

IDENTIFICAÇÃO DE ESFORÇO COGNITIVO ATRAVÉS DE PROCESSAMENTO DE SINAIS DE EEG UTILIZANDO SVM E RF

Lucas Rocha Figueredo Santana e Barros, lucas.oct8@gmail.com¹
Gerardo Antonio Idrobo Pizo, gerardo.idrobo@gmail.com¹

¹Universidade de Brasília, Faculdade do Gama, Área Especial, Projeção A, UnB -, Setor Leste – Gama, CEP 72444-240

Resumo: A atenção é altamente desejável em diversas situações e até vital em outras. No dia a dia é imprescindível que o sujeito esteja plenamente atento para que tenha o melhor rendimento possível na atividade que está fazendo. Para tanto, esse trabalho objetiva fazer uma detecção de esforço cognitivo utilizando processamento de sinais de eletroencefalografia (EEG) e por meio de dois algoritmos de aprendizagem de máquina: Máquinas de Vetores de Suporte (SVM) e Floresta Aleatória (RF). A proposta deste trabalho é usar como base um banco de dados de sinais de EEG em que os candidatos passaram parte do tempo de aquisição em descanso com olhos fechados e outra parte realizando contas aritméticas. Para realizar a detecção, foi feita a extração da energia, e segmentação no domínio da frequência dos sinais adquiridos para ser feito uso como parâmetros de entrada nos algoritmos de aprendizagem de máquina citados. Neste trabalho, um objetivo foi comparar acurácia e precisão dessas duas técnicas, e foi adquirida uma acurácia de 90% e 97% para os classificadores de SVM e RF, respectivamente; e uma precisão para a categoria de esforço cognitivo de 81% e 94% para esses dois classificadores, respectivamente. O outro objetivo deste estudo foi averiguar se há regiões encefálicas com maior ativação durante o esforço cognitivo em comparação ao estado de descanso, e foi constatada uma energia maior adquirida, para o espectro de ondas Theta, nos eletrodos das partes frontal polar, frontal e occipital se comparada à adquirida em outros eletrodos.

Palavras-chave: Processamento de sinais, EEG, Esforço Cognitivo, SVM, RF

1. INTRODUÇÃO

1.1. Contextualização

Carga cognitiva é compreendida como a composição de vários fatores que estão relacionados com o desempenho mental em uma atividade sendo convertido em aprendizado. Esse conceito reflete a proporção do aprendizado como consequência da tarefa em questão, podendo ser observada carga mental, esforço mental e eficiência. Existe uma relação entre atenção e esses parâmetros, de forma que se diminuída, os influencia negativamente (Paas, 2003). Durante as atividades acadêmicas a atenção é consideravelmente requisitada. A performance durante uma aula está diretamente relacionada com o nível de atenção (Zhang et al., 2021).

É possível aferir o estado mental de um indivíduo por meio de sinais de Eletroencefalografia (EEG), que é um método normalmente feito de forma não invasiva, cujo objetivo é capturar e registrar a atividade cerebral por meio de eletrodos colocados no couro cabeludo. A atividade é registrada como mudanças no potencial elétrico na superfície da pele que surge da atividade cerebral dos neurônios (Sanei, 2007). Essa análise pode aferir comportamentos e analisar prognóstico de estados neuropsiquiátricos. O sinal de EEG reflete a atividade eletrofisiológica do cérebro em um intervalo de tempo, ajudando a entender uma patologia escondida (Peng et al., 2020).

Existem diversas aplicações a partir de sinais de EEG como por exemplo sistema para detectar convulsões epiléticas (Abdelhameed e Bayoumi, 2019), classificação de estágios de sono (Acharya et al., 2005), diagnóstico de doença de Alzheimer (Adeli et al. 2008), detecção de alcoolismo (Acharya, 2012), diagnóstico de TDAH (Ahmadlou e Adeli, 2010; Ahmadlou e Adeli, 2011; Loo e Barkley, 2005 e Fayyad, 2017), detecção e classificação de atenção (Aziz, 2017; Purnamasari e Junika, 2019; Peng et al., 2020; Aziz, 2017 e Bird et al., 2018 e Zhang et al., 2021).

Identificação de esforço cognitivo é a motivação deste trabalho, e ainda utilizando algoritmos de inteligência artificial, cujas aplicações conseguem uma satisfatória generalização. Existem diversos trabalhos que utilizaram tal metodologia para detecção de esforço cognitivo e utilizando segmentação em frequência de sinais de EEG, demonstrando resultados satisfatórios (Purnamasari e Junika, 2019; Peng et al., 2020; Aziz, 2017; Bird et al., 2018 e Edla, 2018). As transformadas utilizadas para extração de características em frequência e as técnicas de aprendizagem de máquina que esses autores utilizaram em seus trabalhos estão descritos na Tab. 1.

