

Um Modelo de Aprendizado Profundo Multimodal para Classificação de Estresse Utilizando Sinais Obtidos por Dispositivos Vestíveis de Pulso

Vinícius P. Medeiros, Fagner Cunha, Eulanda M. dos Santos, Eduardo Souto

¹ Instituto de computação - Universidade Federal do Amazonas (UFAM)
Caixa Postal - 69080-900 - Manaus - AM - Brasil

{vpms,esouto}@icompu.ufam.edu.br

{emsantos,fagner.cunha}@icompu.ufam.edu.br

Abstract. *The recent proliferation of wearable devices (e.g. smartphones and smartwatches) and their ability to measure various physiological signals creates an opportunity for continuous and unobtrusive monitoring of an individual's state of stress. With this in mind, we propose a new model for stress classification based on a convolutional neural network using data collected by wrist devices. We used the leave-one-subject-out (LOSO) validation to evaluate our model that reached an average accuracy rate of 95.67%, which is higher than most of the works in the literature.*

Resumo. A recente proliferação dos dispositivos vestíveis (e.g. smartphones e smartwatches) e sua capacidade de medir vários sinais fisiológicos criam uma oportunidade de monitoramento contínuo e discreto do estado de estresse de um indivíduo. Tendo isso em vista, este trabalho propõe um novo modelo para classificação de estresse baseado em uma rede de convolução usando dados coletados por dispositivos de pulso. Os resultados obtidos, utilizando a validação *leave-one-subject-out* (LOSO), alcançaram a taxa média de 95,67% de acurácia, sendo um valor superior à maioria dos trabalhos já existentes na literatura.

1. Introdução

O estresse pode ser definido como uma resposta do corpo humano a estímulos internos ou externos a qual está relacionada à alta carga emocional de um indivíduo [Butler 1993]. Essa reação faz com que o indivíduo sofra alterações psicofisiológicas e entre em estado de alerta [Selye 1950]. Apesar de ser um mecanismo de defesa essencial para a sobrevivência, o estado de estresse torna-se prejudicial à saúde quando há frequente, intensa e consistente exposição, resultando em vários malefícios físicos e mentais [Richard 2019; Everly e Lating 2019]. Portanto, o estresse deve ser diagnosticado em seus estágios iniciais com o intuito de não acarretar danos ou conduzir a pessoa a um estado crônico.

As alterações fisiológicas e comportamentais observadas em um indivíduo podem ser usadas para reconhecer o estresse por meio do aumento dos níveis de cortisol e catecolaminas no plasma sanguíneo [Carneiro 2017; Djuric 2008]. Todavia, utilizar de forma contínua as amostragens desses hormônios é praticamente inviável, visto que são procedimentos invasivos e exigem perícias médicas [Djuric 2008]. Outros marcadores

fisiológicos também são amplamente utilizados para avaliação do estresse, incluindo: resposta galvânica da pele [Vanderark e Ely 1993], variabilidade da frequência cardíaca (HRV - Heart Rate Variability) [Von Dawans 2011], pressão arterial e atividade respiratória [McColl 2016]. Os dados gerados por esses marcadores podem ser obtidos de forma não invasiva por tecnologias vestíveis (e.g. *smartphones* e *smartwatches*), possibilitando o monitoramento contínuo e discreto do estado de estresse de um indivíduo.

Entretanto, a classificação de estresse usando sinais fisiológicos não é trivial, visto que o corpo humano sofre constantes alterações em seus parâmetros fisiológicos mesmo em um estado não estressante. Por exemplo, as respostas fisiológicas causadas pelo estresse mental podem ser mascaradas por variações decorrentes da atividade física [Bernardi 1996]. Portanto, usar apenas a frequência cardíaca como um indicador para detectar estresse mental pode levar a erros de classificação. Além disso, ruídos nos sinais causados por movimento, colocação de eletrodos ou movimento respiratório afetam a precisão dos registros medidos [Sun 2010]. Tais fatores mostram como é difícil desenvolver um sistema de classificação de estresse usando dispositivos vestíveis.

