

# Aprendizado Incremental Online para Classificação Fuzzy de Emoções em Jogos a partir de Fluxos de Dados EEG

Volnei Frigeri Jr.\* Pedro Farah\* Rodrigo Medeiros\*  
Daniel Leite\*

\* Departamento de Automática, Universidade Federal de Lavras, UFLA  
E-mail: vjunior.frigeri@gmail.com, pedroannoni@hotmail.com,  
rodrigo.nmedeiros19@gmail.com, daniel.leite@ufla.br

**Abstract:** We describe an online machine learning algorithm to construct evolving Gaussian Fuzzy Classifiers (eGFC). We present a method to extract and select attributes from the Fourier spectrum of electro-encephalogram data. The data are provided by 28 subjects exposed to the games ‘Train Sim World’, ‘Unravel’, ‘Slender The Arrival’, and ‘Goat Simulator’. According to the Arousal-Valence system, 4 types of emotions prevail (boredom, calmness, horror, and joy). We analyse individual electrodes and the effect of time windows and dimensionality reduction on the accuracy of eGFC. We conclude that both brain hemispheres may assist classification, specially electrodes on the temporal (T7-T8), occipital (O1-O2), and frontal (Af3-Af4) lobes. We observe that patterns may eventually arise in any part of the spectrum, from 1 to 64 Hz. The eGFC approach has shown to be effective for real-time Big-data problems. It reaches a 72,2% accuracy with a compact rule base, and a 1.8 ms/sample processing speed.

**Resumo:** Descrevemos um algoritmo de aprendizado de máquina online para construção de Classificadores Fuzzy Gaussianos (eGFC). Apresentamos um método de extração e seleção de atributos do espectro de Fourier de dados de eletro-encefalograma. Os dados são obtidos de 28 indivíduos expostos aos jogos de computador ‘Train Sim World’, ‘Unravel’, ‘Slender The Arrival’, e ‘Goat Simulator’. De acordo com o sistema Arousal-Valence, 4 emoções prevalecem (tédio, calma, horror e diversão). Analisamos eletrodos individuais e o efeito de janelas de tempo e redução de dimensionalidade no desempenho de eGFC. Concluímos que eletrodos em ambos os hemisférios do cérebro auxiliam na classificação, especialmente aqueles dos lobos temporal (T7-T8), occipital (O1-O2) e frontal (Af3-Af4). Observamos que padrões podem surgir em qualquer parte do espectro de frequências, entre 1 e 64 Hz. A abordagem eGFC é efetiva para o problema *Big data* em tempo real. Ela alcança uma acurácia de 72,2% usando uma estrutura compacta de regras, e velocidade de processamento de 1,8 ms/amostra.

**Keywords:** Brain-Computer Interface, Evolving Fuzzy System, Online Machine Learning.

**Palavras-chave:** Interface Cérebro-Computador, Sistema Fuzzy Evolutivo, Aprendizado de Máquina Online.

## 1. INTRODUÇÃO

O reconhecimento de emoções humanas por parte das máquinas tem sido um tópico de crescente interesse científico, clínico e tecnológico. Emoções são comunicadas não-verbalmente por meio de expressões faciais, gestos, linguagem corporal e tons de voz. Sistemas de visão computacional e dispositivos de interface cérebro-computador (BCI: *brain-computer interface*) são as principais linhas em reconhecimento de emoções. Tal reconhecimento tem implicações úteis em uma variedade de domínios em que a inteligência artificial tem oferecido: (i) suporte à tomada de decisão; (ii) controle de sistemas mecatrônicos, softwares e agentes; e (iii) realismo, eficiência e interatividade.

Dispositivos BCI processam respostas neuro-fisiológicas. Enfatizamos dados de encefalograma (EEG). Eletrodos EEG à seco são interessantes para reconhecimento da atividade cerebral, gerada por estímulos visuais e auditivos.

Algoritmos de aprendizado de máquina convencionais para construção de modelo a partir de dados EEG são muitas vezes ineficazes, já que o volume de dados é enorme e os padrões mudam. É necessário transformações, extração de atributos, modelos não-lineares, janelas, e algoritmos capazes de lidar com fluxos de dados (Leite, 2012).

O problema da alta dimensionalidade em aplicações EEG é discutido em (Nakisa et al., 2018). Um algoritmo evolucionário é usado para selecionar um sub-conjunto ótimo de atributos. É apresentada literatura sobre métodos de extração de atributos. Bases de dados *benchmark* são usadas para avaliar classificadores de emoções em quadrantes do sistema Arousal-Valence (Russell, 1980). No presente artigo, propõe-se extrair atributos de faixas do espectro de Fourier dos sinais de eletrodos e uso do método *Scores* e correlação de Spearman (Soares et al., 2018). Os estímulos são visual-auditivos e relacionados a jogos.

Para endereçar os requisitos de não-linearidade e variação temporal de modelo, é adotada a abordagem denominada Classificador Fuzzy Gaussiano Evolutivo (eGFC: *evolving Gaussian Fuzzy Classifier*) (Leite et al., 2020b; Decker et al., 2020). Trata-se de um método de aprendizado semi-supervisionado, que usa fluxo não-estacionário de dados para atualizar a estrutura de um modelo fuzzy. A abordagem não requer armazenamento de dados nem conhecimento prévio. eGFC opera em tempo real usando hiper-parâmetros adaptativos ou *default*. Foi analisado o problema de classificação de emoções em jogos.

