

Music genre classification using centrality measures of complex brain connectivity networks

Andres Eduardo Coca Salazar¹

¹Graduação em Engenharia de Computação,
Universidade Tecnológica Federal do Paraná (UTFPR),
Toledo, Brazil.

andressalazar@utfpr.edu.br

Abstract. *External stimuli can alter brain activity, bringing with them behavioral and/or emotional changes. The study of these effects serves to extract information that can be applied in personalized classification systems. In this paper, we propose a methodology for classifying the electroencephalogram (EEG) according to the music genre of the stimulus, using structural information from functional connectivity (FC) between electrodes and its representation and mining with complex networks. Wherefore, after having the preprocessed signal, the FC was determined through correlation (C_o) and Phase-Locking Value (PLV). For the resulting electrode network, we calculated global topological measures of integration, resilience, and segregation. In addition, to complement the feature matrix, we also calculated intraelectrode measures, but only for the nodes with the highest centrality. Since the networks are weighted, we also propose six new centrality measures ($\overline{C}_{ks}^{(p)}$), using degree and strength previously normalized and balanced with a tuning factor (α), and combined considering: 1) average node strength, 2) midpoint (arithmetic, harmonic, geometric, and quadratic), or 3) potentiating mutual interaction. Subsequently, we calculated conventional time series measures for the first n_k most central channels, obtaining a variable-dimensional feature vector. In machine learning, we used an ensemble classifier with 10-fold cross-validation. Experiments with C_o and PLV, for each $\overline{C}_{ks}^{(p)}$, and varying n_k and α , revealed that it is possible to identify, with an accuracy of 57.4%, the music genre by analyzing only the most synchronized and most intense channels.*

Resumo. *Estímulos externos podem alterar a atividade cerebral, trazendo consigo mudanças comportamentais e/ou emocionais. O estudo desses efeitos serve para extrair informação que pode ser aplicada em sistemas de classificação personalizada. Neste artigo, é proposta uma metodologia para classificar o eletroencefalograma (EEG) segundo o gênero de um estímulo musical, usando a informação estrutural da conectividade funcional (FC) entre eletrodos e a sua representação e mineração com redes complexas. Para tal, após ter o sinal pré-processado, foi determinada a FC mediante correlação (C_o) e PLV (Phase-Locking Value). Para a rede de eletrodos resultante, foram calculadas medidas topológicas globais de integração, resiliência e segregação. Além disso, para complementar a matriz de características, também foram calculadas medidas intra-elétrodos, porém somente para os nós com maior centralidade. Dado que*

as redes são ponderadas, aqui são propostas seis novas medidas de centralidade ($\overline{C}_{ks}^{(p)}$) usando o grau e a força local, previamente normalizadas e balanceadas com um fator de sintonia (α), e combinadas considerando: 1) força média do nó, 2) ponto médio (aritmético, harmônico, geométrico e quadrático), ou 3) potencializando a interação mútua. Posteriormente, foram calculadas medidas convencionais de séries de tempo para os primeiros n_k canais mais centrais, obtendo um vetor de características de dimensão variável. No aprendizado de máquina, foi usado um classificador de ensemble com 10-validação cruzada repetida 10 vezes. Experimentos com C_o e PLV; para cada $\overline{C}_{ks}^{(p)}$, e variando n_k e α ; revelaram que é possível identificar, com uma acurácia de 57.4%, o gênero musical analisando apenas os canais mais sincronizados e com maior intensidade.

1. Introdução

A análise do sinal cerebral permite extrair informação da atividade neuronal produto de uma patologia ou de um estímulo externo. O eletroencefalograma (EEG) é um registro não invasivo amplamente usado para captar tal dinâmica. A extração de conhecimento a partir do EEG traz grandes desafios pela magnitude dos dados coletados e pela falta de homogeneidade entre os indivíduos [Zhou 2011]. Mesmo assim, pesquisas nesse âmbito têm tido um crescente interesse entre os pesquisadores, por exemplo, na classificação de ações humanas iniciais [Carvalho et al. 2017].

Por outro lado, as redes complexas (RC) são uma poderosa ferramenta computacional que representa a interconexão existente entre os dados e permite extrair medidas da sua topologia local e global. As RCs são frequentemente usadas para mineração, pois contam com um grande leque de medidas [Silva and Zhao 2016]. Em virtude disso, diferentes aplicações das RCs em EEG podem ser encontradas, como na detecção de epilepsia [Supriya et al. 2023] ou reconhecimento de emoções [Yao et al. 2021]. Ademais, aplicações em música também são extensas, por exemplo, na extração de padrões rítmicos [Coca and Zhao 2016]. Especificamente, na classificação de gêneros musicais (MGC, *Music Genre Classification*), as RCs têm sido usadas para minerar espectrogramas convertidos em redes hierárquicas [Coca 2022]. Desta forma, os bons resultados obtidos mediante a mineração com RCs na classificação de sinais EEG, bem como na classificação de gêneros musicais, revelaram que o uso destas no desenvolvimento de um sistema MGC baseado em EEG (MGC-EEG) poderia trazer interessantes utilidades.