Para lidar com esses problemas, esse trabalho propõe um modelo para classificação de estresse (estressado x não estressado) baseado em uma rede de convolução usando dados coletados por dispositivos vestíveis de pulso (dispositivo Empática E4). O modelo de classificação proposto é gerado a partir de uma arquitetura de rede composta por múltiplos blocos convolução usados para extrair características de biosinais como acelerômetro, temperatura, atividade eletrodérmica (EDA) e pulso de volume sanguíneo (BVP). Uma camada de fusão é proposta para combinar as características em uma representação unificada que é usada para classificar estresse. O modelo proposto foi treinado e validado usando o dataset WESAD [Bobade e Vani 2020]. Os resultados mostram que o modelo de classificação de estresse proposto alcança taxa média de acurácia de 95,67%, sendo superior à maioria dos trabalhos existentes na literatura.

O restante do artigo está organizado como segue: a Seção 2 descreve os trabalhos relacionados; a Seção 3 apresenta uma descrição da metodologia utilizada; a Seção 4 descreve os experimentos e discute os resultados obtidos; por fim, na Seção 5 são apresentadas as conclusões e possibilidades de trabalhos futuros.

2. Trabalhos Relacionados

Os avanços tecnológicos têm possibilitado aos usuários portadores de dispositivos vestíveis o monitoramento e a classificação do estado de estresse. Porém, os classificadores normalmente enfrentam desafios de generalização, devido à reação biológica de cada indivíduo ao estresse ser influenciada por diversos fatores como sexo, idade, condições físicas e mentais. Com o intuito de superar esses problemas, foram desenvolvidas diversas abordagens baseadas em técnicas de aprendizado de máquina.

Schmidt et al. (2018) publicaram um conjunto de dados (*dataset*) de sinais fisiológicos de 15 indivíduos, denominado WESAD. Este dataset contém dados de vários sinais fisiológicos como acelerômetro de três eixos (ACC), eletrocardiograma (ECG), eletromiograma (EMG), respiração (RESP), temperatura corporal (TEMP), atividade eletrodérmica (EDA) e pulso do volume sanguíneo (BVP). Com a finalidade

de realizar classificação de estresse e do estado emocional, os indivíduos foram submetidos a diversas condições seguindo vários protocolos de preparação [Schmidt 2018]. Diferentes modelos de classificação foram avaliados incluindo florestas aleatórias, LDA (Análise Discriminante Linear), árvores de decisão, AdaBoost (AB) e K-Vizinhos Mais Próximos (KNN). O classificador LDA obteve o melhor resultado com acurácia de 80,34% para o problema de classificação de três classes (normal, contente e estresse). Para classificação binária (estressado x não estressado), o classificador LDA obteve taxas médias de acurácia de 93,12%.

Bobade e Vani (2020) propõem o uso de redes neurais profundas para realizar a classificação de estado de estresse, utilizando a base WESAD. A metodologia inclui a extração manual de características observando um janelamento de dados de 1 segundo. Os resultados mostram que o modelo de rede neural densa proposta obteve taxas de acurácia de 95,21% e F1-score de 94,24% para classificação binária.

Rashid et al. (2021) propõem o uso de uma arquitetura de rede profunda híbrida que usa tanto extração de características manuais quanto extração automática realizada por uma rede de convolução (CNN) usando apenas o sinal BVP da base de dados WESAD. Os experimentos mostram que o modelo proposto atingiu acurácia de 88,56% e F1-score de 86,18% na classificação binária. Quando avaliado no problema de três classes (normal, contente e estresse), o modelo proposto obteve um desempenho inferior com uma acurácia de 75,21% e F1-score de 64,15%, resultados esses que superam os experimentos utilizando apenas o sinal BVP produzido por Bobade e Vani (2020).

Samyoun et al. (2020) apresentam uma solução para classificação de estresse usando os sensores do pulso de forma que emulem os sensores do tórax, sendo esses considerados o padrão ouro para realizar a classificação de estado de estresse. A avaliação dessa metodologia utilizou o conjunto de dados públicos WESAD e os resultados mostram que a solução proposta tem uma acurácia comparável com os dispositivos do tórax. De maneira similar ao proposto por [Bobade e Vani 2020] e [Rashid 2021], foi realizada uma extração manual de características, obtendo-se as 15 principais. O classificador Random Forest obteve o melhor desempenho para o problema bi-classe, atingindo 92,1% e 89,7% de acurácia e F1-score, respectivamente.