## 2. INTERFACE CÉREBRO-COMPUTADOR

BCIs são dispositivos compostos por eletrodos EEG, hardware de alto desempenho para tratamento de dados, e um ambiente computacional para monitoramento, classificação de padrões, previsão ou suporte à tomada de decisão. A partir de uma BCI é possível ler, analisar, diferenciar e interpretar sinais fisiológicos refletidos em ondas cerebrais (Alonso and Gomez-Gil, 2012). Elas permitem ao usuário interagir com computadores, softwares, dispositivos eletrônicos ou mecânicos, ou com outros humanos a partir do pensamento ou de movimentos. Para isso é necessário que exista um canal de comunicação entre os elementos de interesse (Fatourehchi et al., 2007).

As aplicações tradicionais de BCIs se concentram em soluções que promovam a interação entre humanos e máquinas através de sinais cerebrais (Ferreira et al., 2013), e.g., controle de dispositivos mecânicos, como uma cadeira de rodas, mas sem a necessidade de força manual. As aplicações são diferenciadas de acordo com aspectos como: (i) dispositivo empregado (invasivo/não-invasivo); (ii) estímulo do sinal (exógeno/endógeno); (iii) forma de processamento (síncrona/assíncrona); e (iv) objetivo (ativo, passivo ou reativo) (Vasiljevic and Miranda, 2020).

Entre os métodos EEG, a abordagem não-invasiva é predominante, visto que, apesar da menor resolução espacial provida pelo conjunto de eletrodos e da interferência externa que se manifesta por meio de ruído e distorções nos dados, evita-se implantes cerebrais e riscos. O EEG lê os sinais cerebrais a partir do couro cabeludo, passivamente (Kim et al., 2013). Ademais, há sincronismo da leitura de eletrodos, e predomina a análise de estímulos endógenos, i.e., dependentes de resposta cognitiva a estímulos sensoriais. No presente trabalho, a análise se dá neste contexto.

### 2.1 Classificação de Emoções e Sistema 10-20

A emoção é uma reação afetiva em relação a um evento (Mauss and Robinson, 2009). Ela é definida como um estado mental. Os sistemas BCI podem reconhecer emoções a partir de dados EEG (Gu et al., 2020; Cao et al., 2019). Tal reconhecimento pode ser realizado a partir de métodos estatísticos, redes neurais, máquinas de vetor suporte, modelos fuzzy, e outros. O desenvolvimento de modelos detectores ou classificadores requer dados históricos disponíveis, além de treinamento *offline* para convergência dos parâmetros. Os dados EEG podem ser combinados com outros dados fisiológicos, tais como expressão facial, frequência cardíaca, contagem do piscar de olhos, et al., visando a obtenção de maior acurácia na classificação (Vasiljevic and Miranda, 2020).

A posição de eletrodos EEG segue o sistema internacional 10-20. As posições são definidas com base em referências: *Nasion*, localizado na parte superior do nariz, e *Inion*, na parte traseira do crânio (Alonso and Gomez-Gil, 2012). O sistema 10-20 é empregado em muitos EEGs comerciais. Estes são amplamente empregados em pesquisa científica. A Fig. 1 mostra a posição ideal dos eletrodos; P3 e P4 são pontos de referência. Os 14 pontos em verde são, em particular, mensurados pelo dispositivo EEG Emotiv EPOC+. Os 5 pontos em branco também podem ser considerados. Por exemplo, o dispositivo Open BCI considera todos.

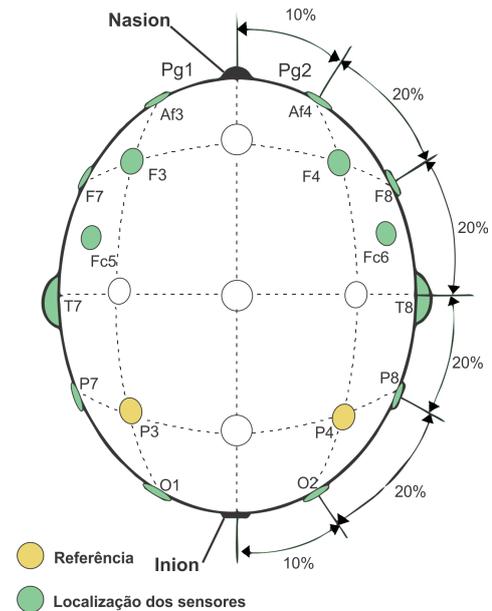


Figura 1. EEG: Sistema internacional 10-20

### 2.2 Modelo Arousal-Valence e Jogos

O modelo Arousal-Valence considera as emoções humanas em classes (Russell, 1980), ver Fig. 2. Rearranjamos a numeração das classes, de 1 a 4, conforme nosso problema de classificação. Do lado esquerdo do círculo constam emoções negativas, N ('bravo', 'entediado' e adjetivos relativos), enquanto do lado direito tem-se emoções positivas, P ('feliz', 'tranquilo' e adjetivos relativos). A área 1 refere-se a uma baixa excitação negativa, e.g., sono e tristeza; enquanto a área 3 é de alta excitação negativa, e varia de emoções nervosas a irritantes. A área 2 refere-se a uma baixa excitação positiva, e inclui os estados calmo, passivo e relaxado. A área 4 inclui as altas emoções de excitação positiva, que variam da satisfação à animação.

