

Uma Abordagem para Classificação de Fadiga Mental baseada em Sinais de Eletroencefalografia (EEG)

Mylene N.M.R.Ferreira^{1,2}, Ana C.Q. Siravenha²,
Schubert R. Carvalho³, Bruno D. Gomes¹,
Ronaldo F. Zampolo¹, Agostinho S. Castro¹, Adriana R.G. Castro¹,

¹ Universidade Federal do Pará, Brasil

rmylena@ufpa.br, zampolo@ieee.org, agcastro@ufpa.br, adcastro@ufpa.br, bruno@ufpa.br

² Instituto Senai de Inovação, Brasil

mylena.isi@sesipa.org.br, anacarolina.isi@sesipa.org.br

³ Instituto Tecnológico Vale, Brasil

schubert.carvalho@itv.org

Abstract.

A complexidade da análise da fadiga mental em pessoas saudáveis é evidenciada pela ausência de perturbações abruptas no sinal de eletroencefalografia e pela singularidade e variabilidade do perfil cognitivo de cada indivíduo. Identificar esse tipo de estado mental requer a análise de fatores que o caracterize, como o comportamento das bandas de frequência e das regiões cerebrais. Este trabalho propõe classificar a fadiga mental a partir da análise de bandas de frequência e razões dessas bandas em dois modelos de aprendizado de máquina: Rede Neural Perceptron de Múltiplas camadas e Redes Neurais auto-associativas encadeadas. Três frequências e quatro razões foram calculadas a partir dos dados eletroencefalográficos em termos de densidade de energia espectral: α , β , θ , e as razões θ/α , $(\alpha+\theta)/\beta$, β/α e $(\alpha+\theta)/(\alpha+\beta)$. Propõe-se também uma estratégia para seleção de canais baseada na significância estatística de Wilcoxon entre as amostras do dado normal e fadigado. Além disso, emprega-se a normalização do vetor de características de forma a reduzir a variabilidade dos dados e melhorar a caracterização dos estados. Os testes mostram que o uso da normalização aumenta efetivamente a acurácia da classificação, independente do modelo utilizado. A seleção de canais reduziu a quantidade de sensores de 30 para 11 e impactou levemente a acurácia dos modelos. A acurácia máxima de 99,97% foi atingida quando usados dados normalizados com seleção de canais, treinados com Redes Neurais auto-associativas.

Categories and Subject Descriptors: I.2.6 [Artificial Intelligence]: Learning; I.5.0 [Pattern Recognition]: General

Keywords: Eletroencefalografia, Redes neurais artificiais, Fadiga, Seleção de características

1. INTRODUÇÃO

Acredita-se que a fadiga mental seja o resultado de uma alta demanda ou esforço mental prolongado durante a execução de uma tarefa. Esse processo é caracterizado pelo declínio da performance cognitiva, e que é, entre outros fatores, grande responsável por acidentes de trânsito [Dimitrakopoulos et al. 2018; Min et al. 2017; Wascher et al. 2014].

A fadiga mental reflete perturbações nos ritmos cerebrais, e portanto resulta em mudanças de comportamento dos sinais de eletroencefalografia (EEG) ao longo das bandas de frequência e regiões corticais. Estas alterações são em sua maioria, percebidas nas regiões frontal e parietal, que apresentam variações mais sensíveis ao longo do experimento, e suas medidas de potência relativa em alfa aumentam consideravelmente [Schier 2000]. Desta forma, empregar a análise espectral de potência neste estudo se justifica pela explicitação destas mudanças significativas, na magnitude cerebral em

Copyright©2018 Permission to copy without fee all or part of the material printed in KDMiLe is granted provided that the copies are not made or distributed for commercial advantage, and that notice is given that copying is by permission of the Sociedade Brasileira de Computação.

relação ao aumento da fadiga mental.