O sistema MGC-EEG proposto aproveita a vantagem das redes complexas na caracterização estrutural de elementos interconectados para extrair informações intrínsecas ao fluxo sináptico entre regiões do cérebro. Essa interconexão é determinada pelos métodos de conectividade funcional (FC, *Functional Connectivity*): correlação (C_o) [Šverko et al. 2022] e PLV (*Phase-Locking Value*) [Lachaux et al. 1999]. Portanto, após a etapa de pré-processamento, foram calculadas medidas topológicas globais para a rede de eletrodos resultante de cada FC.

Ademais, sob a hipótese de que o gênero de um estímulo musical afeta esse fluxo desde o ponto de vista do número de sincronizações com outras partes do crânio, bem como a sua intensidade; o que se veria refletido no grau e na força de sincronização dos nós da rede de canais; surgiu a questão de como combinar adequadamente estas duas

características. Sendo assim, também foram calculadas o grau e a força local, que, após serem normalizadas e a sua contribuição individual balanceada com o fator de sintonia α , foram combinadas mediante seis novas medidas de centralidade ($\overline{C}_{ks}^{(p)}$), sendo: 1) força média do nó, 2) ponto médio (aritmético, harmônico, geométrico e quadrático), ou 3) potencializando a interação conjunta. Estes valores de centralidade foram ranqueados e os primeiros n_k nós foram selecionados. Os canais correspondentes a esses nós são considerados mais influentes na distribuição do fluxo, portanto, as suas respectivas séries de tempo foram mineradas com medidas convencionais baseadas em: estatísticas, energia e entropia. As novas medidas de centralidade, além de ajudarem a determinar os canais mais destacados, também ajudam a reduzir a dimensionalidade do vetor de características, pois somente são minerados apenas alguns canais, em lugar da sua totalidade, diminuindo o custo computacional e destacando a informação mais importante. Na etapa de reconhecimento, foi usado o banco de dados DEAP¹ [Koelstra et al. 2012] e o classificador de ensemble floresta aleatória (RF, *Random Forest*), que tem apresentado excelentes resultados [Coca 2022], aplicado com validação cruzada 10-fold repetida 10 vezes. Na fase experimental, foram realizados experimentos com: 1) cada FC (Co e PLV); 2) cada $\overline{C}_{ks}^{(p)}$; 3) variando n_k ; e 4) variando α . Os resultados demonstraram que a acurácia é proporcional ao número de canais mais centrais, melhorando levemente com a FC derivada do domínio da frequência.

Este artigo está organizado assim: Seção 2 apresenta o estado d'arte e os fundamentos teóricos, Seção 3 descreve os passos do método proposto, e Seção 4 as novas medidas de centralidade. Seção 5 mostra os resultados experimentais, e Seção 6 as conclusões e o trabalho futuro.

2. Referencial teórico

Nesta seção é descrito o estado d'arte e a fundamentação teórica necessária que guiará a compreensão da metodologia proposta.

2.1. Trabalhos relacionados

No método seminal proposto por Ghaemmaghami e Sebe [Ghaemmaghami and Sebe 2016], os autores classificaram gêneros musicais usando informação extraída a partir de registros cerebrais não invasivos, EEG e MEG (Magnetoencefalograma), contidos nos bancos de dados DEAP e DECAF¹, respectivamente. As classes foram determinadas por votação de voluntários, obtendo dois gêneros: pop e rock. O resultado do classificador SVM² treinado com cada tipo de dados individualmente gerou um F-score de 66% e 62%, mas quando adicionaram características de análise de conteúdo multimídia de baixo nível, aumentou para 86% e 78%, respectivamente.

Por sua vez, C. McCluskey [McCluskey 2021] usou um subconjunto do banco de dados de Rahman et al. [Rahman et al. 2020], que registrou a atividade cerebral de 24 participantes usando o dispositivo especializado Emotiv EPOC com 14 canais, enquanto ouviam músicas de três gêneros: clássica, instrumental e pop. Para a caracterização, usou

¹DEAP (*Dataset for Emotion Analysis using Physiological Signals*), DECAF (*Decoding Affective Physiological Responses*).

²SVM: *Support Vector Machine*, ADAM: *Adaptive Moment Estimation*, SGD: *Stochastic Gradient Descent*, FIR: *Finite Impulse Response*.

somente o canal F7, cujo sinal foi minerado com 25 características estatísticas lineares (18) e não-lineares (7); e para a classificação aplicou uma rede neural artificial binária otimizada com ADAM² e SGD². Como resultado, a maior acurácia foi de 71.54% com um limiar de predição de 0.8.

2.2. Teoria do EEG

A atividade elétrica das ondas cerebrais é captada pelo EEG mediante eletrodos dispostos no couro cabeludo, abrangendo os lóbulos principais do cérebro³. Os eletrodos ativos usam circuitos que facilitam o registro, reduzem o ruído e dispensam de gel condutor. Na nomenclatura dos eletrodos, a letra indica o lóbulo no qual está posicionado e um número par/ímpar ou a letra z , sinaliza a sua localização hemisférica direita/esquerda ou plano sagital. O padrão de localização 10-20 refere-se à porcentagem de distância de separação entre eletrodos adjacentes vertical-horizontal no crânio [Zhou 2011]. O registro gera uma matriz multicanal de n_c séries de tempo $x(t)$ com duração T , isto é: $\mathbf{C} \in \mathbb{R}^{n_c \times T}$.