Queremos classificar emoções no momento da exposição de indivíduos a jogos. Neste contexto, é importante diferenciar as emoções do *observador* e do *ator*, i.e., de alguém que efetivamente altera o jogo ou não (Frome, 2007). O observador tem o jogo como uma obra de arte. Em outras palavras, ele se impressiona com seu desenvolvimento, mas, por não influenciar diretamente o resultado, suas emoções são relativamente mais fracas, com tendência às áreas 1 e 2 do círculo de Russell. O ator tem atividade mental elevada. Ele processa cognitivamente as imagens, constrói a história mentalmente, avalia personagens e elementos. Logo, o ator pode apresentar estados em todo o círculo de

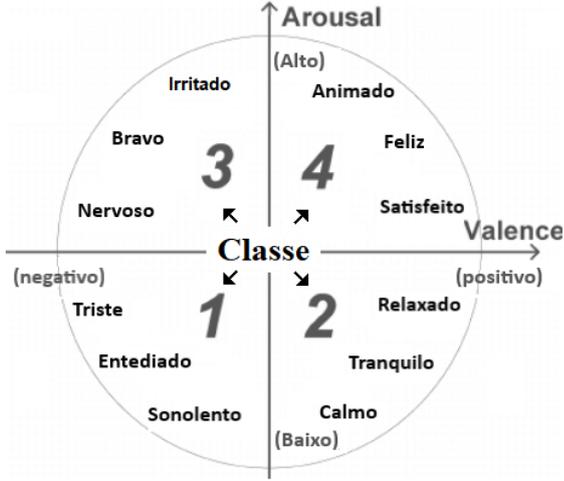


Figura 2. Modelo Arousal-Valence de emoções

Russell, sendo subjetiva a questão de tendência a alguma área. Em análise de emoções, jogos são muito utilizados (Fedwa et al., 2014; Vasiljevic and Miranda, 2020).

Consideramos um problema de classificação de acordo com o modelo Arousal-Valence. Indivíduos são expostos a 4 jogos, que sugerem comportamentos emocionais nos 4 quadrantes. Eles usam EEG e fones. Queremos classificar emoções a partir da análise granular do fluxo de dados EEG. Queremos construir um classificador adaptativo, i.e., provido de algoritmo incremental capaz de incorporar novos padrões, sem intervenção humana; durante a operação.

### 3. CLASSIFICADOR FUZZY EVOLUTIVO

Essa seção descreve um método de construção e adaptação incremental da estrutura e dos parâmetros de um modelo fuzzy a partir do fluxo de dados. O método, denominado eGFC, foi proposto em (Leite et al., 2020b). 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.

#### 3.1 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:

$$\text{SE } (x_1 \text{ é } A_1^i) \text{ E } \dots \text{ E } (x_n \text{ é } A_n^i)$$

$$\text{ENTÃO } (y \text{ é } C^i)$$

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 and Gomide, 2007).

#### 3.2 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. Se

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

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 et al., 2013).

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

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

A Eq. (2) é a abordagem de Stigler para funções Gaussianas padrões (Stigler, 1982; Leite et al., 2020a). 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

$$C^{c+1} = y^{[h]}. \quad (3)$$

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 (par-

cialmente 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., 2020a).

### 3.3 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

$$\min \left( A_1^i(x_1^{[h]}), \dots, A_n^i(x_n^{[h]}) \right) > \rho^{[h]}. \quad (4)$$

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

$$\mu_j^{i^*}(\text{novo}) = \frac{(\varpi^{i^*} - 1)\mu_j^{i^*}(\text{velho}) + x_j^{[h]}}{\varpi^{i^*}}, \quad (5)$$

e

$$\sigma_j^{i^*}(\text{novo}) = \left( \frac{(\varpi^{i^*} - 1)}{\varpi^{i^*}} \left( \sigma_j^{i^*}(\text{velho}) \right)^2 + \frac{1}{\varpi^{i^*}} \left( x_j^{[h]} - \mu_j^{i^*}(\text{velho}) \right)^2 \right)^{1/2}, \quad (6)$$

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,  $1/2\pi$ .

### 3.4 Adaptação do Nível $\rho$

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

$$\sigma_{avg}^{[h]} = \frac{1}{cn} \sum_{i=1}^c \sum_{j=1}^n \sigma_j^{i[h]}, \quad (7)$$

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

$$\rho(\text{novo}) = \frac{\sigma_{avg}^{[h]}}{\sigma_{avg}^{[h-1]}} \rho(\text{velho}). \quad (8)$$

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.

### 3.5 Mescla de Regras

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

$$d(\gamma^{i_1}, \gamma^{i_2}) = \frac{1}{n} \left( \sum_{j=1}^n |\mu_j^{i_1} - \mu_j^{i_2}| + \sigma_j^{i_1} + \sigma_j^{i_2} - 2\sqrt{\sigma_j^{i_1} \sigma_j^{i_2}} \right); \quad (9)$$

$d(\cdot)$  é a distância entre  $\gamma^{i_1}$  e  $\gamma^{i_2}$ . Essa medida considera a especificidade da informação, que, por vez, é inversamente proporcional à dispersão (Leite et al., 2020a).

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  $[0, 1]^n$ , sugerimos  $\Delta = 0, 1$  como valor padrão.