Tabela 1. Trabalhos que utilizaram extração de características em frequência e técnicas de aprendizagem de máquina para identificar esforço cognitivo.

Referência bibliográfica	Transformada utilizada	Técnica de classificação	Acurácia
Aziz, 2017	DFT	ELM	71,75%
	HHT	ELM	72,16%
Peng et al., 2020	DFT	SVM	75,87%
	HHT	ELM	72,10%
Purnamasari e Junika, 2019	DFT	SVM	72%
	DWT	SVM	90%
Edla, 2018	DFT	RF	75%
Bird et al., 2018	DFT	SVM	75,14%
	DFT	RF	87,16%

Conforme será visto no Tópico 4, este trabalho utilizou a DFT como transformada e fez uso de SVM e RF para identificar empenho mental e foi possível obter uma acurácia de 90% e 97% para os dois métodos, respectivamente, porém não é possível comparar diretamente os resultados deste trabalho com os obtidos nas referências da Tabela 1, pois o banco de dados utilizados foram todos distintos entre si. Ou seja, todas as condições impostas aos sujeitos de cada experimento são diferentes, como as características específicas dos aparelhos de EEG e a forma de como foi realizado o experimento. Porém a metodologia dos experimentos utilizados como base no trabalho de (Edla, 2018) foi realizada se aproxima à forma como foi feita no experimento utilizada como base neste trabalho. Em ambas os sujeitos devem realizar operações aritméticas em um dado tempo e permanecer descansando de olhos fechados em um outro intervalo de tempo.

Além de apenas realizar a identificação de esforço cognitivo, este trabalho também visa fornecer detalhadamente informações para replicação de todo o projeto para identificação de empenho mental, com o intuito de simplificar a continuação desta aplicação para trabalhos futuros. Para tal, também será investigado se há regiões do cérebro com uma ativação maior que outras durante a atividade mental em questão que se deseja identificar. Saber de tal informação poderá servir de auxílio para um trabalho futuro cuja a aplicação é similar a este projeto.

1.2. Objetivo

Realizar identificação de esforço cognitivo através de processamento de sinais eletroencefalográficos utilizando SVM e RF, comparando acurácia e precisão desses dois métodos. Além disso, verificar se há regiões encefálicas com maior estimulação que outras durante uma atividade de empenho mental se comparar uma aquisição durante descanso.

1.3. Justificativa

Um exemplo de ambiente em que o esforço cognitivo é altamente requisitado é no contexto educacional. Ocorrem na maioria do tempo situações em que se faz necessária a concentração, e seria útil saber se os estudantes estão tendo um desempenho satisfatório nesse sentido.

Com relação à extração de características, a FFT tem sido comprovadamente um algoritmo que auxilia satisfatoriamente para identificação/classificação de atenção utilizando sinal de EEG de acordo com (Balasubramanian, 2014; Purnamasari e Junika, 2019; Peng et al., 2020; Aziz, 2017; Bird et al., 2018; Edla, 2018 e Zhang et al., 2021) em que a segmentação em bandas de frequência foi utilizada como parâmetros de entrada para classificadores.

No que se refere a efetivamente reconhecer um estado de esforço cognitivo, métodos de inteligência artificial foram satisfatoriamente utilizados, e tratando especificamente de SVM e RF, os dois métodos foram efetivamente impostos à aplicação em questão, e com a motivação a mais por terem baixa complexidade, podem ser colocados em aplicações de sistemas embarcados segundo (Edla, 2018 e Fraiwan, 2012).

O algoritmo de SVM é classicamente utilizado para tarefas de separação de duas classes, sendo muito bem aplicável a essa situação e tendo produzido bons resultados de acordo com (Purnamasari e Junika, 2019 e Peng et al., 2020). Outra característica favorável do SVM para o contexto é o fato de esse tipo de modelagem apresentar bons resultados para uma situação em que o dado de entrada possui relativamente uma baixa quantidade de exemplos se comparada ao número de parâmetros (Pinheiro, 2015).

Já RF é habitualmente utilizado em tarefas binárias também e produziu resultados satisfatórios para aplicações similares de acordo com (Bird et al., 2018 e Edla, 2018). Adicionalmente, por ser um classificador do tipo ensemble (mais detalhes sobre um classificador desse tipo serão mostrados no Tópico 2.4.3) produz uma robustez maior e se aplica bem à uma situação que conta com poucos exemplos para treinamento, porém muitos parâmetros, exemplo que teria uma chance considerável de underfitting.