1. **Medidas:** Da matriz \mathbf{C} podem ser extraídas características das séries de tempo. No domínio do tempo, as medidas podem estar baseadas em entropia, energia, derivadas ou parâmetros estatísticos, dentre outras [Zhou 2011]. Nesta última categoria são encontrados os três **parâmetros de Hjorth**: 1) **Atividade** (HA), que corresponde com a variância, 2) **Mobilidade** (HM), que aplica HA no sinal e na sua primeira derivada, e 3) **Complexidade** (HC), que aplica HM no sinal e na sua primeira derivada, ficando assim:

$$HA = \sigma_x^2, \quad (1) \quad HM = \frac{\sigma_{x'}}{\sigma_x}, \quad (2) \quad HC = \frac{\sigma_x \sigma_{x''}}{\sigma_{x'}^2}. \quad (3)$$

Duas medidas estatísticas que mensuram a forma da distribuição do sinal são **assimetria** (v) e **curtose** (c), ambas baseadas em momentos⁴ $m_n(x) = E\{(x - \bar{x})^n\}$ de ordem superior $n > 2$, e em potências de ordem $p > 2$ da variância: $\sigma_x^p = E\{(x - \bar{x})^2\}^{p/2}$, onde $E\{\cdot\}$ é o valor esperado, assim:

$$v = \frac{m_3(x)}{\sigma_x^3}, \quad (4) \quad c = \frac{m_4(x)}{\sigma_x^4}. \quad (5)$$

A **energia** média do sinal (e_1) é uma característica básica dada por: $(1/T) \sum x^2$, para a qual, se for aplicado o logaritmo, é obtida a **entropia do logaritmo da energia** (e_2) (Eq. (6)). A **entropia de Shannon** (e_3) é uma medida baseada na teoria da informação que mensura o grau de desordem encontrado em um sinal em função da sua probabilidade $p_i = x_i^2 / \sum x_i^2$ (Eq. (7)).

$$e_2 = \sum \log(x_i^2), \quad (6) \quad e_3 = - \sum p_i \log_2(p_i). \quad (7)$$

³Frontal polar (Fp), frontal (F), central (C), temporal (T), parietal (P), e occipital (O). A nomenclatura do sistema de alta resolução MCN (*Modified Combinatorial Nomenclature*) usa eletrodos em regiões intermediárias, e.g., PO: entre P e O.

⁴Por facilidade de notação será obviada a variável do domínio quando necessário.

2. **Conectividade funcional (FC):** Os neurônios cerebrais interagem entre si, e na presença de estímulos essa interação fica mais acentuada entre alguns canais e entre algumas regiões do crânio. A sincronização produzida é mensurada por medidas de FC, as quais podem operar em diferentes domínios, como tempo, frequência ou informação [Bastos and Schoffelen 2016]. No domínio do tempo, a covariância S_{xy} é uma medida estatística que mensura o nível de variabilidade conjunta entre duas variáveis aleatórias, $x(t)$ e $y(t)$, com relação à média, dada por: $E\{(x(t) - E\{x(t)\})(y(t) - E\{y(t)\})\}$. O sinal de S_{xy} revela a existência de dependência linear, mas a interpretação da sua magnitude não é fácil. Portanto, prefere-se a versão normalizada com os desvios de cada variável, chamada coeficiente de correlação de Pearson (C_o , Eq. (8)) [Šverko et al. 2022], cuja magnitude indica o grau de relação linear e o sinal a existência de dependência linear, sendo: positiva, quando valores altos de uma correspondem com valores altos da outra; negativa (correspondência de valores altos com baixos) ou neutral (inexistência de dependência).

$$C_o = \frac{S_{xy}}{\sqrt{S_{xx}S_{yy}}} = \frac{S_{xy}}{\sigma_x\sigma_y}. \quad (8)$$

Se $x(t)$ for transformada ao domínio da frequência, é obtido para cada valor de frequência ω um número complexo, $x(\omega) = a + jb$, que representado em termos da magnitude e fase, $A_x(\omega)e^{j\phi_x(\omega)}$, contém informação espectral. Combinando duas representações espectrais mediante a multiplicação de uma com o complexo conjugado da outra ($x \cdot y^*$)⁴, é obtida a densidade espectral cruzada $S_{xy}(\omega) = A_x A_y e^{j(\phi_x - \phi_y)} = A_x A_y e^{j(\Delta\phi)}$, que aplicada para todas as combinações entre x e y e em disposição matricial, obtém-se a matriz $\mathbf{S}(\omega)$: $\begin{bmatrix} S_{xx}(\omega) & S_{xy}(\omega) \\ S_{yx}(\omega) & S_{yy}(\omega) \end{bmatrix}$, onde $S_{xx}(\omega) = A_x A_x e^{j(\phi_x - \phi_x)} = A_x^2 \cdot 1$. Com os elementos de $\mathbf{S}(\omega)$, calcula-se o coeficiente de coerência $coh_{xy}(\omega) = |S_{xy}(\omega)| / \sqrt{S_{xx}(\omega)S_{yy}(\omega)}$, que é o equivalente a C_o no domínio da frequência. A normalização em amplitude de $coh_{xy}(\omega)$, $A_x = A_y = 1$, produz $|e^{j(\Delta\phi)}|$, cujo valor médio para um conjunto de frequências é o PLV [Lachaux et al. 1999]:

$$PLV_{xy}(\omega) = |E\{e^{j(\phi_x(\omega) - \phi_y(\omega))}\}|. \quad (9)$$

2.3. Redes complexas

Uma rede complexa é denotada como $G = (V, E)$, onde V é um conjunto de nós e E um de arestas que conectam dois nós, $E \subseteq \{(i, j) | i, j \in V\}$, cujo total de elementos é n e m , respectivamente. A matriz de adjacência $\mathbf{A}_{n \times n}$ é uma descrição geral da rede, na qual o elemento $a_{ij} \in \{0, 1\}$ indica a existência ou ausência de conexão entre os nós i e j (rede não ponderada). Nas redes ponderadas, os elementos da matriz de adjacência $\mathbf{W}_{n \times n}$ são reais, chamados pesos, e indicam a força de conexão entre esses nós; enquanto nas não direcionadas cumpre-se $\mathbf{W} = \mathbf{W}^T$. As medidas topológicas quantificam a estrutura da rede e ajudam a compreender melhor o comportamento dos dados, e as suas categorias, e correspondentes medidas, são descritas a seguir [Silva and Zhao 2016].

1. **Integração:** A distância geodésica (d_{ij}) entre dois nós $i, j \in V$ é igual ao número de arestas (ou peso total no caso ponderado) do menor caminho exis-

tente entre eles, e é calculada usando um algoritmo especial, como o algoritmo de Floyd-Warshall. A **eficiência global** (E) quantifica a eficiência da rede para enviar informação entre nós, considerando que isso é inversamente proporcional à distância, assim:

$$E = \frac{1}{n(n-1)} \sum_{i,j \in V, i \neq j} \frac{1}{d_{ij}}. \quad (10)$$

Outra medida é a **excentricidade** (\hat{e}_i), a qual determina uma localização que maximiza a distância geodésica com relação a outras localizações, e corresponde com o maior caminho mínimo entre qualquer nó e o nó i , isto é: $\max \{d_{ij} : j \in V\}$. Algumas medidas globais derivadas de \hat{e}_i são: **excentricidade média** $\bar{e} = n^{-1} \sum_{i \in V} \hat{e}_i$, **raio** $r = \min_{i \in V} \hat{e}_i$, e **diâmetro** $\Delta = \max_{i \in V} \hat{e}_i$.

2. **Resiliência:** A mais importante quantidade local da rede é o **grau do nó** ($k_i \in \mathbb{N}$), o qual define o número de enlaces conectados ao nó i , que para uma rede não ponderada e não direcionada é calculado como: $k_i = \sum_j a_{ij} = \sum_j a_{ji}$. Para quantificar a rede toda em termos do grau, é usado o **grau médio** (\bar{k}):

$$\bar{k} = \frac{1}{n} \sum_i k_i = \frac{1}{n} \sum_{ij} a_{ij}. \quad (11)$$

A definição equivalente para redes ponderadas é a **força do nó** ($s_i \in \mathbb{R}$), que é calculada de forma similar, porém usando w_{ij} ao invés de a_{ij} .

3. **Segregação:** Dentro da estrutura da rede podem ser encontrados agrupamentos intrínsecos triplos, os quais ocorrem quando um nó i está conectado com um nó j e este, por sua vez, está conectado com um nó l . Então, é muito provável que o nó i esteja conectado também com o nó l , criando assim um triângulo. Essa forma de conexão é conhecida como transitividade (T_r), e é definida como a fração entre todos os triângulos da rede (N_Δ) e o número total de possíveis triângulos que poderiam ser formados (N_3), assim: $3N_\Delta/N_3$.
4. **Centralidade:** Mensura a importância de um nó com relação aos demais da rede, segundo uma propriedade que dependerá do objetivo da modelagem do grafo, podendo estar baseada em: distância (centralidade de proximidade), grau (centralidade de grau), ou caminhos mínimos (intermediação), dentre outros [Wan et al. 2021].

3. Metodologia do MGC-EEG proposto

A metodologia proposta é representada no diagrama de blocos da Fig. 1, e cada um dos seus passos é descrito nesta seção.

1. **Preparação e leitura:** O EEG cru precisa ser preparado antes de ser analisado. Esta etapa consiste em segmentar as épocas, eliminar ou refazer (se possível) as épocas e canais ruins, e reordenar os canais, dentre outros.
2. **Pré-processamento:** Nesta etapa foram aplicadas as seguintes tarefas: a) **Correção da linha base:** para o tramo anterior ao estímulo foi calculada a média e subtraída da época toda, e posteriormente removido; b) **Reamostragem:** para diminuir o tamanho e reduzir o custo computacional, a frequência de amostragem foi decrescida; c) **Re-referenciação:** no qual é definido um valor comum para