Os esforços para detectar os padrões neurais que caracterizem esse processo de declínio cognitivo a partir de sinais de EEG, em geral, são tomados em experimentos controlados, estabelecendo paradigmas para indução de fadiga em tarefas cognitivas que requerem o estado de vigília com atenção sustentada [Dimitrakopoulos et al. 2018], no domínio da atenção visual [Li et al. 2016] e uso intenso da memória de trabalho [Helton and Russell 2011].

Em [Min et al. 2017] são apresentados resultados sobre as regiões cerebrais diretamente ativas durante o estabelecimento da fadiga usando medidas de entropia nos registros de EEG. Dados de 12 sujeitos foram coletados em ambiente de simulação de direção durante períodos entre 1 e 2 horas contínuas. Dos 30 canais registrados, e a partir do peso dos canais mais importantes, os testes indicaram que grupos com poucos sensores são suficientes para identificar estados mentais relacionados a fadiga.

[Liu et al. 2016] propõem um sistema de predição de graus de fadiga baseado em rede neural recorrente fuzzy em ambiente de realidade virtual para simulação de direção. Esse tipo de rede é utilizada para contornar a deficiência do método de análise de componentes independentes (ICA) em aplicações em tempo real. Essa estratégia aumenta a capacidade de cancelamento do ruído que tipicamente afeta sinais de EEG e se mostrou efetiva frente à outras abordagens em tempo real.

Este trabalho apresenta a proposta de representação de dados EEG para detecção de fadiga baseada na análise espectral do sinal. Uma abordagem de seleção de canais fundamentada na análise de significância também é apresentada com o intuito de evidenciar os eletrodos que contribuem de forma efetiva para a caracterização das classes de interesse, e para a acurácia das redes. A variabilidade do sinal é controlada pela normalização do tipo min-max. Dois métodos de classificação baseados em redes neurais serão testados sob diversas configurações, com o objetivo de validar a escolha da representação dos dados baseada na análise espectral.

2. MATERIAIS E MÉTODOS

2.1 Base de Dados

Os dados utilizados para desenvolvimentos dos sistemas de classificação propostos no presente estudo foram disponibilizados em domínio público por [Min et al. 2017]. Correspondem a medidas de EEG de 12 indivíduos saudáveis do sexo masculino, cujas idades variaram de 19 a 24 anos. Cada sujeito foi submetido à uma simulação de condução de veículos em estrada. Nenhum fármaco ou estimulantes como álcool ou café foram utilizados durante o processo de coleta de dados e não houve supressão de sono.

Os indivíduos foram submetidos ao experimento por até duas horas. Dos 20 primeiros minutos, os cinco últimos minutos foram nomeados como sinais EEG no estado normal. A partir de 40 minutos, o sujeito permanecia na simulação até sua própria manifestação de estado fadigado ou até 100 minutos. Destes, os cinco últimos minutos foram marcados como estado fadigado. Ao final do experimento, o indivíduo preencheu questionários de fadiga, baseados na escala de fadiga Chalder e Lis [Chalder et al. 1993].

Os dados foram coletados com taxa de amostragem de 1000 Hz para 32 eletrodos, sendo 30 eletrodos efetivos e dois de referência. A base foi referenciada pela média dos eletrodos de referência, denominados mastoides (A1 e A2), e a organização espacial dos eletrodos foi baseada no sistema 10-20.

Pré-processamento Os sinais EEG brutos dos dois estados foram então, pré-processados utilizando filtros passa banda de (4 - 100Hz), e rejeita faixa do tipo Notch em 60 Hz para selecionar as bandas de frequência de interesse e atenuar ruídos elétricos, respectivamente. Artefatos visuais e movimentação lateral ocular foram retiradas por inspeção visual analisando valores z do sinal para cada trial de 1

segundo. Análise de Componentes Independentes (ICA) foi usada para filtrar os sinais EEG de outros ruídos de origem fisiológica.

Após esse procedimento restou, em média, 4 minutos e 36 segundos de coleta, que foi considerado para cada um dos sujeitos. Assim, os dados EEG foram organizados em segmentos/*trials* de 1 segundo, resultando em uma matriz multidimensional de 280 *trials*, por 30 canais, por 30 frequências. Estas matrizes serão utilizadas para o cálculo de energia do sinal EEG e posterior criação do vetor de características.