2. FUNDAMENTAÇÃO TEÓRICA

2.1. Sinal Eletroencefalógrafo

Os sinais de EEG são a representação da atividade neural. Sua aquisição é feita por múltiplos eletrodos, normalmente de forma não invasiva, colocados sob o couro cabeludo.

A atividade elétrica cerebral se manifesta de maneira rítmica relativamente padronizada de cinco principais formas: alpha (α), theta (θ), beta (β), delta (δ), e gamma (γ). Ainda existem autores como (Purnamasari e Junika, 2019) que fazem uma segmentação um pouco diferente, dividindo o intervalo beta em baixo (14-20 Hz) e alto (20-30 Hz) e caracterizando como estados mentais distintos para os dois intervalos. Portanto, segmentar o espectro de mais de uma forma é uma estratégia para investigar aspectos do sinal e podendo ser usada para gerar diferentes características como entrada aos algoritmos de classificação. Uma representação típica pode ser observada na Tab. 2:

Tabela 2. Exemplo de estados mentais para cada espectro de sinal de EEG de acordo com (Sanei, 2007).

Onda	Intervalo típico
delta (δ)	0,5 – 4 Hz
theta (θ)	4 – 7,5 Hz
alpha (α)	7,5 – 14 Hz
beta (β)	14 – 30 Hz
gama (γ)	30 – 60 Hz

Existe uma indicação feita para o posicionamento dos eletrodos pela Federação Internacional de Sociedades de Eletroencefalografia e Neurofisiologia Clínica. O nome dessa convenção é denominado de Sistema 10-20, que recebeu essa nomenclatura devido à medida de distância ser posicionada entre 10 e 20% do tamanho disponível do couro cabeludo. Normalmente os eletrodos A1 e A2 são conectados próximos, respectivamente, à orelha esquerda e à direita. Os eletrodos restantes são frontal-polar (Fp1, Fp2), frontal (F3, F4, Fz, F7, F8), central (C3, C4, Cz) parietal (P3, P4, Pz), occipital (O1, O2) e temporal (T3, T4, T5, T6). Um exemplo de posicionamento pode ser observado na Fig. 3.




Figura 3. Representação do padrão 10/20 (Sanei, 2007).

2.2. Identificação de Esforço Cognitivo

Em indivíduos saudáveis e adultos, o sinal de EEG apresenta uma diferenciação, no que se refere à amplitude e frequência, quando por exemplo estão acordados ou dormindo.

Segundo (Rodriguez-Larios, J., et al., 2020 e Winnie, 2017), uma amplitude de sinal de EEG maior no espectro de ondas Theta foi adquirida em eletrodos da parte frontal da cabeça quando sujeitos executavam atividades que exigiam esforço cognitivo, se comparada à amplitude adquirida em outras regiões quando a situação exigia menos esforço.

Além disso, no trabalho de (Katahira, K., et al., 2018) foi encontrada uma maior atividade elétrica nos eletrodos da parte frontal, no espectro de ondas Theta para quando os sujeitos estavam realizando operações aritméticas.

2.3. Transformada Rápida de Fourier

Existe um conceito denominado projeção, que significa representar um sinal matemático em função de outros sinais, chamados sinais base. A Transformada de Fourier expressa uma função em relação a funções base senoidais, e com isso o sinal original é decomposto para ser representado no domínio da frequência. Portanto, agora serão evidenciadas características em frequência dessa expressão (Vetterli M., et al., 2014). Este autor descreve detalhadamente como realizar matematicamente a Transformada de Fourier, a Transformada Rápida de Fourier e como calcular a Energia do sinal desejado.

2.4. Técnicas de Classificação

O objetivo central do contexto de aprendizagem de máquina se apoia no sentido de enquadrar dados a uma determinada classe. Se essa divisão de grupos for previamente bem definida, o algoritmo de classificador é definido como supervisionado. É notório que essa linha se encaixa no contexto descrito, visto que o dado usado como base é do tipo rotulado.

No caso do sinal do EEG, a subdivisão em bandas de frequências vinculadas a sua energia é a característica central para possibilidade de classificação do estado mental de um indivíduo. Portanto o processamento é essencial para a extração de características que podem levar o classificador a ter um desempenho desejado.

Diferentes amplitudes de ondas Theta, Alfa, Beta e Gama podem ser relacionadas como indicadores de um estado mental de esforço cognitivo, segundo (Sanei, 2007; Aziz, 2017; Purnamasari e Junika, 2019). Existe a tendência a crer, portanto, que o problema se encaixa bem ao paradigma de aprendizagem de máquina.