Este trabalho propõe um modelo que realiza extrações automáticas de características por uma rede neural de convolução, diferenciando-se dos trabalhos de Samyoun et al. (2020), Bobade e Vani (2020) e Schmidt et al. (2018), os quais fazem extração manual de características. Além disso, esta abordagem utiliza apenas canais de sinais obtidos do pulso, similar ao trabalho de Rashid et al. (2021) que aplica a mesma técnica de extração das características apenas no canal BVP. Como a condição de estresse pode ser originalizada por diversos fatores e cada indivíduo produz um conjunto particular de bio-sinais, este trabalho inclui a observação de todos os canais de sinais obtidos a partir do pulso disponíveis na base WESAD como entrada do modelo, de modo a obter um conjunto de dados mais amplo dos sinais e consequentemente uma classificação mais precisa.

3. Metodologia

Nesta seção, nós discutimos a metodologia seguida para alcançar os objetivos de pesquisa identificados. A seção inicia fornecendo uma breve descrição do conjunto de

dados utilizado nos experimentos. Em seguida são descritos os processamentos realizados nos dados para treinar o modelo proposto. A seção 3.3 explica os detalhes da arquitetura de rede neural profunda proposta. A seção seguinte detalha as métricas utilizadas para avaliação do modelo proposto. Por último, a seção 3.6 detalha alguns aspectos da implementação.

3.1. Conjunto de dados

Este trabalho utilizou o dataset WESAD [Schmidt 2018], um conjunto de dados disponível publicamente para classificação de estresse. Esse conjunto de dados multimodal apresenta dados fisiológicos e de movimento de 15 indivíduos registrados por dispositivos usados no pulso e no peito durante um estudo de laboratório. As seguintes modalidades de sensores estão incluídas: pulso de volume sanguíneo (BVP), eletrocardiograma (ECG), atividade eletrodérmica (EDA), eletromiograma (EMG), respiração (RESP), temperatura corporal (TEMP) e aceleração de três eixos (ACC). Além disso, o conjunto de dados preenche a lacuna entre estudos de laboratório anteriores sobre estresse e emoções, contendo três estados afetivos diferentes (normal, contente e estresse). A coleta de dados foi realizada utilizando-se dois dispositivos: RespiBAN, dispositivo com sensores que extraem dados da região torácica (peito) e o dispositivo Empatica E4 (utilizado no pulso). Os sinais captados pelo RespiBAN foram ACC, ECG, EMG, RESP, TEMP e EDA, amostrados em uma frequência de 700 Hz. O Empatica E4 registra os sinais ACC, TEMP, BVP e EDA que foram amostrados a 32 Hz, 4 Hz, 64 Hz e 4 Hz, respectivamente. Neste trabalho utilizamos somente os sinais captados pelo dispositivo de pulso (Empatica E4).

3.2. Pré-processamento dos Dados

Nesta etapa, os dados foram formatados e preparados para o serem utilizados no modelo proposto. Cada sinal coletado a partir do dispositivo Empatica E4 foi segmentado a cada 60 segundos, considerando-se uma janela de sobreposição de 50% e sem sobreposição. Como cada sinal foi amostrado em uma frequência diferente, após a etapa de segmentação, o número de amostra por segmento de cada sinal (ACC, EDA, BVP, TEMP) foi de 1920, 240, 3840 e 240, respectivamente.

Para o sinal EDA adicionou-se uma etapa extra de pré-processamento que consiste em aplicar o algoritmo cvxEDA [Greco 2015] para extrair componentes do sinal por meio de métodos de otimização convexa. O sinal EDA possui dois componentes principais, um componente tônico (*tonic component*) de variação lenta que representa o nível atual de condutância da pele (SLC) e uma componente por fases (*phasic component*) que muda rapidamente, representando a resposta da condutância da pele (SCR). Esses componentes são de suma importância para classificação do estado de estresse de um indivíduo [Setz 2009] e podem ser obtidos utilizando-se o algoritmo cvxEDA mencionado. Além disso, um componente adicional foi extraído denominado SMNA (*Sudomotor Nerve Activity*), sendo outro elemento vital para classificação de estresse [Samyoun 2020].