2.2 Análise Espectral

Esta análise foi fundamentada no cálculo da densidade de energia espectral (PSD), que pode informar acerca de variações na magnitude da resposta cortical em frequências específicas relacionadas à carga mental que está por sua vez relacionada à fadiga mental. A partir do PSD, foi constatado que os eletrodos Fz em teta e Pz em alfa, portanto, as regiões frontais e parietais nestas mesmas bandas de frequência, podem ser consideradas biomarcadores de carga mental, visto que suas magnitudes eram afetadas positivamente pelo aumento de carga mental de trabalho [Cajochen et al. 1995],

O PSD $\Phi(\omega)$ foi calculado a partir do quadrado da magnitude da transformada de Fourier, dada pela equação 1, com a restrição de $f(t)$ ser uma função integrável de energia finita.

$$\Phi(\omega) = \left| \frac{1}{\sqrt{2\pi}} \sum_{n=-\infty}^{\infty} f_n e^{-i\omega n} \right|^2 = \frac{F(\omega)F^*(\omega)}{2\pi} \quad (1)$$

onde ω é a frequência angular, $F(\omega)$ é a transformada de Fourier de tempo discreto $f(n)$, e $F^*(\omega)$ é seu conjugado complexo.

Assim, para cada valor de frequência angular, um valor de PSD é calculado. Ressalta-se que para o cálculo dos coeficientes de Fourier, o método de janelamento multitaper sem superposição foi empregado na tentativa de manter uma boa resolução do sinal na frequência, e contornar os efeitos do princípio de incerteza de Heisenberg, que trata da relação descompassada da resolução de um mesmo sinal no tempo e na frequência.

2.3 Medidas de Fadiga Mental baseadas em EEG

Métodos tradicionais de estimativa de nível de fadiga como Chalder, Lis, Wong-Baker e NASA-TLX por exemplo, são baseados em questionários preenchidos pelo próprio indivíduo, seja, por avaliação verbal ou escrita de terceiros. Estas avaliações são susceptíveis à erros, visto que o indivíduo pode ou não fornecer dados precisos sobre si, assim como ter ou não conhecimento preciso acerca de seu estado fadiga [Scott G. Paris 2001].

Por outro lado, a fadiga mental pode ser identificada pelo comportamento espectral do sinal neural do indivíduo, indicando padrões peculiares para cada estágio de fadiga, e até criando perfis cognitivos para cada indivíduo ou grupo de indivíduos. Assim, a partir do sinal EEG, a fadiga mental pode ser analisada por espectros de potência em diversas bandas de frequência, chamados índices α , β e θ , e pela relação entre estes índices, denominadas métricas, que podem ser particulares de determinadas regiões, ou calculadas para todos os eletrodos.

Os índices, que correspondem a parâmetros diretamente relacionados aos ritmos cerebrais, denotam característica do sinal cortical, apresentando padrões de variação específicos para bandas de frequência de análise [Cheron et al. 2016]. Assim, a banda θ (4-8Hz) exibe sinais com comportamento relacionado à memória, controle sensorimotor e orientação, a banda β (12-30HZ) relacionado à padrões de sinais associados à atenção, acuidade visual e fadiga e a banda α (8-12 HZ) relacionada à criatividade,

atenção seletiva e relaxamento. A combinação desses índices para construção de métricas possibilita determinar mensurações relacionadas à eventos singulares como a fadiga mental [Jap et al. 2009; Eoh et al. 2005].

Quatro razões foram usadas como métrica no presente estudo: $(\alpha + \theta)/\beta$ [Brookhuis and De Waard 1993], β/α [Eoh et al. 2005] e θ/α [Pyun and Kim 2000], e também $(\alpha + \theta)/(\alpha + \beta)$ [Jap et al. 2009], nomeadas como r1, r2, r3 e r4, respectivamente.