2.5. Eficiência dos Classificadores

Para analisar a eficiência dos classificadores será efetuada a verificação de desempenho baseado no modelo de classes positivas e negativas e preenchimento de Matriz de Confusão, que é uma métrica comumente utilizada para aferir a performance de algoritmos de classificação. Esse mapeamento possui as seguintes possibilidades (Visa et al., 2011)

A Matriz de Confusão é populada de acordo como o seguinte exemplo:

Tabela 3: Representação de Matriz de Confusão.

PREDIÇÃO REALIDADE	POSITIVA	NEGATIVA
	Verdadeiro Positivo (VP)	Falso Negativo (FN)
POSITIVA	Verdadeiro Positivo (VP)	Falso Negativo (FN)
NEGATIVA	Falso Positivo (FP)	Verdadeiro Negativo (VN)

Feito isso podem ser calculadas as métricas de desempenho do classificador. A acurácia (A) define a porcentagem de acerto efetivo.

$$A = \frac{VP+VN}{VP+VN+FP+FN} \quad (1)$$

Também será calculada a Precisão (P) para as duas categorias:

$$P = \frac{VP}{VP+FP} \quad (2)$$

$$P = \frac{VN}{VN+FN} \quad (3)$$

3. METODOLOGIA

Primeiramente foi feito a aquisição de um banco de dados cuja natureza da pesquisa seja semelhante com a que é proposta neste trabalho. O banco de dados escolhido foi o que será melhor descrito no Item 3.1. Nesse experimento em questão, os participantes ficaram parte do tempo descansando de olhos fechados e na outra parte do tempo realizando subtrações aritméticas. Essa situação serviu como parâmetro em que possa ser feita a distinção entre estados de descanso e estado de atenção, respectivamente.

Posteriormente foi feito o processamento de sinais, transformando para o domínio da frequência, remoção de ruído e segmentação em bandas de frequência. Com isso, essas características foram utilizadas para realizar a distinção entre esforço cognitivo e descanso utilizando SVM e RF.

A implementação do sistema de um modo geral foi feita utilizando *Python3* que conta com uma grande quantidade de bibliotecas úteis para aplicações de processamento de sinais (como *Scipy* e *Numpy*), de algoritmos de classificação (como *Scikit Learn*), e de análise gráfica (como *Pandas*, *Seaborn* e *Matplotlib*). Além disso, a facilidade e popularidade da plataforma torna mais próxima a possibilidade de um trabalho posterior.

3.1. Banco de Dados

O banco de dados utilizado como referência para este trabalho foi o dos pesquisadores (Zyma et al., 2019), e nesse experimento foi utilizado o Neurocom EEG de 23 canais. Os eletrodos foram colocados no couro cabeludo de acordo com o padrão internacional 10/20.

O formato do banco de dados é *EDF* e para melhor manipulação será feita a conversão para o formato *CSV* por meio da biblioteca *Mne*. Para fazer a extração, segmentação e visualização dos dados dos algoritmos será utilizada a biblioteca *Pandas* e *Csv*. Para eventuais manipulações de dados também será utilizada a biblioteca *Numpy*.

3.2. Processamento de sinais

Primeiramente foi feito um fatiamento da quantidade de dados a fim de ter mais parâmetros para serem utilizados no treinamento. O tempo realizado em cada experimento é mais que o suficiente para adquirir características em frequência. O tempo escolhido foi de 30 segundos, então haverá em média 30 ciclos de ondas Theta, ou pelo menos 200 ciclos de ondas Alfa, por exemplo. Via de regra, em média 10 segundos já são suficientes para extrair características de sinal de EEG (Sanei, 2007). No trabalho de (Carrión-Ojeda, D., et al., 2019) foi constatado uma eficiência de 90% para identificação de uma pessoa por meio de sinal de EEG e DWT, tendo utilizado apenas 2 segundos.

Em relação ao tratamento do sinal, o padrão utilizado, e que também será aplicado nesse desenvolvimento, as técnicas que serão apresentadas são:

- Segmentação em cinco bandas do sinal: Theta (de 0,5 Hz a 7,5 Hz, incluindo portanto o espectro de ondas Delta nessa segmentação, e nomeando de Theta apenas por preferência), Alfa (de 7,5 Hz a 14 Hz), Beta Baixa (14 Hz a 20 Hz), Beta Alta (20 Hz a 30 Hz) e Gama (30 Hz a 60 Hz).
- Cálculo das energias dessas bandas, para que essas sejam utilizadas como características para os classificadores;

3.3. Classificação

Inspirado em teses similares como para (Balasubramanian, 2014; Purnamasari e Junika, 2019; Peng et al., 2020; Aziz, 2017; Bird et al., 2018; Edla, 2018 e Zhang et al., 2021) é buscado nesse trabalho utilizar as técnicas de aprendizagem de máquina SVM e RF.

