130667. Disponível em: <[https://www.researchgate.net/publication/278316153\\_Toward\\_Affective\\_Brain-Computer\\_Interface\\_Fundamentals\\_and\\_Analysis\\_of\\_EEG-Based\\_Emotion\\_Classification](https://www.researchgate.net/publication/278316153_Toward_Affective_Brain-Computer_Interface_Fundamentals_and_Analysis_of_EEG-Based_Emotion_Classification)>. Acesso em: 08 dez. 2020.
- LOTTE, F.; BOUGRAIN, L.; CLERC, M. Electroencephalography (EEG)-based brain-computer interfaces. In: **Wiley Encyclopedia of Electrical and Electronics Engineering**. Wiley, 2015. p. 44. Disponível em: <<https://hal.inria.fr/hal-01167515>>. Acesso em: 21 nov. 2020.
- MADDULA, R. et al. Deep recurrent convolutional neural networks for classifying P300 BCI signals. In: . [s.n.], 2017. Disponível em: <<https://www.researchgate.net/publication/>

320434061\_DEEP\_RECURRENT\_CONVOLUTIONAL\_NEURAL\_NETWORKS\_FOR\_CLASSIFYING\_P300\_BCI\_SIGNALS>. Acesso em: 12 nov. 2020.

MAK, J. N.; WOLPAW, J. R. Clinical applications of brain-computer interfaces: Current state and future prospects. **IEEE Reviews in Biomedical Engineering**, v. 2, p. 187–199, 2009. Disponível em: <[https://www.researchgate.net/publication/224085382\\_Clinical\\_Applications\\_of\\_Brain-Computer\\_Interfaces\\_Current\\_State\\_and\\_Future\\_Prospets](https://www.researchgate.net/publication/224085382_Clinical_Applications_of_Brain-Computer_Interfaces_Current_State_and_Future_Prospets)>. Acesso em: 11 nov. 2020.

MCFARLAND, D. et al. Emulation of computer mouse control with a noninvasive brain-computer interface. **Journal of neural engineering**, v. 5, p. 101–10, 07 2008. Disponível em: <<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC2757111/>>. Acesso em: 08 dez. 2020.

MITRUȚ, O. et al. Emotion classification based on biophysical signals and machine learning techniques. **Symmetry**, v. 12, p. 21, 12 2019. Disponível em: <[https://www.researchgate.net/publication/338118399\\_Emotion\\_Classification\\_Based\\_on\\_Biophysical\\_Signals\\_and\\_Machine\\_Learning\\_Techniques](https://www.researchgate.net/publication/338118399_Emotion_Classification_Based_on_Biophysical_Signals_and_Machine_Learning_Techniques)>. Acesso em: 09 out. 2021.

NGUYEN, T. et al. Eeg signal classification for bci applications by wavelets and interval type-2 fuzzy logic systems. **Expert Systems with Applications**, v. 42, 06 2015. Disponível em: <[https://www.researchgate.net/publication/272891407\\_EEG\\_signal\\_classification\\_for\\_BCI\\_applications\\_by\\_wavelets\\_and\\_interval\\_type-2\\_fuzzy\\_logic\\_systems](https://www.researchgate.net/publication/272891407_EEG_signal_classification_for_BCI_applications_by_wavelets_and_interval_type-2_fuzzy_logic_systems)>. Acesso em: 01 dez. 2020.

NICOLAS-ALONSO, L. F.; GOMEZ-GIL, J. Brain computer interfaces, a review. **Sensors (Basel, Switzerland)**, v. 12, p. 1211–79, 12 2012. Disponível em: <[https://www.researchgate.net/publication/221967606\\_Brain\\_Computer\\_Interfaces\\_a\\_Review](https://www.researchgate.net/publication/221967606_Brain_Computer_Interfaces_a_Review)>. Acesso em: 21 nov. 2020.

NOLAN, H.; WHELAN, R.; REILLY, R. FASTER: Fully automated statistical thresholding for EEG artifact rejection. **Journal of Neuroscience Methods**, v. 192, n. 1, p. 152 – 162, 2010. ISSN 0165-0270. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0165027010003894>>. Acesso em: 21 nov. 2020.

ORHAN, U.; HEKIM, M.; OZER, M. EEG signals classification using the K-means clustering and a multilayer perceptron neural network model. **Expert Systems with Applications**, v. 38, n. 10, p. 13475 – 13481, 2011. ISSN 0957-4174. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0957417411006762>>. Acesso em: 03 dez. 2020.