2.4 Normalização dos dados

A normalização do tipo min-max foi aplicada aos atributos para reduzir variabilidade dos dados durante a análise. A equação abaixo normaliza os dados coluna por coluna, classe a classe, entre 0 e 1 [Siravenha and Carvalho 2016]. Tomando t_i como cada coluna da matriz de dados de cada classe F_c , temos:

$$t'_i = \frac{t_i - \min_{F_c}}{\max_{F_c} - \min_{F_c}} (new_{\max_{F_c}} - new_{\min_{F_c}}) + new_{\min_{F_c}}, \quad (2)$$

onde $new_{\min_{F_c}} = 0$ e $new_{\max_{F_c}} = 1$.

2.5 Seleção de Canais

As regiões frontal e parietal parecem apresentar clara variação da energia espectral que pode indicar estados de fadiga [Wascher et al. 2014; Cajochen et al. 1995; Eoh et al. 2005]. Portanto, canais localizados nestas regiões supostamente contribuiriam para a detecção de sinais significativos. Apesar disso, no presente estudo inicialmente todos os canais foram considerados. Uma análise de significância estatística baseada no método não paramétrico de Wilcoxon foi usado para selecionar canais que diferiram entre os estados normal e fadigado.

O valor de p para cada amostra comparada é calculado a partir dos coeficientes do teste de Wilcoxon (W), z-valor e da probabilidade de ocorrência da rejeição da hipótese nula, dadas pelas equações 3 e 4.

$$z = \frac{W - \mu_w}{\sigma_w}, \text{ onde } W = \sum_{i=1}^{n1} [sgn(x_{2,i} - x_{1,i})] \cdot R_i. \quad (3)$$

$$p = 1 - 2 * P(o), \quad (4)$$

onde z é dado pela razão da diferença entre o W de cada par de amostra e a média (μ) e desvio padrão (σ) de W para todos os pares. O valor de W é obtido pelo somatório da diferença do par de cada posição do *ranking* R_i . Em seguida, a probabilidade de ocorrência da hipótese nula ($P(o)$) ser rejeitada é calculada para, por fim, obter o valor de p pela Equação 4. Valores de p maiores que 0,05 são ditos como não significativos, e portanto as amostras analisadas que apresentem valores maiores que este nível de significância são desconsideradas.

O processo de seleção de canais baseado no teste de Wilcoxon foi implementado amostra a amostra, canal a canal, para os dados normalizados e não normalizados. Ao final, a ocorrência de significância foi convertida em percentual para seleção de canais com ocorrência maior ou igual a 50%. Assim, para um canal ser selecionado, deve apresentar valores significativamente diferentes entre os estados, em pelo menos seis sujeitos.

2.6 Vetor de Características

Os valores das razões descritas na Seção 2.3 e os valores de PSD de cada canal em cada uma das bandas empregadas nessas razões (Seção 2.2) formam os vetores $F_r = [r_1, r_2, r_3, r_4] \in \mathbb{R}^4$ e $F_{psd} =$

$[C_\alpha, C_\beta, C_\theta] \in \mathbb{R}^{3\zeta}$, respectivamente, onde $\lambda = 4$ e $\zeta = 30$.

$C_\alpha \in \mathbb{R}^\zeta$, $C_\beta \in \mathbb{R}^\zeta$ e $C_\theta \in \mathbb{R}^\zeta$ representam os valores de PSD em cada um dos 30 canais disponíveis na base de dados.

Assim, a matriz de dados empregada pode ser descrita como:

$$\begin{aligned} F_{rpsd} &= [F_r, F_{psd}] \in \mathbb{R}^{\eta=\lambda+3\zeta} \\ &= [r_1, r_2, r_3, r_4, C_\alpha, C_\beta, C_\theta] \\ &= [r_1, r_2, r_3, r_4, C_\alpha^1, C_\alpha^2, \dots, C_\alpha^\zeta, C_\beta^1, C_\beta^2, \dots, C_\beta^\zeta, C_\theta^1, C_\theta^2, \dots, C_\theta^\zeta] \end{aligned} \quad (5)$$

Sem seleção de canais, $\eta = 94$, e após a seleção de canais $\zeta = 11$ e $\eta = 37$.