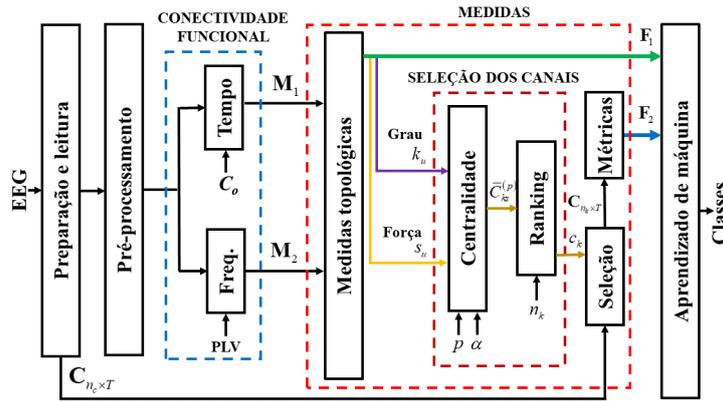


Figure 1. Diagrama de blocos do método MGC-EEG proposto.

todos os canais; d) Eliminação da **tendência polinomial**; e) **normalização** à amplitude máxima; f) **filtragem**: para eliminar ruído de alta frequência e a frequência da corrente direta; g) **remoção de artefatos**: para eliminar a influência de sinais fisiológicos: EOG, ECG...etc⁵.

3. **Redes de conectividade**: O valor de conectividade entre cada par de canais é disposto em uma matriz M com dimensão $n_c \times n_c$, que tem as mesmas propriedades da matriz de adjacência, portanto, gerando uma rede de eletrodos $G^{(j)}$, com $j \in \{1, 2\}$. Neste artigo usou-se a conectividade C_o e PLV, gerando as redes $G^{(1)}$ e $G^{(2)}$ com matrizes de adjacência M_1 e M_2 , respectivamente.
4. **Medidas topológicas**: A rede $G^{(j)}$ é minerada com medidas topológicas globais e o vetor de características resultantes é denotado como F_1 .
5. **Seleção de canais via centralidade**: Somente são selecionados os $n_k < n_c$ canais (nós) mais centrais da rede $G^{(j)}$. Para tal, aqui são propostas seis novas medidas de centralidade ($\bar{C}_{ks}^{(p)}(i, \alpha)$) baseadas no grau e na força, e descritas na Seção 4. A seleção da medida é feita com $p \in \{1 \dots 6\}$ e a sintonia com o parâmetro $\alpha \in \mathbb{R}$.
6. **Características das séries de tempo**: Com as séries de tempo dos n_k canais mais centrais ($c_k, k \in \{1 \dots n_k\}$) a matriz EEG é reduzida para $C_{n_k \times T}$. Essas séries são caracterizadas com medidas de diferentes domínios (Seção 2.2), e o vetor de características resultante é denotado como $F_2^{(k)}$.
7. **Aprendizado de máquina**: Com a matriz de características $F = \begin{bmatrix} F_1 & F_2^{(1)} & \dots & F_2^{(n_k)} \end{bmatrix}$ e os rótulos das classes, é treinado o algoritmo de aprendizado de máquina e estimadas as classes das instâncias de teste.

4. Novas medidas de centralidade

As seis novas medidas de centralidade estão baseadas na união de grau e força, e buscam quantificar a importância de um nó se ele tiver, ao mesmo tempo, muitas conexões com outros nós e com alta coesão, e.g., um nó é considerado mais central se tiver altos valores de grau e força simultaneamente. Existem medidas que consideram mais centrais aqueles nós que interagem com muitos outros, como a centralidade de grau [Silva and Zhao 2016], também generalizações para redes ponderadas de medidas de centralidade originalmente criadas para redes binárias, como a centralidade de intermediação

⁵EOG (Electrooculograma), ECG (Electrocardiograma): sinais dos movimentos dos olhos e do coração, respectivamente.

ponderada [Wan et al. 2021]. No entanto, são poucas as medidas que consideram conjuntamente esses dois valores. Uma delas foi proposta por Opsahl et al. [Opsahl et al. 2010], dada por $k_i^{(1-\alpha)} s_i^\alpha$, onde α é o parâmetro de sintonia que comuta entre operar somente com as conexões ($\alpha = 0$) e somente com os pesos ($\alpha = 1$); e valores entre 0 e 1 destacam as conexões fracas e maiores que 1 as fortes.

As medidas de centralidade propostas são denotadas com $\bar{C}_{ks}^{(p)}(i, \alpha)$, em que a barra (\bar{C}) significa que k_i está normalizado com relação ao máximo grau possível: $(n - 1)$, e s_i com relação à força total da rede: $s_T = \sum_{i \in n} s_i$. O primeiro critério considera a conservação da proporcionalidade entre as variáveis, para a qual uma variação em alguma delas conservará o mesmo efeito no valor final, exceto se controladamente se deseje destacar a contribuição de uma sobre a outra via α . Na primeira medida, um nó é mais central se a sua força média por grau for maior, isto é:

$$\bar{C}_{ks}^{(1)}(i, \alpha) = \frac{\alpha}{(1 - \alpha)} \frac{(n - 1) s_i}{s_T k_i}. \quad (12)$$