Para implementação do algoritmo de SVM e de RF também será utilizado o pacote *svm* e *ensemble* da biblioteca *sklearn* (Pedregosa F., et al. 2011), respectivamente.

4. RESULTADOS

O esquema geral do projeto de detecção de esforço cognitivo pode ser observado na Fig. 4.

A legenda para esse esquema é: elipse para dados do banco de dados, retângulo para implementação de algoritmos e retângulo com título sublinhado para resultado final.




Figura 4. Esquema geral do projeto de identificação de esforço cognitivo.

O código para o primeiro algoritmo pode ser encontrado em: https://github.com/lucasrfsb/EEG_Attention/blob/dev/EEG_ENERGY.py e o do segundo em: https://github.com/lucasrfsb/EEG_Attention/blob/dev/Attention_EEG_SVM_RF.ipynb.

	FP1_THETA	FP1_ALFA	FP1_LOW_BETA	FP1_HIGH_BETA	FP1_GAMMA	FP2_THETA	FP2_ALFA	FP2_LOW_BETA	FP2_HIGH_BETA	FP2_GAMMA	F3_THETA	F3_ALFA	F3_LOW_BETA
0	0.003122	0.000746	0.001290	0.003108	0.000984	0.005411	0.001114	0.001699	0.003875	0.001397	0.007081	0.001243	0.002075
1	0.003605	0.000666	0.001151	0.003855	0.001076	0.006041	0.000956	0.001577	0.004728	0.001484	0.005199	0.001226	0.001922
2	0.003238	0.000703	0.001059	0.003332	0.001057	0.006116	0.001001	0.001324	0.004140	0.001483	0.004321	0.001103	0.001612
3	0.002924	0.000697	0.001280	0.003898	0.001035	0.005723	0.000899	0.001609	0.004823	0.001454	0.004187	0.001242	0.002095
4	0.002708	0.000764	0.001208	0.003596	0.001209	0.004032	0.000965	0.001529	0.004449	0.001588	0.004251	0.001402	0.001964
...	...	...	...	...	...	...	...	...	...	...	...	...	...
275	0.017603	0.001304	0.000946	0.000722	0.000534	0.026915	0.001756	0.000780	0.000780	0.001292	0.011065	0.001165	0.001000
276	0.012351	0.001250	0.000720	0.000617	0.000463	0.024394	0.001063	0.000664	0.000588	0.000297	0.004792	0.001229	0.000637
277	0.010578	0.001124	0.000813	0.000886	0.000451	0.017699	0.001011	0.000729	0.000940	0.000322	0.005207	0.001073	0.000747
278	0.008294	0.000932	0.001500	0.000572	0.001109	0.002390	0.000732	0.002013	0.000458	0.001094	0.002618	0.001049	0.001456
279	0.011787	0.001186	0.001903	0.000585	0.001153	0.004362	0.001039	0.002633	0.000625	0.001022	0.004459	0.001450	0.002224

280 rows x 101 columns

Figura 5. Demonstração de parâmetros de eletrodos em 5 bandas de frequência.

Primeiramente foi feito o treinamento com os hiperparâmetros de valor padrão, ou seja, que as bibliotecas disponibilizam como padrão. Como o afinamento de hiperparâmetros sempre irá gerar resultados melhores, não serão mostrados os resultados da eficiência dos classificadores sem o afinamento.

Posteriormente foi feita, para ambos os modelos, a Otimização de hiperparâmetros, que foram os que estão no Quadro 2. Os modelos foram treinados, separadamente, com a combinação de todas as possibilidades de hiperparâmetros, sendo que a escolha dos intervalos para cada hiperparâmetro foi feita de maneira estocástica.

Quadro 1. Hiper Parâmetros utilizados nos dois modelos.

Support Vector Machine	Random Forest
Parâmetro C: 0,1; 1; 10; 100	Bootstrap: Ativado e Desativado
	Altura máxima: 10, 20, 30, 40, 50, 60, 70, 80, 90, 100
Parâmetro γ : 1,0; 0,1; 0,01; 0,001	Máximo de parâmetros por separação: Raiz quadrada e log2
	Mínimo de amostras por folha: 1, 2, 4
Kernel: RBF; Polinomial; Sigmoid	Mínimo de amostras por separação: 2, 5, 10
	Número de estimadores: 200, 400, 600, 800, 1000, 1200, 1400, 1600, 1800, 2000

Para cada modelo foram executadas as opções descritas no Quadro 1 e com isso foram gerados os resultados descritos na Tabela 4. Os hiperparâmetros escolhidos algoritmicamente estão descritos no Quadro 2.