Por fim, é realizada a normalização dos sinais subtraindo-se a média e dividindo-se pelo desvio padrão da base de treino. Durante a fase de testes, a normalização foi realizada utilizando-se os valores calculados na base de treino.

3.3. Arquitetura de Classificação

Esta seção apresenta a arquitetura do modelo de aprendizado profundo multimodal proposto. O modelo desenvolvido visa fundir as características extraídas dos sinais de atividade eletrodérmica (EDA) e suas componentes obtidas pelo algoritmo cvxEDA, pulso do volume sanguíneo (BVP), temperatura corporal (TEMP) e acelerômetro (ACC) com a finalidade de realizar a classificação do indivíduo como estressado ou não-estressado.

Cada uma das entradas é processada por uma ramificação do modelo formada pelo bloco padrão que é responsável por extrair características. Esse bloco padrão é composto por 3 blocos menores formados por uma camada de convolução 1D, seguida por uma uma camada de normalização em lote (batch normalization), função de ativação Relu e uma camada de average pooling, conforme apresenta a Figura 1. No terceiro bloco, a camada de average pooling é substituída por uma camada de global average pooling 1D. Por fim, há uma camada de dropout com 20% de remoção para reduzir o *overfitting*. A Tabela 1 apresenta os parâmetros das camadas de convolução utilizados.

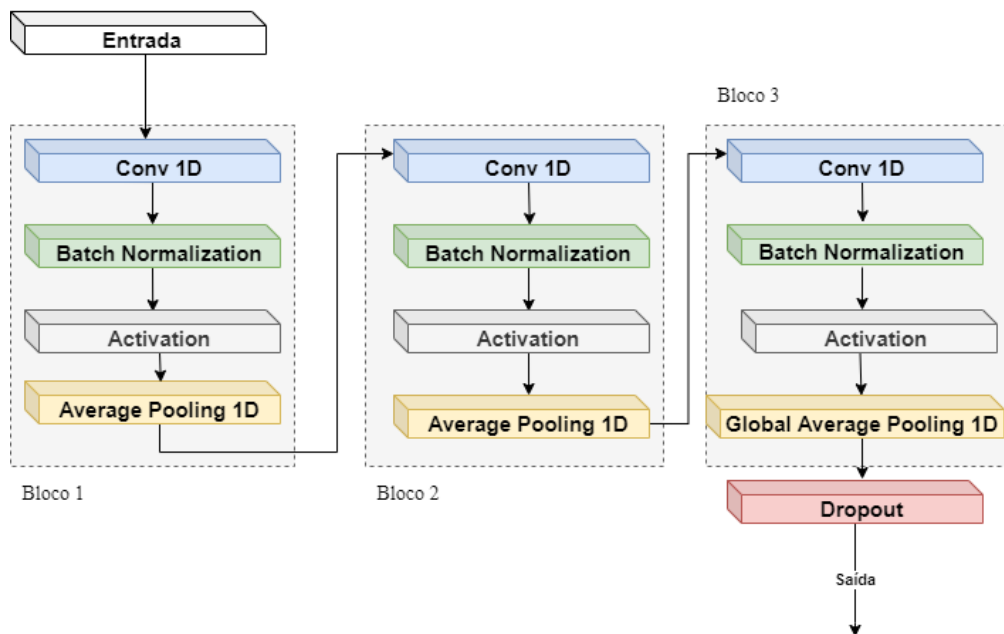


Figura 1 - Bloco Padrão da rede neural profunda proposta.

Tabela 1. Detalhes das camadas de convolução do Bloco Padrão da arquitetura proposta.