As seguintes medidas supõem que a centralidade deva ser um ponto intermédio entre grau e força ($\min \{k_i, s_i\} \leq C_{ks} \leq \max \{k_i, s_i\}$), definida harmônica $C_{ks}^{(2)}$, geométrica $C_{ks}^{(3)}$, aritmética $C_{ks}^{(4)}$ e quadráticamente $C_{ks}^{(5)}$, assim:

$$\bar{C}_{ks}^{(2)}(i, \alpha) = \frac{k_i s_i}{\alpha s_T k_i + (1 - \alpha) (n - 1) s_i}, \quad (13)$$

$$\bar{C}_{ks}^{(3)}(i, \alpha) = \left(\frac{1}{(n - 1)^{(1-\alpha)} s_T^\alpha} \right) k_i^{(1-\alpha)} s_i^\alpha, \quad (14)$$

$$\bar{C}_{ks}^{(4)}(i, \alpha) = \frac{(1 - \alpha)}{(n - 1)} k_i + \frac{\alpha}{s_T} s_i, \quad (15)$$

$$\bar{C}_{ks}^{(5)}(i, \alpha) = \sqrt{\frac{(1 - \alpha)}{(n - 1)^2} k_i^2 + \frac{\alpha}{s_T^2} s_i^2}. \quad (16)$$

O segundo critério considera que uma variável deve potencializar a outra na centralidade final, onde o resultado sempre será superior ao máximo delas ($C_{ks}(i, \alpha) \geq 2\alpha \cdot \max \{k_i, s_i\}$), chegando ao valor máximo quando forem iguais, caso no qual incrementará em um fator $\sqrt{2}$, obtendo:

$$\bar{C}_{ks}^{(6)}(i, \alpha) = \frac{2\sqrt{((1 - \alpha) s_T k_i)^2 + (\alpha (n - 1) s_i)^2}}{(n - 1) s_T}. \quad (17)$$

5. Resultados

Primeiramente, foi testado o comportamento das novas medidas de centralidade, visando guiar a interpretação e facilitar a análise dos resultados da metodologia. Dado que para as medidas é indistinguível a ordem das variáveis, com exceção da primeira, s_i foi fixada em 100, k_i variado entre 1 e 100, e para α foram definidos três valores: 0.25, 0.5 e 0.75. A

Fig. 2 mostra que $\overline{C}_{ks}^{(1)}$ tem dinâmica inversa a k_i , neste caso diminui rapidamente com o aumento de k_i . Caso contrário acontece com as outras medidas, onde a dinâmica é direta com a variação de alguma das variáveis, porém, $\overline{C}_{ks}^{(4)}$ linearmente e $\overline{C}_{ks}^{(6)}$ sempre $\geq 2\alpha s_i$ devido à potencialização. Perceba-se que o efeito de α baixo é priorizar a variável menor e alto a maior, modificando os pontos inicial e final do gráfico.

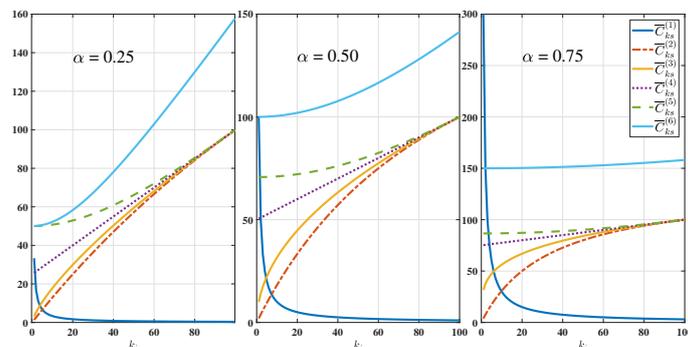


Figure 2. Dinâmica das novas medidas de centralidade com $s_i = 100$, $1 \leq k_1 \leq 100$ e α : 0.25, 0.5 e 0.75.

Para testar a metodologia foi usado o banco de dados DEAP, o qual contém o registro dos sinais eletrofisiológicos de 32 sujeitos, onde cada um foi submetido a 40 estímulos visual-auditivos, correspondentes com vídeos musicais de 1 min. de duração. Para o registro foi usado o dispositivo *Biosemi ActiveTwo System*, com 48 canais gravados a 512 Hz; sendo os primeiros 32 canais do EEG, os quais foram gravados com eletrodos ativos AgCI na disposição do sistema internacional 10-20, com dois ordenamentos Twente (Canais 1-22) e Geneva (23-32). Originalmente DEAP foi desenvolvido para a análise de estados afetivos humanos originados por música, e não para MGC. No entanto, o rótulo do gênero pode ser inferido. Neste artigo foram usados os rótulos inferidos em [Ghaemmaghami and Sebe 2016]: pop e rock.

Na etapa de processamento foram reordenados os canais para que todos ficassem na ordem Twente, foi usado o sistema de re-referenciação REST (*Reference Electrode Standardization Technique*) [Zhai and Yao 2004], um filtro passa-banda tipo FIR² de ordem 2 com faixa de frequência de 1 a 60 Hz, filtro Notch com banda 58-62 Hz, e remoção de artefatos usando o método de regressão CRLS (*Conventional Recursive Least Squares Algorithm*) [He et al. 2004], tendo como referência os canais EOG⁶, e o algoritmo wICA (*Wavelet enhanced Independent Component Analysis*) [Castellanos and Makarov 2006].

