



## Redes Neurais Densas para Classificação de Estresse

Dense Neural Networks for Stress Classification

Redes neuronales densas para la clasificación del estrés

Alex Fernandes Figueiredo<sup>1</sup>, Hygo Sousa de Oliveira<sup>2</sup>, Eduardo James Pereira Souto<sup>3</sup>

### RESUMO

**Descritores:** Estresse Psicológico; Redes Neurais; Otimização Grid-Search

**Objetivo:** Propor uma arquitetura de rede neural otimizada para classificação de estresse com base em sinais vitais coletados por meio de dispositivos vestíveis. **Métodos:** Uso de rede neural densa, multicamadas, otimizada por meio da técnica *Grid-Search* para seleção de hiperparâmetros. Para treinamento e avaliação da rede foi utilizada a base de dados pública WESAD. **Resultados:** O modelo proposto atingiu acurácia média de 98.55% com desvio padrão de 0.28% em validação cruzada *k-fold*, batendo o modelo de referência que apresentou acurácia média de 86.14% e desvio padrão de 4.61% nas mesmas condições. **Conclusão:** Por meio de técnicas de otimização de hiperparâmetros para redes neurais, pode-se obter modelos com acurácia elevada na tarefa de classificação de estresse a partir de sinais fisiológicos coletados por dispositivos vestíveis.

### ABSTRACT

**Keywords:** Psychological Stress; Neural Network; Grid-Search Optimization

**Objective:** To propose a neural network architecture optimized for stress classification based on vital signs collected through wearable devices. **Methods:** Use of dense, multilayered neural network, optimized by means of the Grid-Search technique for selection of hyper-parameters. The WESAD public database was used for training and evaluation of the network. **Results:** The proposed model reached an average accuracy of 98.55% with a standard deviation of 0.28% in k-fold cross-validation, beating the reference model that presented an average accuracy of 86.14% and a standard deviation of 4.61% under the same conditions. **Conclusion:** Through hyper-parameter optimization techniques for neural networks we can obtain models with high accuracy in the task of stress classification from physiological signals collected by wearable devices.

### RESUMEN

**Descriptores:** Estrés psicológico; Red neuronal; Optimización Grid-Search

**Objetivo:** Proponer una arquitectura de red neuronal optimizada para la clasificación del estrés basada en los signos vitales recopilados a través de dispositivos portátiles. **Métodos:** Uso de red neuronal densa, multicapa, optimizada mediante la técnica de *Grid-Search* para la selección de hiperparámetros. La base de datos pública WESAD se utilizó para la capacitación y evaluación de la red. **Resultados:** El modelo propuesto alcanzó una precisión promedio de 98.55% con una desviación estándar de 0.28% en k-fold cross-validation, superando al modelo de referencia que presentó una precisión promedio de 86.14% y una desviación estándar de 4.61% en las mismas condiciones. **Conclusión:** A través de técnicas de optimización de hiperparámetros para redes neuronales, se pueden obtener modelos con alta precisión en la tarea de clasificación del estrés a partir de señales fisiológicas recolectadas por dispositivos portátiles.

<sup>1</sup> Pesquisador em Ciências da Computação e Informática do Departamento de Display Visual - VD, Sidia Instituto de Ciência e Tecnologia - SIDIA, Manaus (AM), Brasil.

<sup>2</sup> Especialista em Ciências da Computação do Instituto de Computação - IComp, Universidade Federal do Amazonas – UFAM, Manaus (AM), Brasil.

<sup>3</sup> Professor Doutor do Instituto de Computação - IComp, Universidade Federal do Amazonas – UFAM, Manaus (AM), Brasil.

## INTRODUÇÃO

Computação afetiva é a área que estuda a habilidade de computadores em reconhecer, entender e até mesmo expressar emoções<sup>(1)</sup>. Picard<sup>(2)</sup> apresenta uma discussão detalhada sobre alguns dos principais desafios presentes na computação afetiva, nas suas mais diversas áreas relacionadas a expressão, modelagem, comunicação e reconhecimento de emoções. Com relação ao reconhecimento de emoções, o grande desafio está relacionado a sua natureza contínua, que torna difícil dividi-las em um conjunto discreto e bem definido de possibilidades para serem usadas em tarefas de classificação.

No entanto, vários trabalhos classificam as emoções de acordo com as suas formas mais extremas, cuja manifestação é mais evidente e relevante para cada contexto de interesse. Picard, Vyzas e Healey<sup>(3)</sup> apresentam uma divisão das emoções em 8 classes distintas (neutro, raiva, ódio, aflição, amor platônico, amor romântico, alegria e reverência), e mostra que é possível distingui-las a partir de 4 sinais fisiológicos (eletromiografia, condutância da pele, pulso de volume sanguíneo e respiração) obtidos por meio de sensores vestíveis.