O novo grânulo  $\gamma^i$ , resultado da mescla de  $\gamma^{i_1}$  e  $\gamma^{i_2}$ , é construído por Gaussianas com valor modal

$$\mu_j^i = \frac{\frac{\sigma_j^{i_1}}{\sigma_j^{i_2}} \mu_j^{i_1} + \frac{\sigma_j^{i_2}}{\sigma_j^{i_1}} \mu_j^{i_2}}{\frac{\sigma_j^{i_1}}{\sigma_j^{i_2}} + \frac{\sigma_j^{i_2}}{\sigma_j^{i_1}}}, \quad j = 1, \dots, n, \quad (10)$$

e dispersão

$$\sigma_j^i = \sigma_j^{i_1} + \sigma_j^{i_2}, \quad j = 1, \dots, n. \quad (11)$$

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

### 3.6 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.

### 3.7 Algoritmo eGFC

O procedimento de aprendizado para construir e atualizar modelos eGFC é dado em Algoritmo 1.

## 4. METODOLOGIA

É descrito o problema de classificação de emoções e a base de dados considerada. São apresentados o procedimento de extração de atributos e as medidas de desempenho. Dois experimentos, considerando canais individuais e o sistema multi-variável acoplado, são descritos.

---

**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. (2)), classe  $C^{c+1}$  indef.;
5: FOR  $h = 2, \dots$  DO
6:   Ler  $\mathbf{x}^{[h]}$ , calcular ativação de regras (Eq. (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. (2)-(3));
12:    ELSE
13:     Criar grânulo  $\gamma^{c+1}$ , classe indef. (Eqs. (2));
14:    END
15:  ELSE
16:    IF classe  $y^{[h]}$  está disponível
17:     Atualizar grânulo mais ativo  $\gamma^{i^*}$  cuja classe
18:      $C^{i^*}$  é igual a  $y^{[h]}$  (Eqs. (5)-(6));
19:     Rotular grânulos ativos sem rótulo;
20:    ELSE
21:     Atualizar grânulo  $\gamma^{i^*}$  mais ativo (Eqs. (5)-(6));
22:    END
23:  END
24:  Atualizar nível  $\rho$  (Eqs. (7)-(8));
25:  Remover regras inativas baseado em  $h_r$ ;
26:  Mesclar regras baseado em  $\Delta$  (Eqs. (9)-(11));
27: END

```

---

#### 4.1 Sobre o Experimento e Base de Dados

O método de aprendizado de máquina online e classificação eGFC é avaliado a partir de um fluxo de dados EEG produzido por grupos de indivíduos expostos a 4 jogos. Cada jogo estimula emoções diferentes, conforme os 4 quadrantes do sistema Arousal-Valence. Logo, o objetivo é atribuir as amostras de dados EEG coletadas a um rótulo de classe relativo a uma emoção. As classes do problema são: ‘Classe 1’, entediado; ‘Classe 2’, calmo; ‘Classe 3’, horrorizado; e ‘Classe 4’, feliz. Os dados originais considerados foram aqueles disponibilizados em (Alakus et al., 2020).

Os dados foram obtidos a partir de 28 indivíduos entre 20 e 27 anos de idade, incluindo estudantes, professores e funcionários da Faculdade de Tecnologia da *Firat University*, Turquia. Os indivíduos são saudáveis, sem histórico de doenças. Cada indivíduo jogou cada um dos jogos por 5 minutos usando o mesmo EEG (Emotiv Epop+) e fones. Cada indivíduo produziu dados por 20 minutos. Estímulos auditivos e visuais são capturados pelos 14 canais EEG. A posição dos 14 eletrodos Emotiv Epop+, segundo o sistema internacional 10-20, é: Af3, Af4, F3, F4, F7, F8, Fc5, Fc6, T7, T8, P7, P8, O1, O2, P3 e P4, sendo P3 e P4 as referências, vide Fig. 1. A taxa de amostragem é 128Hz. Cada indivíduo gera 38.400 amostras de dados por jogo, e 153.600 no total.

Os experimentos foram realizados em sala relativamente escura e silenciosa. Os jogos foram apresentados por meio de um notebook com tela de 15,6 polegadas e placa gráfica GTX980M de 16 GB. A resolução de tela é máxima e a renderização gráfica é de alta qualidade. Para aumentar a

concentração dos indivíduos antes do experimento, houve um período de relaxamento. Esta fase consistiu em repetir a sequência: manter os olhos fechados por 10 segundos, e manter abertos por 10 segundos. Os indivíduos não sabiam o nome dos jogos *a priori*, e nunca tinham os jogado. Os jogos foram apresentados sempre na mesma sequência: chato (Classe 1), calmo (Classe 2), raiva/horror (Classe 3), e engraçado/feliz (Classe 4). As classes não retratam a opinião geral. Os jogos são ‘Train Sim World’, ‘Unravel’, ‘Slender The Arrival’, e ‘Goat Simulator’, ver Fig. 3.

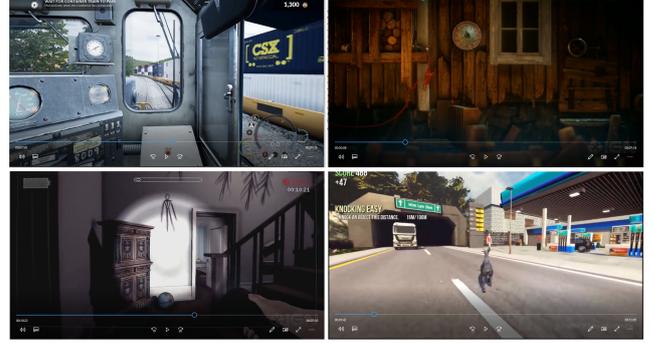


Figura 3. Exemplo de interface dos jogos Train Sim World, Unravel, Slender The Arrival, e Goat Simulator usados para obtenção dos dados EEG