Tabela 4: Eficiência dos classificadores com o afinamento dos Hiper Parâmetros.

	VP	VN	FP	FN	A	P
Support Vector Machine	13	50	3	4	90%	Atento 81%
						Desatento 93%
Random Forest	16	52	1	1	97%	Atento 94%
						Desatento 98%

Quadro 2. Hiper Parâmetros selecionados nos dois modelos.

Máquina de Vetores de Suporte	C: 100 γ : 0,01 Kernel: RBF
Floresta Aleatória	Bootstrap: Ativado Altura Máxima: 50 Máximo de parâmetros por separação: Raiz quadrada Mínimo de amostras por folha: 1 Mínimo de amostras por separação: 2 Número de estimadores: 1000

Com base no valor dos parâmetros que foram selecionados na Máquina de Vetores de Suporte é possível concluir que: devido ao parâmetro C com um valor alto, o algoritmo penalizou bastante amostras que não estavam de acordo com o enquadramento. Em razão de um baixo valor de γ , o modelo não ficou muito complexo, ou seja, cada amostra não influenciou um espaço pequeno ao seu redor (área de influência do raio). Foi eleito como Kernel o RBF Gaussiano, pois ele possuiu uma melhor capacidade de generalização.

Observando os parâmetros indicados pelo modelo de Floresta Aleatória resulta-se que: o bootstrap ativado aumenta a variabilidade das amostras de entrada, o que faz sentido para o problema deste trabalho, por ter um baixo número de amostras. A altura máxima não foi até a poda máxima da árvore, parâmetro que poderia levar ao overfitting. O mínimo de amostras por folha e por separação foi um número pequeno devido ao reduzido número de amostras do problema deste trabalho e da complexidade do modelo resultante, se esse número mínimo fosse alto significaria que o algoritmo não iria precisar de muita especificidade.




Figura 6. Comparativo da Energia média em Volt².Hz de todos eletrodos do sistema 10-20 para espectro Theta.

Alguns eletrodos tiveram destaque na diferença de energia observada para o espectro de frequência Theta, conforme mostra a Fig. 6.. Esses eletrodos foram os da parte frontal (FP1, FP2, F7 e F8) e occipital, O2 principalmente. Resultados similares foram relatados por (Lim S., et al., 2019), em que foi descrito uma maior ocorrência de ondas Theta no estado de imersão para os eletrodos FP1, FP2 e O2. Também para (Rodriguez-Larios, J., et al., 2020 e Winnie, 2017) ondas Theta na parte frontal foram relacionadas com alto nível cognitivo.

Ressalta-se que houve uma discrepância maior para os eletrodos da parte frontal polar, frontal e occipital, levando a crer que para discernir entre os estados mentais de atenção e relaxamento bastariam esses eletrodos, e não todos como proposto no Sistema 10-20. Mais especificamente, como houve essa disparidade maior no espectro de ondas Theta, bastaria a análise nesse intervalo de frequência para que se possa discernir o estado mental de esforço cognitivo do estado de descanso.

5. CONCLUSÃO

Neste trabalho foi comparada a energia em frequência de sinais de EEG para os estados mentais de descanso com olhos fechados e ao realizar conta aritmética. Para isso foi feita a segmentação em cinco bandas de frequência e utilização dessas informações como parâmetros a serem utilizados nos classificadores Máquina de Vetores de Suporte e Floresta Aleatória. Como resultado foi possível obter, para o primeiro modelo, uma acurácia de 90%, precisão de 81% para o

estado de esforço cognitivo e precisão de 90% para estado de descanso. E para o segundo modelo foi possível obter uma acurácia de 97%, precisão de 94% para o estado de esforço cognitivo e precisão de 98% para o estado de descanso. Além disso, houve destaque para uma diferença significativa de energia para o grupo de eletrodos das partes frontal polar, frontal e occipital no segmento de ondas Theta. Essa importância encontrada para discernir os estados mentais conclui que é possível fazer essa identificação de esforço cognitivo em relação ao estado de descanso com apenas esse grupo reduzido de eletrodos e fazendo análise apenas do espectro Theta.

6. HIPÓTESE E TRABALHOS FUTUROS

A extração de sinal de eletroencefalografia da forma não invasiva não influenciaria a presença de um aluno em uma aula significativamente. Portanto, os dados de sinal de EEG daquela situação podem ser adquiridos e posteriormente analisados para identificar se o aluno estava realmente em um estado de esforço cognitivo adequado.