Bloco	Kernel Size	Número de Filtros	Função de Ativação
1	40	16	Relu
2	40	32	Relu
3	40	64	Relu

Após passarem pelo Bloco Padrão da rede, os sinais processados são concatenados e por fim é adicionada uma camada densa com função de ativação sigmoid, conforme mostra a Figura 2. Como os sinais de entrada não possuem os mesmos tamanhos, os pesos do Bloco Padrão não são compartilhados entre si, com cada ramificação da rede aprendendo pesos específicos durante o treinamento. As entradas são representadas como matrizes, onde o número de colunas representa a quantidade de amostras registradas no tempo de 60 segundos de enjanelamento e o número de linhas é dado pela quantidade de componentes de cada entrada. Por exemplo, a entrada do sinal EDA, devido à frequência de amostragem ser 4 Hz, possui 240 amostras e possui quatro componentes (sinal original e as componentes extraídas pelo cvxEDA), resultando numa matriz de tamanho 240×4 . As demais entradas são construídas de forma conforme mostra a Figura 1.

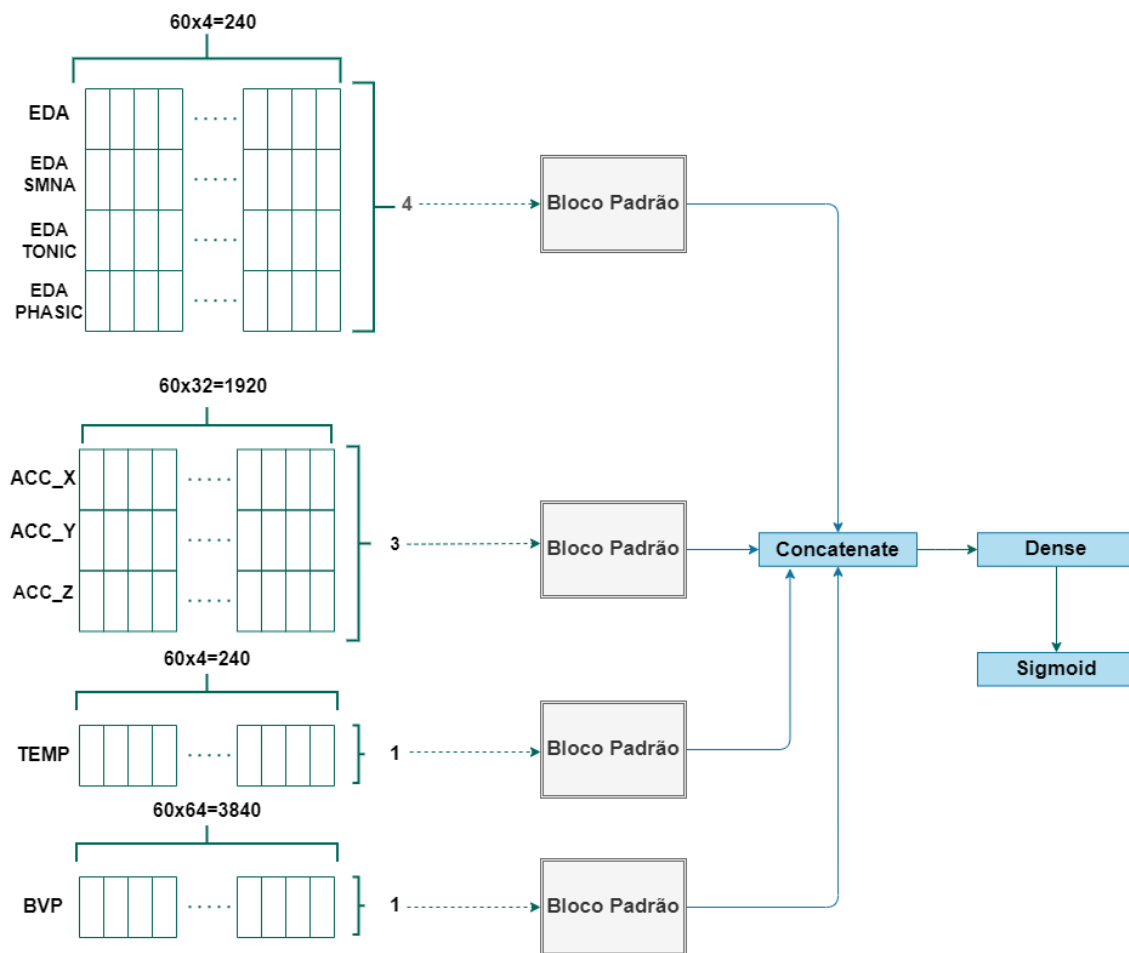


Figura 2. Arquitetura do Modelo de Classificação.