#### 4.2 Pré-Processamento e Extração de Atributos

A base de dados foi pré-processada a partir da aplicação de um filtro *sinc* (seno cardinal) de quinta ordem com o objetivo de eliminar interferência resultante de movimentos da cabeça, braços e mãos (Alakus et al., 2020). Em seguida, um conjunto de atributos foi extraído dos dados dos canais EEG dos 28 indivíduos.

Primeiramente, foi considerado, dentre os 14 canais EEG, um canal por vez, tal que os atributos tratam-se do valor médio e máximo de 5 faixas de frequência específicas do espectro de Fourier. As faixas são: Delta (1-4Hz), Theta (4-8Hz), Alpha (8-13Hz), Beta (13-30Hz) e Gamma (30-64Hz). Logo, 10 atributos são obtidos a partir de um canal. Se os 10 atributos são extraídos de uma janela de tempo de 5 minutos, então cada indivíduo gera 4 amostras (uma por jogo, ou uma apontando para cada uma das classes). No total, os 28 indivíduos geram 112 amostras. Avaliamos também janelas de 1 minuto (560 amostras), e 30 (1120 amostras) e 10 (3360 amostras) segundos. Portanto, temos uma análise individual para cada canal, *i.e.*, análise de série temporal univariada. Os 10 atributos,  $\mathbf{x} = [x_1 \dots x_{10}]$ , são alimentados no modelo eGFC.

Neste experimento, o objetivo é estimar a classe das amostras. São 4 as classes (emoções/jogos) possíveis. Porém foram avaliados atributos de eletrodos EEG individuais. Um classificador aleatório (*coin flipping*), sem suporte de aprendizado de máquina, tem expectativa de acurácia de 25%. Valores superiores indicam que houve um nível de aprendizado e captura de padrões no fluxo de dados.

A acurácia da classificação,  $Acc \in [0, 1]$ , é obtida de forma recursiva conforme

$$Acc(\text{novo}) = \frac{h-1}{h} Acc(\text{velho}) + \frac{1}{h} \tau, \quad (12)$$

em que  $\tau := 1$  se a estimativa é correta, isto é,  $\hat{C}^{[h]} = C^{[h]}$ , e  $\tau := 0$ , caso contrário. O número médio de grânulos fuzzy ao longo do tempo,  $c_{avg}$ , é uma medida da compacidade do modelo. Assim temos, recursivamente,

$$c_{avg}(\text{nov}) = \frac{h-1}{h} c_{avg}(\text{velho}) + \frac{1}{h} c^{[h]}. \quad (13)$$

O segundo experimento considera o problema global, i.e., o problema multi-classe baseado em série temporal multi-variada. Dados os 10 atributos extraídos dos 14 canais Emotiv EPOC+, tem-se um conjunto de 140 atributos passíveis de serem considerados como entrada do modelo eGFC. Avaliamos a redução de dimensionalidade a partir do método não-paramétrico de *Score* baseado em correlação de Spearman, conforme (Soares et al., 2018). Em essência, foi estabelecido o *rank* dos atributos mais correlacionados com a classe de saída e menos correlacionados com o resto dos atributos. Utilizou-se a estratégia *Leave One-Attribute Out*, para eliminar atributos gradativamente.

## 5. RESULTADOS

### 5.1 Experimento de Canal EEG Individual

Consideramos a análise individual dos eletrodos. Usamos os atributos  $\mathbf{x} = [x_1 \dots x_{10}]$  extraídos do espectro de Fourier de canal único como entrada do classificador eGFC. Utilizou-se hiper-parâmetros padrões. As classes de emoção são 4. A acurácia e compacidade dos modelos obtidos para amostras extraídas de diferentes tamanhos de janela, viz. 5 e 1 min., e 30 e 10 seg., estão na Tabela 1.

Nota-se na Tabela 1 que, para uma janela de 5 minutos, o classificador não é capaz de encontrar padrão no fluxo de dados. Ele funciona como um modelo que estima classes de forma aleatória. Valores de acurácia maiores que 25% surgem para janelas de menor comprimento. Isto sugere que o efeito filtro na extração de atributos de janelas de 5 minutos é grande, suprimindo detalhes cruciais. A acurácia média de eGFC para janela de 1 minuto, em torno de 40 a 41%, já é significativa, pois trata-se de informação extraída de apenas um eletrodo por vez. Para janelas menores, percebe-se que a acurácia aumenta usando uma estrutura de regras fuzzy mais compacta. Entretanto, a diferença entre a média de acurácia das janelas de 30 e 10 segundos é pequena, o que sugere saturação da curva de acurácia em torno de 45 a 46%, e que janelas menores que 10 segundos são dispensáveis. A questão da redução da base de regras é explicada visto um maior número de amostras  $\mathbf{x}$  quando tem-se janelas de 10 segundos apenas. Um maior número de amostras permite um maior número de passos de aprendizado, e faz com que os grânulos encontrem melhores posições e dispersões.