Desta forma, o vetor de características é criado a partir das matrizes multidimensionais obtidas após o pré-processamento, organizadas em 280 segmentos de um segundo por 30 canais, por 30 frequências para cada classe e para cada sujeito. Após o cálculo de energia e das razões de fadiga, os resultados são concatenados segundo a classe específica para todos os indivíduos, resultando no vetor de 6720 amostras por 94 atributos, organizados em 3360 amostras para cada classe.

2.7 Aprendizado e classificação

Após a extração dos vetores de características contendo as informações sobre estados normal e fadigado, os dados serviram de entrada para dois tipos de arquitetura de redes neurais: do tipo Perceptron de múltiplas camadas (PMC) e redes neurais auto-associativas encadeadas (AE).

A rede neural Perceptron de múltiplas camadas é o tipo mais simples de rede neural, na qual a informação avança, das entradas para os nós de saída por camadas ocultas. Nesta arquitetura, em cada camada (exceto a camada de saída) é implementado um nó adicional, a unidade de polarização (*bias*), que restringe como os valores ponderados determinados pelo fluxo iterativo de dados de treinamento, relaciona os dados de entrada e saída. Os resultados obtidos pela rede na camada de saída se dá pela soma ponderada das saídas da camada oculta.

Redes auto-associativas por sua vez são redes especializadas em reconstruir os dados de entrada com o objetivo de aprender representações, ou extrair atributos para redução de dimensionalidade [Bourlard and Kamp 1988; Hinton and Zemel 1994]. Se encadeadas, estas redes podem refinar os atributos selecionados ao longo da reconstrução do dado e portanto podem ser utilizadas anteriormente a uma rede classificadora. Tanto as auto-associativas como a rede classificadora são treinadas com os dados de entrada antes de serem encadeadas, e portanto apresentam valores de pesos inicializados pelo dado quando são encadeadas e treinadas novamente.

O paradigma de aprendizado foi o supervisionado e os dados de entrada para o treinamento e teste foram arranjados de quatro maneiras: não normalizados, com e sem seleção de canal e normalizados, com e sem seleção de canais. Desta forma, os efeitos da seleção de canal e normalização puderam ser discriminados no desempenho de cada uma das redes.

As quatro entradas foram submetidas à diferentes configurações de redes. Na PMC, os neurônios da única camada oculta variaram de 10, 20, 26, 50 e 100 neurônios, e na AE foram testadas uma rede de duas camadas ocultas com 100 e 50 neurônios, e outra com 300 e 150 neurônios. A avaliação em várias topologias de rede tem como objetivo verificar a adaptabilidade das arquiteturas para um dado não estacionário e sem eventos, ou seja, sem perturbações abruptas.

3. RESULTADOS E DISCUSSÕES

Para identificar os dois estados mentais normal e fadigado de 12 sujeitos, a partir de características extraídas da PSD, as duas abordagens de classificação testadas, PMC e AE, foram submetidas à variação

de quantidade de neurônios e os dados de entrada organizados em normalizados e não normalizados, com e sem seleção de canais.

A avaliação da eficiência da representação dos dados proposta neste trabalho, resumida na Equação 5, foi feita em diversas sessões de treinamento e teste a partir dos dados divididos na proporção 70-30, ou seja, 70% dos dados separados para treino e 30% para teste usando validação cruzada [Kohavi 1995].

Vetores	PMC					AE	
	10	20	26	50	100	[300 150]	[100 50]
Não normalizado	88,46	87,40	88,70	83,53	89,98	78,70	79,54
Normalizado	99,92	99,88	99,88	99,93	99,90	99,81	99,68

Table I. Avaliação da representação dos dados baseada em medidas de PSD sem seleção de canal, normalizados e não normalizados. Os valores de acurácia representam a média de diversas sessões de treinamento e teste.