A Fig. 3 mostra para o sujeito #1, a matriz de adjacência (M_1) e a respectiva rede complexa $G^{(1)}$. Na etapa de mineração, foram usadas as seis medidas topológicas globais (vetor F_1), complementadas com as medidas (vetor $F_2^{(k)}$) das séries de tempo dos n_k canais mais centrais selecionados com cada $\overline{C}_{ks}^{(p)}$. Na parte experimental, foram testadas as seis medidas de centralidade, variando n_k acumulativamente de 1 a 3, e α com os mesmos valores do primeiro experimento.

Quando analisado por classes e para todos os sujeitos, na Fig. 4 encontra-se que os canais selecionados em cada classe são diferentes e mais numerosos para a classe 1 (pop),

⁶Canais 33 a 36 (horizontais: hEOG1 hEOG2, verticais: vEOG1 vEOG4).

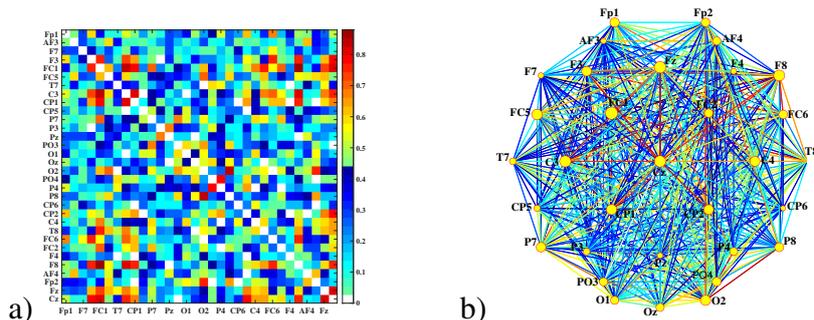


Figure 3. Conectividade com correlação do sujeito #1: a) Matriz de adjacência (M_1); b) Rede complexa ($G^{(1)}$).

e apenas os canais T7, PO4³, CP2 e FC2 são comuns. Revelando o índice de que o gênero musical muda a intensidade e a sincronização entre pares de canais. Também, percebe-se que alguns canais (Fp1, FC2, F7 e T7) não são afetados pelo fator de sintonia α , enquanto para outros, se for priorizada a intensidade de sincronização, a sua centralidade é alterada e, conseqüentemente, a sua seleção também.

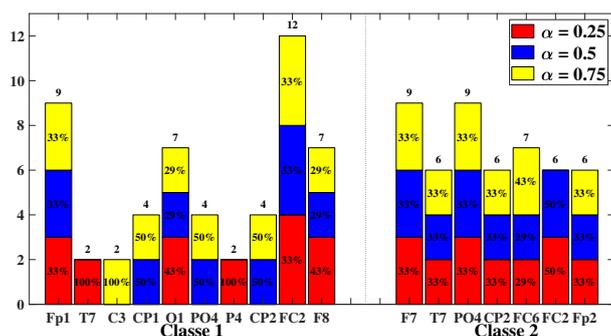


Figure 4. Histograma dos canais mais centrais nas duas classes.

Na Tabela 1 é mostrada a acurácia de classificação para cada experimento usando RF. Em todas as medidas, observa-se que a acurácia aumenta com o incremento do número de canais, já que os maiores valores foram com $n_k = 3$, e que priorizar a intensidade de sincronização (conforme analisado na Fig. 2) permite selecionar canais mais discriminantes, pois os maiores valores resultaram com $\alpha = 0.75$. Note-se que os melhores resultados, 57.33% e 57.4% com C_o e PLV, respectivamente, foram obtidos com $\overline{C}_{ks}^{(1)}$, indicando que nós com maior força média por grau correspondem com canais mais discriminantes.

6. Conclusões

Uma nova metodologia para a identificação do gênero musical a partir da análise do efeito no sinal EEG foi proposta. As redes de eletrodos, geradas mediante conectividade funcional em tempo e frequência, foram mineradas com medidas topológicas globais, e para complementar o vetor de características, também foram mineradas as séries dos eletrodos mais centrais. Para determinar a centralidade, foram propostas 6 medidas. Os melhores resultados foram obtidos com mais de dois canais centrais, indicando que a adição de mais medidas temporais ajuda a discriminar melhor o gênero. Como trabalho futuro propõe-se aprofundar o comportamento das novas medidas de centralidade, usar FC no domínio

Table 1. Resultado de classificação do MGC-EEG proposto.

C_o		Centralidade $\overline{C}_{ks}^{(p)}$					
α	n_k	$p = 1$	2	3	4	5	6
0.25	{1}	55.05	55.26	54.5	55.26	55.26	54.86
	{1, 2}	57.18	56.34	56.01	55.05	54.72	55.55
	{1 – 3}	56.81	56.33	56.30	56.27	56.67	56.47
0.50	{1}	54.93	55.02	55.08	55.51	54.47	55.33
	{1, 2}	57.33	56.43	56.16	55.56	55.55	55.46
	{1 – 3}	56.62	56.58	56.23	56.80	55.91	56.05
0.75	{1}	54.91	55.23	55.34	55.60	55.09	54.69
	{1, 2}	56.90	57.23	56.35	55.91	54.47	54.92
	{1 – 3}	56.33	56.74	55.99	56.25	56.01	55.93
PLV							
0.25	{1}	57.13	54.37	54.88	54.75	54.59	54.81
	{1, 2}	56.59	56.57	56.36	56.07	56.30	56.20
	{1, 2, 3}	56.61	56.16	56.35	56.11	56.38	56.22
0.50	{1}	57.19	54.72	54.48	54.74	54.48	54.34
	{1, 2}	56.87	55.30	56.48	56.21	56.59	56.47
	{1, 2, 3}	57.18	56.38	57.00	56.59	56.14	56.14
0.75	{1}	57.40	54.57	54.49	54.75	54.84	54.28
	{1, 2}	56.62	55.91	56.86	56.65	56.55	56.66
	{1, 2, 3}	56.83	56.22	56.55	56.66	56.66	56.78