É importante observar na Tabela 1 que não há diferença significativa de acurácia para eletrodos dos hemisférios esquerdo e direito do cérebro. Apesar de que o hemisfério direito é conhecido por lidar com a interpretação emocional e estar associado à criatividade e intuição, os jogadores usam similarmente a interpretação lógica das situações (típicas do hemisfério esquerdo), e buscam razões para justificar suas decisões. Isso explica o surgimento de padrões em ambos os hemisférios. Em geral, os eletrodos

Tabela 1. Resultado eGFC por canal individual de EEG e diferentes tamanhos de janela

Janela de 5 minutos					
Hemisfério esquerdo			Hemisfério direito		
Canal	Acc(%)	$c_{avg}$	Canal	Acc(%)	$c_{avg}$
Af3	18,8	24,8	Af4	19,6	22,9
F3	23,2	21,3	F4	20,5	21,2
F7	17,0	21,2	F8	25,0	19,1
Fc5	24,1	22,5	Fc6	20,5	19,0
T7	22,3	20,2	T8	24,1	21,2
P7	18,8	21,7	P8	18,8	21,7
O1	21,4	21,9	O2	21,4	21,9
<b>Avg.</b>	20,8	21,9	<b>Avg.</b>	21,4	21,0
Janela de 1 minuto					
Hemisfério esquerdo			Hemisfério direito		
Canal	Acc(%)	$c_{avg}$	Canal	Acc(%)	$c_{avg}$
Af3	43,4	17,3	Af4	41,6	13,1
F3	37,0	14,3	F4	39,6	15,5
F7	41,3	14,5	F8	31,6	10,3
Fc5	38,4	16,1	Fc6	41,8	18,6
T7	43,9	14,4	T8	50,4	15,9
P7	37,9	17,4	P8	33,8	15,7
O1	45,0	16,3	O2	40,5	16,6
<b>Avg.</b>	41,0	15,8	<b>Avg.</b>	39,9	15,1
Janela de 30 segundos					
Hemisfério esquerdo			Hemisfério direito		
Canal	Acc(%)	$c_{avg}$	Canal	Acc(%)	$c_{avg}$
Af3	51,3	11,7	Af4	43,9	8,9
F3	40,5	10,3	F4	42,9	8,8
F7	44,2	10,3	F8	37,5	6,7
Fc5	41,3	10,8	Fc6	44,7	11,6
T7	40,4	10,2	T8	49,6	11,3
P7	46,3	9,4	P8	42,7	10,3
O1	45,9	10,1	O2	44,7	12,8
<b>Avg.</b>	44,3	10,4	<b>Avg.</b>	43,7	10,1
Janela de 10 segundos					
Hemisfério esquerdo			Hemisfério direito		
Canal	Acc(%)	$c_{avg}$	Canal	Acc(%)	$c_{avg}$
Af3	52,6	6,3	Af4	44,0	5,5
F3	41,8	6,1	F4	43,8	5,9
F7	46,3	6,1	F8	40,2	4,8
Fc5	40,5	5,7	Fc6	46,8	6,8
T7	40,4	5,7	T8	51,5	6,2
P7	46,9	6,7	P8	45,2	6,5
O1	47,7	6,6	O2	45,2	7,0
<b>Avg.</b>	45,2	6,2	<b>Avg.</b>	45,2	6,1

T7 e T8, e O1 e O2, posicionados nos lobos temporais e occipitais, respectivamente, proveem as maiores acurácias – embora os eletrodos no entorno, Fc5 e Fc6, e P7 e P8; e frontais, Af3 e Af4, também carreguem informações relevantes. Os lobos temporais são úteis para percepção auditiva, da linguagem, memória declarativa, visual e emoção. Os lobos occipitais contêm o córtex visual primário e áreas de associação visual. Como esperado, os eletrodos T7 e T8, e O1 e O2 se mostram interessantes.

### 5.2 Experimento Multivariado

Considerou-se, em conjunto, os 140 atributos extraídos do espectro de frequência dos 14 eletrodos Emotiv EPOC+ para janelas de 10 segundos sobre os 20 minutos de grava-

ção. Estabelecemos um *rank* dos atributos de acordo com o método não-paramétrico de *Scores* – que considera a correlação de Spearman entre atributos, e entre atributos e classes (Soares et al., 2018). Na sequência, usamos a estratégia *Leave One-Attribute Out* para eliminar atributos acumulativamente, a partir do *rank*. A Tabela 2 mostra os resultados eGFC para os diferentes conjuntos de dados e atributos. Foi usado um notebook quad-core i7-8550U com 1,80 GHz e 8 GB de RAM em sistema Windows 10.

Tabela 2. Resultado eGFC após método *Leave One-Attribute Out*

# atributos	Acc (%)	$c_{avg}$	Tempo (s)
140	72,20	5,52	6,032
135	71,10	5,70	5,800
130	71,46	5,68	5,642
125	71,25	5,75	5,624
120	70,89	5,79	5,401
115	70,92	5,68	5,193
110	70,68	5,73	4,883
105	70,68	5,71	4,676
100	70,24	5,78	4,366
95	70,12	5,69	4,290
90	69,91	5,66	3,983
85	66,31	5,53	3,673
80	65,09	5,45	3,534
75	65,48	5,26	3,348
70	64,08	5,26	2,950
65	63,42	5,37	2,775
60	62,56	5,33	2,684
55	60,95	5,33	2,437
50	60,57	5,57	2,253
45	60,39	5,53	2,135
40	54,13	5,14	1,841
35	52,29	5,28	1,591
30	52,52	5,54	1,511
25	50,95	5,61	1,380
20	51,42	5,58	1,093
15	49,28	5,57	0,923
10	48,63	5,58	0,739