PEDRYCZ, W.; GOMIDE, F. **Fuzzy Systems Engineering: Toward Human-Centric Computing**. first. New Jersey: Wiley: Hoboken, 2007. Disponível em: <[https://www.researchgate.net/publication/220692625\\_Fuzzy\\_Systems\\_Engineering\\_Toward\\_Human-Centric\\_Computing](https://www.researchgate.net/publication/220692625_Fuzzy_Systems_Engineering_Toward_Human-Centric_Computing)>. Acesso em: 22 nov. 2020.

RAHMAN, M. A. et al. Employing PCA and t-statistical approach for feature extraction and classification of emotion from multichannel EEG signal. **Egyptian Informatics Journal**, v. 21, n. 1, p. 23 – 35, 2020. ISSN 1110-8665. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1110866519301720>>. Acesso em: 02 dez. 2020.

RICHHARIYA, B.; TANVEER, M. EEG signal classification using universum support vector machine. **Expert Systems with Applications**, v. 106, p. 169 – 182, 2018. ISSN 0957-4174. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0957417418302100>>. Acesso em: 02 dez. 2020.

RUSSELL, J. A circumplex model of affect. **Journal of Personality and Social Psychology**, v. 39, p. 1161–1178, 12 1980. Disponível em: <[https://www.researchgate.net/publication/235361517\\_A\\_Circumplex\\_Model\\_of\\_Affect](https://www.researchgate.net/publication/235361517_A_Circumplex_Model_of_Affect)>. Acesso em: 19 set. 2021.

SATAPATHY, S. K.; DEHURI, S.; JAGADEV, A. K. EEG signal classification using PSO trained RBF neural network for epilepsy identification. **Informatics in Medicine Unlocked**, v. 6, p. 1 – 11, 2017. ISSN 2352-9148. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S2352914816300387>>. Acesso em: 02 dez. 2020.

SKRJANC, I. et al. Evolving fuzzy and neuro-fuzzy approaches in clustering, regression, identification, and classification: A survey. **Inf. Sci.**, v. 490, p. 344–368, jul 2019. Disponível em: <[https://www.researchgate.net/publication/332041753\\_Evolving\\_Fuzzy\\_and\\_Neuro-Fuzzy\\_Approaches\\_in\\_Clustering\\_Regression\\_Identification\\_and\\_Classification\\_A\\_Survey](https://www.researchgate.net/publication/332041753_Evolving_Fuzzy_and_Neuro-Fuzzy_Approaches_in_Clustering_Regression_Identification_and_Classification_A_Survey)>. Acesso em: 06 nov. 2020.

SOARES, E. et al. Ensemble of evolving data clouds and fuzzy models for weather time series prediction. **Appl Soft Comput**, v. 64, p. 445–453, 2018. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S1568494617307573>>. Acesso em: 06 nov. 2020.

STIGLER, S. M. A modest proposal: A new standard for the normal. **The American Stat.**, v. 36, n. 2, p. 137–138, nov 1982.

SUBASI, A.; ERÇELEBI, E. Classification of EEG signals using neural network and logistic regression. **Computer Methods and Programs in Biomedicine**, v. 78, n. 2, p. 87 – 99, 2005. ISSN 0169-2607. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0169260705000246>>. Acesso em: 03 dez. 2020.

SUBASI, A.; GURSOY, M. I. EEG signal classification using PCA, ICA, LDA and support vector machines. **Expert Systems with Applications**, v. 37, n. 12, p. 8659 – 8666, 2010. ISSN 0957-4174. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0957417410005695>>. Acesso em: 02 dez. 2020.

SUGENO, M.; KANG, G. Structure identification of fuzzy model. **Fuzzy Sets and Systems**, v. 28, n. 1, p. 15 – 33, 1988. ISSN 0165-0114. Disponível em: <<http://www.sciencedirect.com/science/article/pii/0165011488901133>>. Acesso em: 09 dez. 2020.

SWEENEY, K. T.; WARD, T. E.; MCLOONE, S. F. Artifact removal in physiological signals—practices and possibilities. **IEEE Transactions on Information Technology in Biomedicine**, v. 16, n. 3, p. 488–500, 2012. Disponível em: <[https://www.researchgate.net/publication/221857994\\_Artifact\\_Removal\\_in\\_Physiological\\_Signals-Practices\\_and\\_Possibilities](https://www.researchgate.net/publication/221857994_Artifact_Removal_in_Physiological_Signals-Practices_and_Possibilities)>. Acesso em: 21 nov. 2020.