A Tabela I apresenta a avaliação da capacidade de representação dos dados pelo vetor de características proposto. Foram testadas cinco valores de número de neurônios escondidos na rede Perceptron e duas arquiteturas AE. Os vetores sem normalização e com a normalização apresentada na Seção 2.4 são apresentados para comparação.

Foi observado que o desempenho dos vetores são similares em todas as arquiteturas e número de neurônios, ao redor dos 85% de acurácia média.

O processo de seleção de canais baseado no teste de significância estatística de Wilcoxon, foi implementado considerando a média das ocorrências de índices e métricas (vetor F_{rpsd} , de apenas índices (vetor F_{psd}), de apenas métricas (vetor F_r), e de cada um dos índices e métricas. Pela condição de seleção de canais com ocorrência igual ou acima de 50%, dos 30 eletrodos, 11 foram selecionados: F8, FT7, FCz, FC4, T4, TP7, FC3, T3, C4, Pz e P4.

A Figura 1 resume a estratégia usada para a redução do número de canais. O percentual de ocorrência de diferença significativa entre os valores dos conjuntos de dados normal e fadigado em termos de PSD e razões. Nota-se que com o vetor F_r (barras amarelas) os 11 canais selecionados apresentam diferença significativa em, pelo menos, metade dos sujeitos.

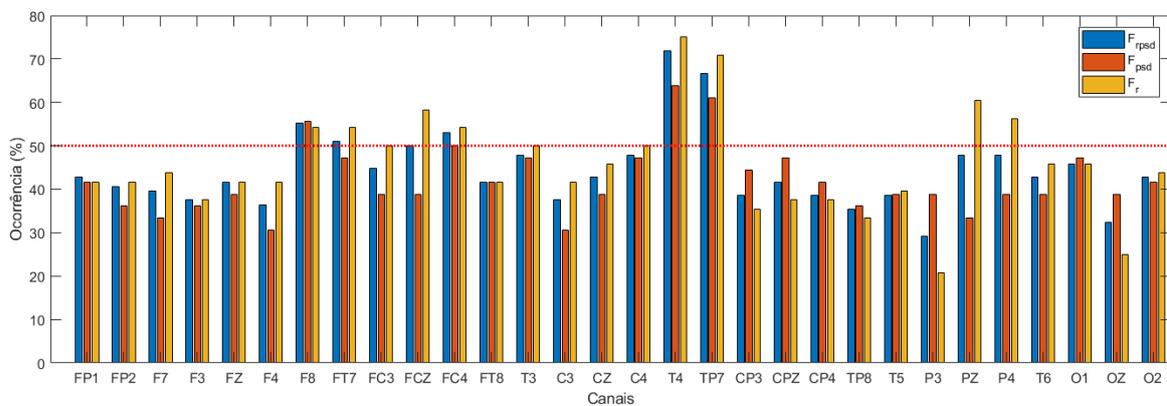


Fig. 1. Gráfico de barras do percentual de ocorrência de valores significativos entre as duas classes normal e fadigada, amostra a amostra, considerando todas as métricas e índices, destaca-se os canais F8, FT7, FCz, FC4, T4 e TP7.

Após a aplicação da seleção de canais a redução do vetor de características (F_{rpsd}^η) foi de $\eta = 94$ para $\eta = 37$ (Tabela II). Houve uma leve redução da acurácia média dos modelos de classificação, embora tenha havido melhora na acurácia quando utilizada a AE com [100 50] neurônios.

Vetores	PMC					AE	
	10	20	26	50	100	[300 150]	[100 50]
Não normalizado	68,88	68,15	70,37	70,08	70,43	72,33	63,55
Normalizado	99,65	99,73	99,83	99,79	99,87	99,41	99,97

Table II. Representação dos dados baseada em PSD com seleção de canal, normalizados e não normalizados. Os valores de acurácia representam a média dos testes de diversas sessões de treinamento e teste.

Na abordagem original de [Min et al. 2017], a acurácia máxima, obtida com uma rede neural, foi de 98,30%. Mesmo sem seleção de canais, no presente estudo, todos os testes com dados normalizados excederam o patamar dos 99% de acurácia em todas as sessões de treinamento.