3.4. Métricas de Avaliação

O método proposto para classificação de estado de estresse foi avaliado utilizando quatro métricas: acurácia, revocação, precisão e F1-score. A acurácia é a razão de amostras corretamente preditas. Precisão refere-se a quantos foram acertados das classificações positivas. Revocação é a métrica que indica quantas o modelo consegue classificar corretamente das amostras positivas existentes. F1-score fornece uma medida que equilibra a precisão e a revocação, pois seu valor é calculado pela média harmônica da precisão e revocação.

$$Acurácia = \frac{TP+TN}{TN+TP+FP+FN} \quad (1)$$

$$Precisão = \frac{TP}{TP+FP} \quad (2)$$

$$Revocação = \frac{TP}{TP+FN} \quad (3)$$

$$F1\ Score = 2 \cdot \frac{Acurácia \cdot Precisão}{Acurácia + Precisão} \quad (4)$$

Onde TP, TN são, respectivamente, verdadeiro positivo e verdadeiro negativo. Ambos ocorrem quando o modelo classifica corretamente. Para os casos onde há incorreta classificação, tem-se o FP e FN que representam, falso positivo e falso negativo, respectivamente.

3.5. Validação

O modelo desenvolvido foi avaliado utilizando o procedimento de validação cruzada denominada *leave-one-subject-out* (LOSO). Esta técnica é um caso especial de k-fold onde k é igual ao número de pessoas na amostra. A validação utilizada permite que o modelo generalize e tenha um desempenho melhor em dados de pessoas que são consideradas desconhecidas para o modelo.

3.6. Detalhes de Implementação

A arquitetura desenvolvida tem como foco a classificação binária (estressado vs. não estressado). O classificador foi treinado por 100 épocas, utilizando um tamanho de lote (*batch*) de 64. Para a geração da arquitetura utilizou-se a linguagem python 3.6.9, e as principais bibliotecas utilizadas foram: tensorflow, sklearn e numpy. O ambiente utilizado para realização da criação, treino e validação foi Google Colaboratory.

4. Resultados e Discussão

O primeiro experimento tem como objetivo avaliar o impacto da utilização de janelamento na acurácia do modelo de classificação proposto. A Tabela 2 mostra as taxas de acurácia, revocação, precisão e F1-score obtidas pelo classificador quando utiliza sobreposição de dados dos sinais de 50% e sem sobreposição. Percebe-se que o uso de sobreposição das janelas de dados melhora todas as métricas de avaliação. A diferença entre as acurácias é de 2,66% e o aumento da métrica F1-score chega a ser 5,71%.

Tabela 2. Desempenho da classificação de estado de estresse do método

proposto (estressado vs não estressado).

Sobreposição	Acurácia (%)	Revocação (%)	Precisão (%)	F1-Score (%)
50%	95,67	89,41	94,40	91,83
0%	93,01	81,95	90,74	86,12

Com base nesses resultados, para realizar comparações com os trabalhos relacionados, optou-se por utilizar o modelo com sobreposição das janelas de dados. A Tabela 3 mostra que o modelo obteve taxas de acurácia de 95,67% sendo superior a todos os trabalhos comparados. Entretanto, o trabalho de Bobade e Vani (2020) obteve o F1-Score de 94,25%, sendo este valor superior ao modelo proposto neste trabalho. Para esse fato, existem duas principais justificativas: primeiro, a metodologia proposto por Bobade e Vani (2020) realiza uma segmentação diferente que o habitual da literatura e também utilizam os sinais do dispositivo RespiBAN (tórax), ou seja, além possuir uma quantidade maior de dados para realização do desenvolvimento do modelo, esses sinais captados pelo tórax são considerados, pela literatura, o padrão ouro para a realização de classificação do estado de estresse.