TAKAGI, T.; SUGENO, M. Fuzzy identification of systems and its applications to modeling and control. **IEEE Transactions on Systems, Man, and Cybernetics**, SMC-15, n. 1, p. 116–132, 1985. Disponível em: <<https://ieeexplore.ieee.org/document/6313399>>. Acesso em: 09 dez. 2020.

- TATTOLI, G. et al. A novel BCI-SSVEP based approach for control of walking in virtual environment using a convolutional neural network. **Proceedings of the International Joint Conference on Neural Networks**, jul. 2014. Disponível em: <[https://www.researchgate.net/publication/265173645\\_A\\_novel\\_BCI-SSVEP\\_based\\_approach\\_for\\_control\\_of\\_walking\\_in\\_Virtual\\_Environment\\_using\\_a\\_Convolutional\\_Neural\\_Network](https://www.researchgate.net/publication/265173645_A_novel_BCI-SSVEP_based_approach_for_control_of_walking_in_Virtual_Environment_using_a_Convolutional_Neural_Network)>. Acesso em: 12 nov. 2020.
- TEPLAN, M. Fundamental of EEG measurement. **MEASUREMENT SCIENCE REVIEW**, v. 2, 01 2002. Disponível em: <[https://www.researchgate.net/publication/228599963\\_Fundamental\\_of\\_EEG\\_Measurement](https://www.researchgate.net/publication/228599963_Fundamental_of_EEG_Measurement)>. Acesso em: 10 nov. 2020.
- VASILJEVIC, G.; MIRANDA, L. Brain-computer interface games based on consumer-grade EEG devices: A systematic literature review. **International Journal of Human-Computer Interaction**, 06 2019. Disponível em: <[https://www.researchgate.net/publication/333566540\\_Brain-Computer\\_Interface\\_Games\\_Based\\_on\\_Consumer-Grade\\_EEG\\_Devices\\_A\\_Systematic\\_Literature\\_Review](https://www.researchgate.net/publication/333566540_Brain-Computer_Interface_Games_Based_on_Consumer-Grade_EEG_Devices_A_Systematic_Literature_Review)>. Acesso em: 11 nov. 2020.
- VEGA-ESCOBAR, L.; CASTRO-OSPINA, A. E.; DUQUE-MUÑOZ, L. Feature extraction schemes for BCI systems. In: **2015 20th Symposium on Signal Processing, Images and Computer Vision (STSIVA)**. [s.n.], 2015. p. 1–6. Disponível em: <[https://www.researchgate.net/publication/315365742\\_Feature\\_extraction\\_schemes\\_for\\_BCI\\_systems](https://www.researchgate.net/publication/315365742_Feature_extraction_schemes_for_BCI_systems)>. Acesso em: 11 nov. 2020.
- VERMA, G.; TIWARY, U. S. Affect representation and recognition in 3d continuous valence-arousal-dominance space. **Multimedia Tools and Applications**, v. 76, 01 2017. Disponível em: <[https://www.researchgate.net/publication/284724383\\_Affect\\_Representation\\_and\\_Recognition\\_in\\_3D\\_Continuous\\_Valence-Arousal-Dominance\\_Space](https://www.researchgate.net/publication/284724383_Affect_Representation_and_Recognition_in_3D_Continuous_Valence-Arousal-Dominance_Space)>. Acesso em: 19 set. 2021.
- VOZHENKO, T. I.; CHEPIN, E. V.; URVANOV, G. A. The control system based on extended BCI for a robotic wheelchair. **Procedia Computer Science**, v. 123, p. 522 – 527, 2018. ISSN 1877-0509. 8th Annual International Conference on Biologically Inspired Cognitive Architectures, BICA 2017 (Eighth Annual Meeting of the BICA Society), held August 1-6, 2017 in Moscow, Russia. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1877050918300802>>. Acesso em: 08 dez. 2020.
- WANG, X. et al. From numeric data to information granules: A design through clustering and the principle of justifiable granularity. **Knowledge-Based Systems**, v. 101, p. 100–113, mar 2016. Disponível em: <[https://www.researchgate.net/publication/298799992\\_From\\_Numeric\\_Data\\_to\\_Information\\_Granules\\_A\\_Design\\_Through\\_Clustering\\_and\\_the\\_Principle\\_of\\_Justifiable\\_Granularity](https://www.researchgate.net/publication/298799992_From_Numeric_Data_to_Information_Granules_A_Design_Through_Clustering_and_the_Principle_of_Justifiable_Granularity)>. Acesso em: 06 nov. 2020.
- WU, S. et al. Fuzzy integral with particle swarm optimization for a motor-imagery-based brain-computer interface. **IEEE Transactions on Fuzzy Systems**, v. 25, n. 1, p. 21–28, 2017. Disponível em: <[https://www.researchgate.net/publication/306075845\\_Fuzzy\\_Integral\\_With\\_Particle\\_Swarm\\_Optimization\\_for\\_a\\_Motor-Imagery-Based\\_Brain-Computer\\_Interface](https://www.researchgate.net/publication/306075845_Fuzzy_Integral_With_Particle_Swarm_Optimization_for_a_Motor-Imagery-Based_Brain-Computer_Interface)>. Acesso em: 12 nov. 2020.
- XU, G. et al. A deep transfer convolutional neural network framework for EEG signal classification. **IEEE Access**, v. 7, p. 112767–112776, 2019. Disponível em: <[https://www.researchgate.net/publication/334691492\\_A\\_Deep\\_Transfer\\_Convolutional\\_Neural\\_Network\\_Framework\\_for\\_EEG\\_Signal\\_Classification](https://www.researchgate.net/publication/334691492_A_Deep_Transfer_Convolutional_Neural_Network_Framework_for_EEG_Signal_Classification)>. Acesso em: 02 dez. 2020.