Sobre a eficiência do vetor de característica: As acurácias apresentadas na Tabela I mostram que a representação dos dados foi eficiente para identificar os estados mentais desejados. A normalização dos dados promoveu um aumento da acurácia que foi superior aquela obtida no estudo que gerou os dados ([Min et al. 2017]).

Sobre o desempenho da seleção de canais: Em aplicações reais o uso prolongado dos dispositivos para captura de dados de EEG pode contribuir para o aumento das sensações de cansaço e desconforto. Assim, a implementação de uma metodologia que contemple o menor número de canais, mantendo níveis de precisão aceitáveis para o sistema, torna-se altamente desejável.

A Tabela II mostra que a redução de canais, manteve as taxas de acerto bastante próximas àquelas sem seleção, em particular, quando usado o vetor normalizado. Ainda, a maior taxa de acurácia foi obtida usando a arquitetura AE com duas camadas contendo 100 e 50 neurônios, nesse caso.

Os canais selecionados a partir do método de Wilcoxon (Figura 1) estão em grande consonância com a literatura que aborda identificação de fadiga em humanos saudáveis: cinco canais vindos da região frontal, três canais temporais, dois canais parietais e um central. De fato, trabalhos como [Min et al. 2017; Eoh et al. 2005; Jap et al. 2009] destacam a importância dessas regiões no processo de fadiga mental durante a realização de tarefas em ambientes reais e laboratoriais, principalmente por se tratar de regiões ligadas à atenção e memória de trabalho.

Sobre o desempenho das arquiteturas de classificação: Notou-se que as duas abordagens empregadas foram suficientes para a classificação dos estados, apresentando comportamento similar ao longo dos testes. A PMC com 100 neurônios conseguiu alcançar resultados excelentes, porém sob um custo computacional muito alto, principalmente quando usados dados não normalizados e sem seleção de canais. Em contraste com as outras abordagens que tomavam, ao máximo, 15 minutos de treinamento, a aprendizagem dessa rede durava aproximadamente 7 vezes mais.

Finalmente, observa-se que para esse conjunto de dados sob a representação proposta, a utilização de poucos neurônios é suficiente para obter resultados excelentes em um curto espaço de tempo.

Oportunamente, os dados foram testados em Matlab, em máquinas dotadas de processador Core™ i7 2.9GHz, memória RAM de 32GB e placa gráfica GeForce GTX 1070.

4. CONCLUSÕES E TRABALHOS FUTUROS

Neste trabalho foi apresentada a representação de dados de EEG em termos de densidade de energia espectral para classificação de fadiga em sujeitos saudáveis. Mostrou-se que a concatenação de

informações sobre as bandas α , β e θ e quatro medidas de fadiga foram suficientes para diferenciar o estado mental de fadiga do estado dito normal com alta acurácia e precisão. A acurácia máxima entre os testes ocorreu quando foram associadas as estratégias de seleção de canal e normalização coluna à coluna na rede auto-associativa. As redes PMC apresentaram desempenho superior à 99%, corroborando a qualidade da representação dos dados proposta.

Pesquisas futuras devem focar nos aprimoramentos necessários para a utilização dessa metodologia em sistemas *on-line*, além de expandir a análise para dados coletados em experimentos diversos aos utilizados neste trabalho.