Tabela 3. Desempenho da classificação de estado de estresse dos baselines (estressado vs não estressado).

Método	Acurácia (%)	Revocação (%)	Precisão (%)	F1-Score (%)
Método Proposto	95,67	89,41	94,40	91,83
Schmidt et al. (2018)	93,12	–	–	91,47
Bobade e Vani (2020)	95,21	–	–	94,24
Rashid et al. (2021)	88,56	–	–	86,18
Samyon et al. (2020)	92,10			89,70

4.1 Estudo de ablação

O desenvolvimento da arquitetura apresentada neste artigo passou por diversas alterações e adaptações. Com intuito de obter melhores resultados, realizou-se um estudo de ablação para verificar o impacto de cada alteração na arquitetura de rede proposta.

Inicialmente, em cada bloco de extração de características possuíam duas funções de ativação, uma após a camada de convolução (CNN) e a outra após a camada de *batch normalization*, além de uma camada de *dropout*. Além disso, não existia dropout ao final de cada ramificação.

Ao retirar-se a função de ativação após a camada de convolução percebeu-se uma melhora, como pode ser observado na Tabela 4. Outro teste realizado foi adicionar camadas de *dropout* no final de cada ramificação da arquitetura antes da concatenação,

obtendo-se uma melhora. Em seguida, optou-se por remover as camadas de *dropout* na parte de extração. Como mostrado na Tabela 5, houve uma melhora significativa na revocação e uma pequena melhora nas outras métricas. Por fim, o experimento foi concluído com o aumento do kernel de cada camada de convolução, obtendo-se o melhor resultado de 95,67% de acurácia e 91,83% de F1-score.

Tabela 4. Resultados do estudo de ablação.

Refinamentos	Acurácia (%)	Revocação (%)	Precisão (%)	F1-Score (%)
+ função de ativação extra	91,95	81,28	87,79	84,41
- função de ativação extra	93,17	84,34	89,90	86,61
+ <i>dropout</i> na classificação	94,01	82,93	91,69	87,09
- <i>dropout</i> na extração	95,00	86,79	91,76	89,22
aumento do kernel	95,67	89,41	94,40	91,83

5. Conclusões

Este trabalho apresentou um novo modelo para classificação de estresse utilizando redes de convolução que utiliza os dados brutos dos sensores EDA, TEMP, BVP e ACC. As amostras dos sensores selecionados para treinar e validar o modelo estão disponíveis no conjunto de dados públicos WESAD, sendo eles captados pelo dispositivo vestível do pulso chamado Empatica E4.

Neste artigo foram realizados dois experimentos em relação à sobreposição das janelas de dados, experimentalmente, obteve-se um resultado superior quando houve uma sobreposição de 50%, chegando a exceder a acurácia e F1-score do modelo sem sobreposição, 2,66% e 5,71%, respectivamente. O melhor modelo atingiu uma acurácia de 95,67% e 89,41% de revocação para classificação binária (estressado x não estressado), mostrando que a generalização é possível, visto que utilizou-se a validação *leave-one-subject-out* (LOSO) para verificar a generalização do modelo. Comparando os resultados obtidos do modelo proposto com os trabalhos relacionados que utilizam o tempo de enjanelamento de 60 segundos, percebe-se que a metodologia desenvolvida neste trabalho foi superior em cada métrica de avaliação, mesmo utilizando uma quantidade menor de sinais em relação ao proposto por Bobade e Vani (2020).

Como possíveis trabalhos futuros, pode-se verificar a inclusão dos sinais obtidos com o dispositivo RespiBAN. Outra possibilidade é verificar um tratamento para o desbalanceamento das classes do dataset, bem como fazer uma avaliação do modelo em dispositivos reais.

6. Agradecimentos

Este artigo foi produzido no âmbito do Projeto Samsung-UFAM de Ensino e Pesquisa (SUPER), conforme previsto no Artigo 48 do Decreto nº 6.008 / 2006 (SUFRAMA),

que foi financiada pela Samsung Eletrônica da Amazônia Ltda., nos termos da Lei Federal nº 8.387 / 1991, através do convênio 001/2020, firmado com a Universidade Federal do Amazonas e a FAEPI, Brasil.