A Tabela 2 mostra que existe informação sobre os padrões espaço-temporais da atividade cerebral dos jogadores em todas as bandas, *i.e.*, Delta, Theta, Alpha, Beta e Gamma. Algum atributo de qualquer dos eletrodos EEG pode vir a auxiliar a decisão do classificador e, consequentemente, contribuir com a acurácia global. Porém, tal contribuição de uma banda e atributo específico não é sistemática. Assim, a acurácia maior de eGFC, 72,2%, acontece quando do uso de todos os 140 atributos extraídos do espectro de frequência. Todos os atributos podem vir a contribuir em algum momento. O tempo de processamento dos dados pelo algoritmo eGFC é um ponto a se enfatizar. As 3360 amostras com 140 atributos foram processadas em 6,032 segundos em um notebook comercial. Isso equivale a 1,8 mili-segundo por amostra. Não há armazenamento de dados. Para que esse desempenho seja mantido em configurações e cenários diferentes é importante que a estrutura do modelo (o número de regras  $c_{avg}$ ) seja similarmente compacta, ou seja, em torno de 5,5 a 6 regras. Se o algoritmo decidir, autonomamente, que há necessidade de uma estrutura de modelo maior para uma acurácia maior

em um cenário, ou se expressarmos isso por meio dos hiper-parâmetros, então o tempo de processamento médio de 1,8 mili-segundo por amostra aumenta. De qualquer forma, adotadas janelas de 10 segundos (entrada de instâncias de dados em intervalos de 10 segundos), o algoritmo eGFC pode ainda operar em tempo real com boa folga para números bem maiores de atributos e regras. Segundo o estudo de complexidade temporal de algoritmos evolutivos em (Leite, 2012) – que aponta aumento quase-linear do tempo de processamento com o aumento gradativo do número de atributos, e aumento exponencial do tempo com o número de regras fuzzy – então 14000 atributos e 500 regras fuzzy (100× mais do que o utilizado) ainda não seriam um problema para a operação em tempo real. O algoritmo eGFC é factível para aplicações *Big data*.

Um exemplo de evolução da base de regras eGFC é mostrado na Fig. 4. Trata-se do experimento de maior acurácia (Tabela 2). O número de regras fuzzy varia entre 4 e 12, conforme a necessidade. Nota-se que, para se ter maior memória do passado, é interessante desligar o procedimento de remoção de regras fazendo  $h_r = \infty$ . Da mesma forma, um valor menor do hiper-parâmetro  $\Delta$  pode dificultar a mescla de grânulos (Sec. 3.5), e aumentar a memória. A memória de modelos evolutivos nunca foi discutida na literatura. O foco tem sido em acurácia e estrutura compacta. A Fig. 5 mostra a respectiva matriz de confusão. Há um relativo equilíbrio entre as classes, e confusões das estimações em todas as direções.

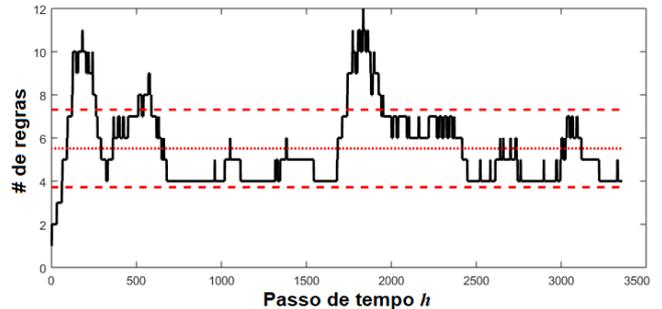


Figura 4. Evolução da base de regras eGFC

## 6. CONCLUSÃO

Aplicou-se um algoritmo de aprendizado de máquina online proposto recentemente, útil para construção incremental de modelos eGFC, na classificação de emoções em jogos. 28 jogadores foram expostos aos jogos Train Sim World, Unravel, Slender The Arrival, e Goat Simulator por um total de 20 minutos. As classes dos dados foram atribuídas de acordo com o modelo Arousal-Valence. Analisamos fluxos de dados de 14 eletrodos EEG. Foram extraídos atributos baseados em 5 bandas do espectro de Fourier: Delta, Theta, Alpha, Beta e Gamma. A contribuição de eletrodos individuais e o efeito do comprimento de janelas de tempo, e da redução de dimensionalidade, na acurácia global do classificador eGFC foram analisados.

Conclui-se que: (i) os eletrodos de ambos os hemisférios do cérebro auxiliam a classificação; (ii) eletrodos dos lobos temporal (T7 e T8), occipital (O1 e O2) e frontal (Af3 e Af4) carregam uma quantidade de informação ligeiramente

Classe estimada	1	757 22.5%	199 5.9%	116 3.5%	77 2.3%	65.9% 34.1%
	2	42 1.3%	598 17.8%	172 5.1%	96 2.9%	65.9% 34.1%
	3	13 0.4%	8 0.2%	539 16.0%	134 4.0%	77.7% 22.3%
	4	28 0.8%	35 1.0%	13 0.4%	533 15.9%	87.5% 12.5%
		90.1% 9.9%	71.2% 28.8%	64.2% 35.8%	63.5% 36.5%	72.2% 27.8%
	1	2	3	4	Classe alvo	

Figura 5. Matriz de confusão do melhor caso,  $Acc = 72,2\%$  maior do que os demais; (iii) padrões podem surgir em qualquer banda do espectro de Fourier; (iv) o algoritmo lida com amostras de dados EEG contendo 140 atributos em uma média de 1,8 mili-segundos por amostra. Assim, o algoritmo é bastante apropriado para problemas *Big data* e aplicações em tempo real; (v) um maior número de atributos (140 atributos) cobrindo todo o espectro de frequência e o uso de janelas de tempo de 10 segundos levaram ao melhor desempenho de classificação. Ademais uma acurácia de 72,2% foi alcançada pelo classificador fuzzy evolutivo eGFC.