REFERENCES

- BOURLARD, H. AND KAMP, Y. Auto-association by multilayer perceptrons and singular value decomposition. *Biological cybernetics* 59 (4-5): 291–294, 1988.
- BROOKHUIS, K. A. AND DE WAARD, D. The use of psychophysiology to assess driver status. *Ergonomics* 36 (9): 1099–1110, 1993.
- CAJOCHEN, C., BRUNNER, D. P., KRAUCHI, K., GRAW, P., AND WIRZ-JUSTICE, A. Power density in theta/alpha frequencies of the waking eeg progressively increases during sustained wakefulness. *Sleep* 18 (10): 890–894, 1995.
- CHALDER, T., BERELOWITZ, G., PAWLIKOWSKA, T., WATTS, L., WESSELY, S., WRIGHT, D., AND WALLACE, E. Development of a fatigue scale. *Journal of psychosomatic research* 37 (2): 147–153, 1993.
- CHERON, G., PETIT, G., CHERON, J., LEROY, A., CEBOLLA, A., CEVALLOS, C., PETIEAU, M., HOELLINGER, T., ZARKA, D., CLARINVAL, A.-M., ET AL. Brain oscillations in sport: toward eeg biomarkers of performance. *Frontiers in psychology* vol. 7, pp. 246, 2016.
- DIMITRAKOPOULOS, G. N., KAKKOS, I., DAI, Z., WANG, H., SGARBAS, K., THAKOR, N., BEZERIANOS, A., AND SUN, Y. Functional connectivity analysis of mental fatigue reveals different network topological alterations between driving and vigilance tasks. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 4320 (c): 1–10, 2018.
- EOH, H. J., CHUNG, M. K., AND KIM, S.-H. Electroencephalographic study of drowsiness in simulated driving with sleep deprivation. *International Journal of Industrial Ergonomics* 35 (4): 307–320, 2005.
- HELTON, W. S. AND RUSSELL, P. N. Working memory load and the vigilance decrement. *Experimental Brain Research* 212 (3): 429–437, 2011.
- HINTON, G. E. AND ZEMEL, R. S. Autoencoders, minimum description length and helmholtz free energy. In *Advances in neural information processing systems*. pp. 3–10, 1994.
- JAP, B. T., LAL, S., FISCHER, P., AND BEKIARIS, E. Using eeg spectral components to assess algorithms for detecting fatigue. *Expert Systems with Applications* 36 (2): 2352–2359, 2009.
- KOHAVI, R. A study of cross-validation and bootstrap for accuracy estimation and model selection. In *Proceedings of the 14th International Joint Conference on Artificial Intelligence - Volume 2. IJCAI'95*. Morgan Kaufmann Publishers Inc., San Francisco, CA, USA, pp. 1137–1143, 1995.
- LI, J., LIM, J., CHEN, Y., WONG, K., THAKOR, N., BEZERIANOS, A., AND SUN, Y. Mid-Task Break Improves Global Integration of Functional Connectivity in Lower Alpha Band. *Frontiers in Human Neuroscience* 10 (June): 1–12, 2016.
- LIU, Y. T., WU, S. L., CHOU, K. P., LIN, Y. Y., LU, J., ZHANG, G., LIN, W. C., AND LIN, C. T. Driving fatigue prediction with pre-event electroencephalography (EEG) via a recurrent fuzzy neural network. *2016 IEEE International Conference on Fuzzy Systems, FUZZ-IEEE 2016*, 2016.
- MIN, J., WANG, P., AND HU, J. Driver fatigue detection through multiple entropy fusion analysis in an EEG-based system. *PLOS ONE* 12 (12): e0188756, dec, 2017.
- PYUN, H. AND KIM, J. A study on the effect of emotion-evoking advertisement with eeg analysis. In *Proceedings of 2000 Joint Conference of KIIE and KORMS, KIIE and KORMS, Seoul*. Vol. 413416, 2000.
- SCHIER, M. A. Changes in eeg alpha power during simulated driving: a demonstration. *International Journal of Psychophysiology* 37 (2): 155–162, 2000.
- SCOTT G. PARIS, A. H. P. Classroom applications of research on self-regulated learning. *Educational Psychologist* 36 (2): 89–101, 2001.
- SIRAVENHA, A. C. AND CARVALHO, S. R. Plant classification from leaf textures. In *Digital Image Computing: Techniques and Applications (DICTA), 2016 International Conference on*. IEEE, pp. 1–8, 2016.
- WASCHER, E., RASCH, B., SUNGER, J., HOFFMANN, S., SCHNEIDER, D., RINKENAUER, G., HEUER, H., AND GUTBERLET, I. Frontal theta activity reflects distinct aspects of mental fatigue. *Biological Psychology* 96 (1): 57–65, 2014.