7. Referências

- Bernardi, L., Valle, F., Coco, M., Calciati, A., & Sleight, P. (1996). "Physical activity influences heart rate variability and very-low-frequency components in Holter electrocardiograms". *Cardiovascular research*, 32(2), 234-237.
- Bobade, P., & Vani, M. (2020). "Stress detection with machine learning and deep learning using multimodal physiological data". In *2020 Second International Conference on Inventive Research in Computing Applications (ICIRCA)* (pp. 51-57). IEEE.
- Butler, G. (1993). "Definitions of stress". In *Stress management in general practice* (pp. 1-5). Royal College of General Practitioners.
- Carneiro, D., Novais, P., Augusto, J. C., & Payne, N. (2017). "New methods for stress assessment and monitoring at the workplace". *IEEE Transactions on Affective Computing*, 10(2), 237-254.
- Djuric, Z., Bird, C. E., Furumoto-Dawson, A., Rauscher, G. H., Ruffin IV, M. T., Stowe, R. P., ... & Masi, C. M. (2008). "Biomarkers of psychological stress in health disparities research". *The open biomarkers journal*, 1, 7.
- Everly, G. S., & Lating, J. M. (2019). "The anatomy and physiology of the human stress response". In *A clinical guide to the treatment of the human stress response* (pp. 19-56). Springer, New York, NY.
- Greco, A., Valenza, G., Lanata, A., Scilingo, E. P., & Citi, L. (2015). "cvxEDA: A convex optimization approach to electrodermal activity processing". *IEEE Transactions on Biomedical Engineering*, 63(4), 797-804.
- McColl, D., Hong, A., Hatakeyama, N., Nejat, G., & Benhabib, B. (2016). "A survey of autonomous human affect detection methods for social robots engaged in natural HRI". *Journal of Intelligent & Robotic Systems*, 82(1), 101-133.
- Rashid, N., Chen, L., Dautta, M., Jimenez, A., Tseng, P., & Al Faruque, M. A. (2021). "Feature Augmented Hybrid CNN for Stress Recognition Using Wrist-based Photoplethysmography Sensor". In *2021 43rd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)* (pp. 2374-2377). IEEE.
- Richard, L., Hurst, T., & Lee, J. (2019). "Lifetime exposure to abuse, current stressors, and health in federally qualified health center patients". *Journal of Human Behavior in the Social Environment*, 29(5), 593-607.
- Samyoun, S., Mondol, A. S., & Stankovic, J. A. (2020). "Stress detection via sensor translation". In *2020 16th International Conference on Distributed Computing in Sensor Systems (DCOSS)* (pp. 19-26). IEEE.
- Schmidt, P., Reiss, A., Duerichen, R., Marberger, C., & Van Laerhoven, K. (2018). "Introducing wesad, a multimodal dataset for wearable stress and affect detection".

- In Proceedings of the 20th ACM international conference on multimodal interaction (pp. 400-408).
- Selye, H. (1950). "Stress and the general adaptation syndrome". *British medical journal*, 1(4667), 1383.
- Setz, C., Arnrich, B., Schumm, J., La Marca, R., Tröster, G., & Ehlert, U. (2009). "Discriminating stress from cognitive load using a wearable EDA device". *IEEE Transactions on information technology in biomedicine*, 14(2), 410-417.
- Sun, F. T., Kuo, C., Cheng, H. T., Buthpitiya, S., Collins, P., & Griss, M. (2010). "Activity-aware mental stress detection using physiological sensors". In *International conference on Mobile computing, applications, and services* (pp. 282-301). Springer, Berlin, Heidelberg.
- Vanderark, S. D., & Ely, D. (1993). "Cortisol, biochemical, and galvanic skin responses to music stimuli of different preference values by college students in biology and music". *Perceptual and motor skills*, 77(1), 227-234.
- Von Dawans, B., Kirschbaum, C., & Heinrichs, M. (2011). "The Trier Social Stress Test for Groups (TSST-G): A new research tool for controlled simultaneous social stress exposure in a group format". *Psychoneuroendocrinology*, 36(4), 514-522.