O estresse é uma das emoções que tem ganhado destaque devido a sua constante e crescente presença na sociedade moderna e a sua relação intrínseca com doenças graves. Segundo a Organização Mundial da Saúde<sup>(4)</sup>, os custos gerados para as empresas com problemas relacionados ao estresse só nos Estados Unidos são superiores a 300 bilhões de dólares por ano. Na Europa, estima-se que em 2013 o estresse associado ao trabalho teve um custo de 25 bilhões de euros para os negócios, além de um custo anual de absentismo e presenteísmo estimado em 272 bilhões de euros, e um custo de 242 bilhões de euros associado à perda de produtividade<sup>(5)</sup>.

O estresse pode ser compreendido como um mecanismo de defesa do corpo humano quando exposto a situações que exigem habilidades ou recursos muito além do que o indivíduo possui. A resposta fisiológica associada a estas situações é controlada pelo sistema nervoso autônomo, que regula funções importantes do corpo como temperatura, pressão sanguínea, respiração e atividade cardíaca<sup>(6)</sup>. Esta relação entre estresse e resposta fisiológica tem feito com que vários trabalhos venham buscar soluções que possibilitem o monitoramento contínuo de estresse em diferentes ambientes como trabalho, universidades e vida cotidiana<sup>(7)</sup>.

Greene et al.<sup>(8)</sup> apresentam os principais sinais fisiológicos associados ao estresse, assim como suas tecnologias sensoriais, tais como: (i) atividade cerebral - eletroencefalografia (EEG); (ii) atividade cardíaca - eletrocardiografia (ECG); (iii) resposta da pele - resposta galvânica da pele (GSR) e atividade eletrodérmica (EDA); (iv) atividade sanguínea - fotopletismografia (PPG); (v) atividade muscular - eletromiografia (EMG); (vi) resposta respiratória - piezoelectricidade ou geração eletromagnética. O avanço recente na área de Internet das Coisas, mais especificamente no campo de tecnologias vestíveis, fez com que grande parte destes sinais e sensores estejam presentes em produtos amplamente difundidos no mercado, como relógios e pulseiras inteligentes. Com isso, a implementação de soluções reais para monitoramento e controle contínuo de estresse

tem se tornado cada vez mais viável.

Motivados por esses avanços e oportunidades, vários autores têm explorado o uso de técnicas de inteligência artificial para classificação de estresse com base em sinais fisiológicos. Can, Arnrich e Erso<sup>(7)</sup> apresentam uma revisão detalhada da literatura sobre o uso de técnicas de aprendizado de máquina para detecção e classificação de estresse, agrupando os trabalhos com base no ambiente onde foi realizado o experimento: controlado - laboratório; restrito - escritório e carro; semi-restrito - campus universitário; irrestritos - vida diária. A maior parte dos trabalhos analisados pelos autores classificam o estresse em duas ou três classes: estresse ou relaxamento; nível alto, médio ou baixo. Para isto, são utilizadas técnicas clássicas de aprendizado de máquina, tais como SVM, KNN, Random Forest e Decision Tree. Apesar dos altos níveis de precisão alcançados, de até 99% em ambientes controlados, o uso de técnicas clássicas de aprendizagem de máquina requer um grande conhecimento do domínio, necessário para a tarefa de extração de características dos diferentes tipos de dados (sinais fisiológicos, dados comportamentais, questionários etc.). Além disso, os resultados obtidos em ambientes não controlados ainda possuem precisão inferior a 80%.

Mozgovoy<sup>(9)</sup> explora o uso de aprendizagem de máquina não supervisionada com 2 técnicas de agrupamento: *K-means* e *Gaussian Mixture Model* (GMM). O trabalho mostra que a combinação de sinais fisiológicos e não fisiológicos (MA) melhora a detecção de estresse na vida diária (ambientes não controlados) por meio de dispositivos vestíveis. Nesses ambientes, não é trivial diferenciar as respostas fisiológicas relacionadas a eventos como a atividade física intensa de respostas fisiológicas decorrentes de situações estressantes. O estudo encontrou um mapeamento entre os dados e os seguintes estados: superexcitação emocional, excitação e relaxamento. Embora o estudo tenha conseguido mostrar a importância da combinação de dados fisiológicos e não fisiológicos para classificar os estados emocionais na vida diária, não foi apresentado uma comparação com métodos validados clinicamente, tais como questionários aceitos na literatura, a fim de validar os agrupamentos encontrados pelos algoritmos *K-means* e GMM.