No futuro serão avaliadas famílias wavelets na extração de atributos. Será considerada a imputação de eGFC em uma camada de rede neural profunda, de forma a obter extração automática de atributos e manter a capacidade evolutiva da abordagem eGFC.

#### AGRADECIMENTOS

Este trabalho recebeu apoio do Instituto Serrapilheira (processo Serra – 1812-26777).

#### REFERÊNCIAS

Alakus, T.B., Gonenb, M., and Turkoglu, I. (2020). Database for an emotion recognition system based on EEG signals and various computer games - gameemo. *Biomedical Signal Processing and Control*, 60(101951), 12p.

Alonso, L.F. and Gomez-Gil, J. (2012). Brain computer interfaces, a review. *Sensors*, 12(2), 1211–1279.

Cao, Z., Chuang, C.H., King, J.K., and Lin, C.T. (2019). Multi-channel EEG recordings during a sustained-attention driving task. *Scientific Data*, 6:19, 8p.

Decker, L., Leite, D., Giommi, L., and Bonacorsi, D. (2020). 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, 8p.

Fatourechi, M., Bashashati, A., Ward, R.K., and Birch, G.E. (2007). EMG and EOG artifacts in brain computer

interface systems: A survey. *Clinical Neurophysiology*, 118(3), 480–494.

Fedwa, L., Eid, M., and Saddik, A. (2014). An overview of serious games. *Int J Comput Game Technol*, 2014, 15p.

Ferreira, A.L.S. et al. (2013). A survey of interactive systems based on brain-computer interfaces. *SBC Journal on Interactive Systems*, 4(1), 3–13.

Frome, J. (2007). Eight ways videogames generate emotion. *DiGRA Conference*, 831–835.

Gu, X., Cao, Z., Jolfaei, A., Xu, P., Wu, D., Jung, T.P., and Lin, C.T. (2020). EEG-based brain-computer interfaces (BCIs): A survey of recent studies on signal sensing technologies and computational intelligence approaches and their applications. *arXiv:2001.11337*, 22p.

Kim, C.M., Kang, G.H., and Kim, E.S. (2013). A study on the generation method of visual-auditory feedback for BCI rhythm game. *J. Korea Game Soc.*, 13(6), 15–26.

Leite, D. (2012). *Evolving Granular Systems*. Ph.D. thesis, State University of Campinas (UNICAMP).

Leite, D., Andonovski, G., Skrjanc, I., and Gomide, F. (2020a). Optimal rule-based granular systems from data streams. *IEEE Tran Fuzzy Syst*, 28(3), 583–596.

Leite, D., Costa, P., and Gomide, F. (2013). Evolving granular neural networks from fuzzy data streams. *Neural Networks*, 38, 1–16.

Leite, D., Decker, L., Santana, M., and Souza, P. (2020b). EGFC: Evolving Gaussian fuzzy classifier from never-ending semi-supervised data streams - With application to power quality disturbance detection and classification. In *IEEE World Congr. Comput Intel (WCCI - FUZZ-IEEE)*, Glasgow, 8p.

Mauss, I.B. and Robinson, M.D. (2009). Measures of emotion: A review. *Cogn. Emot.*, 23(2), 209–237.

Nakisa, B., Rastgoo, M., Tjondronegoro, D., and Chandran, V. (2018). Evolutionary computation algorithms for feature selection of EEG-based emotion recognition using mobile sensors. *Expert Syst Appl*, 93(1), 143–155.

Pedrycz, W. and Gomide, F. (2007). *Fuzzy Systems Engineering: Toward Human-Centric Computing*. Wiley: Hoboken, New Jersey, first edition.

Russell, J. (1980). A circumplex model of affect. *Journal of Personality and Social Psychology*, 39(6), 1161–1178.

Skrjanc, I., Iglesias, J.A., Sanchis, A., Leite, D., Lughofer, E., and Gomide, F. (2019). Evolving fuzzy and neuro-fuzzy approaches in clustering, regression, identification, and classification: A survey. *Inf. Sci.*, 490, 344–368.

Soares, E., Costa, P., Costa, B., and Leite, D. (2018). Ensemble of evolving data clouds and fuzzy models for weather time series prediction. *Appl Soft Comput*, 64, 445–453.

Stigler, S.M. (1982). A modest proposal: A new standard for the normal. *The American Stat.*, 36(2), 137–138.

Vasiljevic, G. and Miranda, L. (2020). Brain-computer interface games based on consumer-grade EEG devices: A systematic literature review. *International Journal of Human-Computer Interaction*, 36(2), 105–142.

Wang, X., Pedrycz, W., Gacek, A., and Liu, X. (2016). From numeric data to information granules: A design through clustering and the principle of justifiable granularity. *Knowledge-Based Systems*, 101, 100–113.

Yager, R. (2008). Measures of specificity over continuous spaces under similarity relations. *Fuzzy Set and Systems*, 159, 2193–2210.