da informação, como a causalidade de Granger, experimentar com a extração e análise do ritmo sensorio motor, adicionar mais gêneros e explorar outras tarefas no domínio de dados musicais, como detecção de regravações (*covers*).

References

- [Bastos and Schoffelen 2016] Bastos, A. and Schoffelen, J. (2016). A tutorial review of functional connectivity analysis methods and their interpretational pitfalls. *Frontiers in Systems Neuroscience*, 9(175):1–23.
- [Carvalho et al. 2017] Carvalho, S., Filho, I., Resende, D., Siravenha, A., Meiguins, B., Debarba, H., and Gomes, D. (2017). A novel procedure for classification of early human actions from EEG signals. In *Proc. Brazilian Conference on Intelligent Systems (BRACIS)*, pages 240–245.
- [Castellanos and Makarov 2006] Castellanos, N. and Makarov, V. (2006). Recovering EEG brain signals: Artifact suppression with wavelet enhanced independent component analysis. *Journal of Neuroscience Methods*, 158(2):300–312.
- [Coca 2022] Coca, A. (2022). Hierarchical mining with complex networks for music genre classification. *Digital Signal Processing*, 127(1):103559.
- [Coca and Zhao 2016] Coca, A. and Zhao, L. (2016). Musical rhythmic pattern extraction using relevance of communities in networks. *Information Sciences*, 329(1):819–848.

- [Ghaemmaghami and Sebe 2016] Ghaemmaghami, P. and Sebe, N. (2016). Brain and music: Music genre classification using brain signals. In *Proc. European signal Processing Conference (EUSIPCO)*, pages 708–712.
- [He et al. 2004] He, P., Wilson, G., and Russell, C. (2004). Removal of ocular artifacts from electro-encephalogram by adaptive filtering. *Medical & Biological Engineering & Computing*, 42:407–412.
- [Koelstra et al. 2012] Koelstra, S., Muhl, C., Soleymani, M., Lee, J., Yazdani, A., Ebrahimi, T., Pun, T., Nijholt, A., and Patras, I. (2012). DEAP: A database for emotion analysis using physiological signals. *IEEE Transactions on Affective Computing*, 3(1):18–31.
- [Lachaux et al. 1999] Lachaux, J., Rodriguez, E., Martinerie, J., and Varela, F. (1999). Measuring phase synchrony in brain signals. *Human Brain Mapping*, 8(4):194–208.
- [McCluskey 2021] McCluskey, C. (2021). Identifying music genre from electroencephalogram readings, and optimising neural network performance. In *Proc. ANU Bio-inspired Computing Conference (ABCs)*, volume 47, pages 1–5.
- [Opsahl et al. 2010] Opsahl, T., Agneessens, F., and Skvoretz, J. (2010). Node centrality in weighted networks: Generalizing degree and shortest paths. *Social Networks*, 32(3):245–251.
- [Rahman et al. 2020] Rahman, J., Gedeon, T., Caldwell, S., and Jones, R. (2020). Brain melody informatics: Analysing effects of music on brainwave patterns. In *Proc. International Joint Conference on Neural Networks (IJCNN)*, pages 1–8.
- [Silva and Zhao 2016] Silva, T. and Zhao, L. (2016). *Machine Learning in Complex Networks*. Springer International Publishing, 1 edition.
- [Supriya et al. 2023] Supriya, S., Siuly, S., Wang, H., and Zhang, Y. (2023). Epilepsy detection from EEG using complex network techniques: A review. *IEEE Reviews in Biomedical Engineering*, 16:292–306.
- [Šverko et al. 2022] Šverko, Z., Vrankić, M., Vlahinić, S., and Rogelj, P. (2022). Complex Pearson correlation coefficient for EEG connectivity analysis. *Sensors*, 22(1477):1–19.
- [Wan et al. 2021] Wan, Z., Mahajan, Y., Kang, B., Moore, T., and Cho, J.-H. (2021). A survey on centrality metrics and their network resilience analysis. *IEEE Access*, 9:104773–104819.
- [Yao et al. 2021] Yao, L., Wang, M., Lu, Y., Li, H., and Zhang, X. (2021). EEG-based emotion recognition by exploiting fused network entropy measures of complex networks across subjects. *Entropy*, 23(8):984.
- [Zhai and Yao 2004] Zhai, Y. and Yao, D. (2004). A study on the reference electrode standardization technique for a realistic head model. *Computer Methods and Programs in Biomedicine*, 76(3):229–238.
- [Zhou 2011] Zhou, J. (2011). *EEG Data Analysis, Feature Extraction and Classifiers*. PhD thesis, Clemson University.