XUE, J.; GU, X.; NI, T. Auto-weighted multi-view discriminative metric learning method with fisher discriminative and global structure constraints for epilepsy EEG signal classification. **Frontiers in Neuroscience**, v. 14, 2020. Disponível em: <[https://www.researchgate.net/publication/345962953\\_Auto-Weighted\\_Multi-View\\_Discriminative\\_Metric\\_Learning\\_Method\\_With\\_Fisher\\_Discriminative\\_and\\_Global\\_Structure\\_Constraints\\_for\\_Epilepsy\\_EEG\\_Signal\\_Classification](https://www.researchgate.net/publication/345962953_Auto-Weighted_Multi-View_Discriminative_Metric_Learning_Method_With_Fisher_Discriminative_and_Global_Structure_Constraints_for_Epilepsy_EEG_Signal_Classification)>. Acesso em: 02 dez. 2020.

XYDEAS, C. et al. Advances in classification of EEG signals via evolving fuzzy classifiers and dependant multiple HMMs. **Computers in Biology and Medicine**, v. 36, n. 10, p. 1064 – 1083, 2006. ISSN 0010-4825. Intelligent Technologies in Medicine and Bioinformatics. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0010482505001022>>. Acesso em: 01 dez. 2020.

YAGER, R. Measures of specificity over continuous spaces under similarity relations. **Fuzzy Set and Systems**, v. 159, p. 2193–2210, sep 2008. Disponível em: <[https://www.researchgate.net/publication/220527864\\_Measures\\_of\\_specificity\\_over\\_continuous\\_spaces\\_under\\_similarity\\_relations](https://www.researchgate.net/publication/220527864_Measures_of_specificity_over_continuous_spaces_under_similarity_relations)>. Acesso em: 06 nov. 2020.

ZHANG, X. et al. A survey on deep learning-based non-invasive brain signals: recent advances and new frontiers. **Journal of Neural Engineering**, 2020. Disponível em: <[https://www.researchgate.net/publication/346807137\\_A\\_survey\\_on\\_deep\\_learning-based\\_non-invasive\\_brain\\_signals\\_recent\\_advances\\_and\\_new\\_frontiers](https://www.researchgate.net/publication/346807137_A_survey_on_deep_learning-based_non-invasive_brain_signals_recent_advances_and_new_frontiers)>. Acesso em: 06 nov. 2020.

ZHU, Y. Chapter 4 - identification by the least-squares method. In: ZHU, Y. (Ed.). **Multivariable System Identification For Process Control**. Oxford: Pergamon, 2001. p. 65 – 96. ISBN 978-0-08-043985-3. Disponível em: <<http://www.sciencedirect.com/science/article/pii/B9780080439853500065>>. Acesso em: 09 dez. 2020.

ZHUANG, J.; GENG, K.; YIN, G. Ensemble learning based brain-computer interface system for ground vehicle control. **IEEE Transactions on Systems, Man, and Cybernetics: Systems**, p. 1–13, 2019. Disponível em: <[https://www.researchgate.net/publication/337852397\\_Ensemble\\_Learning\\_Based\\_Brain-Computer\\_Interface\\_System\\_for\\_Ground\\_Vehicle\\_Control](https://www.researchgate.net/publication/337852397_Ensemble_Learning_Based_Brain-Computer_Interface_System_for_Ground_Vehicle_Control)>. Acesso em: 08 dez. 2020.