Como na base de dados pesquisada e utilizada neste trabalho é possível ter acesso ao número de operações aritméticas realizadas corretamente pelos sujeitos, hipoteticamente em um projeto futuro pode ser feita a relação entre um bom rendimento em esforço cognitivo com a atividade elétrica obtida em determinadas regiões encefálicas

Um suposto projeto como esse descrito na hipótese teria como base este trabalho. Além disso, poderia haver o desenvolvimento da análise para que fosse feita uma identificação de alguma anomalia cognitiva utilizando a abordagem de estudo no domínio frequência e técnicas de Inteligência Artificial.

7. REFERÊNCIAS

- Abdelhameed, A. M.; Bayoumi, M. Semi-supervised EEG signals classification system for epileptic seizure detection. *IEEE Signal Process Lett* 26(12):1922–1926 (2019). Acessando em: <https://doi.org/10.1109/LSP.2019.2953870>.
- Acharya U. R.; Faust, N. O.; Kannathal, T. C. and S. Laxminarayan, Nonlinear analysis of EEG signals at different sleep stages, *Computer Methods and Programs in Biomedicine* 80(1) (2005).
- Acharya, U. R., Sree, S.; Chattopadhyay, S.; Suri J. *Automated Diagnosis of Normal and Alcoholic EEG signals* (2012).
- Acharya U. R.; Sree, S.; Suri, J. S. Automatic detection of epileptic EEG signals using higher order cumulant features, *International Journal of Neural Systems* 21(4) (2011).
- Adeli H.; Ghosh-Dastidar, S.; Dadmehr, N. A Spatio-temporal wavelet-chaos methodology for EEG-based diagnosis of Alzheimer's disease, *Neuroscience Letters* 444(1) (2008).
- Ahmadlou and. M.; Adeli, H. Fuzzy synchronization likelihood with application to attention-deficit/ hyperactivity disorder, *Clinical EEG and Neuroscience* (2011).
- Ahmadlou and. M.; Adeli, H. Wavelet-synchronization methodology: A new approach for EEG-based diagnosis of ADHD, *Clinical EEG and Neuroscience* (2010).
- Aziz F. A. A., Setiawan N. A., Shapiai M. I., Yasue M. *Classification of Human Concentration in EEG Signals using Hilbert Huang Transform*. Eletronc System Engineering, MJIIT, Center of Artificial Intelligence and Robotics (CAIRO), (2017).
- Bird J. J.; Manso L. J.; Ribeiro E. P.; Ekart A. *A Study on Mental Classification using EEG-based Brain-Machine Interface*. International Conference on Intelligent System, (2018).
- Carrión-Ojeda, D.; H. Mejía-Vallejo, R.; Fonseca-Delgado, P.; Gómez-Gil and M. Ramírez-Cortés. "A method for studying how much time of EEG recording is needed to have a good user identification," *2019 IEEE Latin American Conference on Computational Intelligence (LA-CCI)*, pp. 1-6, doi: 10.1109/LA-CCI47412.2019.9037054 (2019).
- Edla, D. R.; Mangalorekar, K.; Dhavalikar G.; Dodia, S. *Classification of EEG data for human mental state analysis using Random Forest Classifier*. International Conference on Computational Intelligence and Data Science, (2018).
- Fayyad, J.; Sampson, N.A.; Hwang I, et al. *The descriptive epidemiology of DSM-IV Adult ADHD in the World Health Organization World Mental Health Surveys. Atten Defic Hyperact Disord*, (2017).
- Fraiwan, L.; Lweesy, K.; Khasawneh, N.; Wenz, H.; & Dickhaus, H. *Automated sleep stage identification system based on time-frequency analysis of a single EEG channel and random forest classifier. Computer Methods and Programs in Biomedicine*, 108(1), 10–19. doi:10.1016/j.cmpb.2011.11.005, (2012).
- Huang, G.-B., Zhu, Q.-Y.; and C.-K. Siew, "Extreme learning machine: Theory and applications," *Neurocomputing*, vol. 70, no. 1, pp. 489–501, (2006).
- Katahira, K., Yamazaki, Y., Yamaoka, C., Ozaki, H., Nakagawa, S., Nagata, N. *EEG Correlates of the Flow State: A Combination of Increased Frontal Theta and Moderate Frontocentral Alpha Rhythm in the Mental Arithmetic Task*, (2018).
- Lim S, Yeo M, Yoon G. *Comparison between Concentration and Immersion Based on EEG Analysis*. *Sensors* (Basel). Apr 8;19(7):1669. doi: 10.3390/s19071669. PMID: 30965606; PMCID: PMC6479797, (2019).
- Loo, S. K., & Barkley, R. A. *Clinical Utility of EEG in Attention Deficit Hyperactivity Disorder*. *Applied Neuropsychology*, 12(2), 64–76. doi:10.1207/s15324826an1202_2, (2005).

- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, D., Brucher, M., Perrot, M., & Duchesnay, E. Scikit-learn: *Machine Learning in Python*. *Journal of Machine Learning Research*, 12, 2825–2830, (2011).
- Peng C., Chen Y., Chen C., Chen S., Cagneau B., Chassagne L. *An EEG- Based Attentiveness Recognition System Using Hilbert-Huang Transform and Support Vector Machine*. *Journal of Medical and Biological Engineering*, (2020).
- Pinheiro, V. C. *Desenvolvimento e Avaliação de um Sistema de Análise de Equilíbrio Postural Humano com Base em Sinais de Inclínômetros e Máquinas de Suporte Vetorial*. Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia Biomédica, Universidade de Brasília, Campus Gama (2014).
- Purnamasari, P. D.; Junika, T. W. *Frequency-based EEG Human Concentration Detection System Methods with SVM Classification*. *IEEE CYBERNETICSCOM*, (2019).
- Rodriguez-Larios, J., Faber, P., Achermann, P. et al. *From thoughtless awareness to effortful cognition: alpha - theta cross-frequency dynamics in experienced meditators during meditation, rest and arithmetic*. *Sci Rep* 10, 5419. Acessado em: <https://doi.org/10.1038/s41598-020-62392-2> (2020).
- Tan, P.; W. Sa and L. Yu, "Applying Extreme Learning Machine to classification of EEG BCI," *2016 IEEE International Conference on Cyber Technology in Automation, Control, and Intelligent Systems (CYBER)*, pp. 228-232, doi: 10.1109/CYBER.2016.7574827 (2016).
- Vetterli M.; Kovacevic J.; Goyal V. K. *Foundations of Signal Processing* (2014).
- Visa S., Ramsay B., Ralescu A., Knaap E. V. D. *Confusion Matrix-based Feature Selection*. *MAICS*, (2011).
- Winnie, K. Y. So.; Savio, W. H. Wong.; Joseph, N. Mak.; Rosa, H. M. Chan. *An evaluation of mental workload with frontal EEG*. *PLOS ONE* 12(4): e0174949. Acessado em: <https://doi.org/10.1371/journal.pone.0174949> (2017).
- Zhang YN.; Dong R.; Wu Y.; Cheng X.; Cheng C.; Xu L. *Research on Classroom Attention Analysis Based on Multi-source Data Correlation*. In: Wang Y., Xu L., Yan Y., Zou J. (eds) *Signal and Information Processing, Networking and Computers*. *Lecture Notes in Electrical Engineering*, vol 677. Springer, Singapore. https://doi.org/10.1007/978-981-33-4102-9_108 (2021).
- Zyma, I., Tukaev S., Seleznev I., Kiyono K., Popov A., Chernykh M., Shepenkov O. *Eletroencefalograms during mental arithmetic task performance*, (2019). Acessado em: <https://doi.org/10.3390/data4010014>.

8. RESPONSABILIDADE AUTORAL

Os autores são os únicos responsáveis pelo conteúdo deste trabalho.

IDENTIFICATION OF COGNITIVE EFFORT THROUGH EEG SIGNAL PROCESSING USING SVM AND RF

Lucas Rocha Figueredo Santana e Barros, lucas.oct8@gmail.com
Gerardo Antonio Idrobo Pizo, gerardo.idrobo@gmail.com

Universidade de Brasília, Faculdade do Gama, Área Especial, Projeção A, UnB – Setor Leste – Gama, CEP 72444-240

Abstract. Attention is highly desirable in uncountable situations and even vital in others. On daily basis it is essential that the subject is fully aware so that he has the best possible performance in the activity he is doing. To do so, this work goal is to make a cognitive effort detection using eletroencephalographic signal processing and making use of two machine learning algorithms: Support Vector Machine (SVM) and Random Forest (RF). This paper base will be a EEG signals dataset, in which candidates passed a fraction of the acquisition time in rest with their eyes closed, and a fraction making mental arithmetic. To accomplish the detection, energy extraction, and segmentation in the frequency domain of the acquired signals were performed to be used as input parameters in the cited machine learning algorithms. In this work, one goal was to compare accuracy and precision of these two techniques, and it performed with an accuracy of 90% and 97% for SVM and RF classifiers, respectively; and a precision for the cognitive effort category of 81% and 94% for these two classifiers, respectively. The other goal of this study is to find out if there are encephalic regions with more activation during the cognitive effort if compared to the rest state, and it was found a bigger energy, for the Theta waves spectrum, acquired in the frontal polar, frontal and occipital region electrodes if compared to the acquired in other electrodes.

Keywords: Signal Processing, EEG, Cognitive Effort, SVM, RF