O objetivo deste trabalho é apresentar uma arquitetura de rede neural densa, multicamada e otimizada para classificação de estresse em 3 classes distintas: estresse, diversão e neutro. Para isto, será utilizada a base de dados pública WESAD, que disponibiliza dados coletados por meio de dispositivos vestíveis e validados por meio de questionários de estresses amplamente aceitos na literatura. Além de combinar sinais fisiológicos e de movimento, potencializando o uso em soluções de detecção de estresse na vida cotidiana, a arquitetura utilizada dispensa um amplo conhecimento do domínio para extração de características dos sinais utilizados, uma vez que aceita os sinais puros como entrada. A seleção de hiperparâmetros da rede neural foi realizada através da técnica *Grid-Search*, otimizando os resultados obtidos.

## MÉTODOS

Base de Dados

Neste trabalho será utilizada a base de dados

WESAD<sup>(10)</sup>. Esta é uma base aberta para estudos em computação afetiva, construída a partir de dados coletados de 15 indivíduos submetidos a experimentos laboratoriais. Cada um dos indivíduos, 12 homens e 3 mulheres com idade média de  $27.5 \pm 2.4$  anos, foram expostos a diferentes estímulos de modo a transitarem entre 3 estados afetivos: neutro, estresse e diversão. Durante o experimento foram coletados sinais fisiológicos, de movimento e dados de questionários bem estabelecidos na literatura de computação afetiva.

Dois dispositivos vestíveis foram utilizados para o sensoriamento dos sinais: *Empatica E4\** e *RespiBAN Professional\*\**. Nesta pesquisa apenas os dados de alta resolução (700Hz) coletados por meio do dispositivo vestível peitoral *RespiBAN* são utilizados para o treinamento e avaliação dos modelos apresentados. Os principais sinais fisiológicos e de movimento utilizados na literatura para detecção de estresse foram coletados com o *RespiBAN* e disponibilizados na base de dados: ECG, EDA, EMG, respiração, temperatura corporal e aceleração em três eixos. Na figura 1 são apresentadas amostras destes sinais.

Devido às limitações de recursos computacionais, para treinamento e avaliação final dos modelos a base de dados WESAD foi reduzida de forma a serem utilizadas apenas 100.000 amostras para cada indivíduo da base, totalizando 1.500.000 amostras de um conjunto de 23.206.404 amostras disponíveis (6.43%). A seleção das amostras para cada paciente foi realizada de forma aleatória, mantendo a seguinte distribuição de classes: 53,21% neutro, 30,04% estresse e 16,76% diversão. Estes valores são similares à distribuição da base de dados original, preservando assim sua característica.

### Redes Neurais

Uma Rede Neural Artificial (RNA) é um modelo computacional com um conjunto de unidades de processamento interconectadas e funcionando em paralelo, inspiradas no comportamento organizacional do cérebro humano, possibilitando um alto desempenho na realização

de tarefas que antes eram restritas as pessoas, como problemas perceptivos complexos<sup>(11)</sup>. As unidades básicas de processamento das redes neurais são chamadas de neurônios. A forma como os neurônios são interconectados está diretamente relacionada a capacidade da rede em realizar determinado tipo de tarefa. Neste sentido, o presente trabalho concentra-se em arquiteturas de redes neurais densas, completamente conectadas, como a arquitetura apresentada na figura 2.

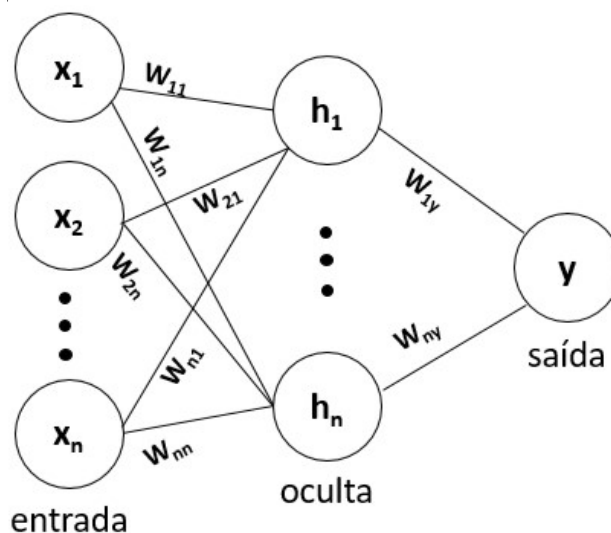


Figura 2 – Estrutura geral de uma rede neural densa.

A geração de uma rede neural passa pelos ajustes de seus pesos  $w$  durante a fase de treinamento do modelo, que é composta de duas etapas principais: (i) alimentação (*feedforward*) – onde a saída  $y$  é estimada com base nos valores atuais dos pesos  $w$  e nas funções de ativação  $h$  em cada camada da rede<sup>(12)</sup>; (ii) retro alimentação (*backpropagation*) – onde o erro da estimativa realizada na etapa anterior, representado pela função de custo, é utilizado para atualização dos pesos da rede por meio de algoritmos de otimização, em um processo conhecido por gradiente descendente<sup>(13-14)</sup>.

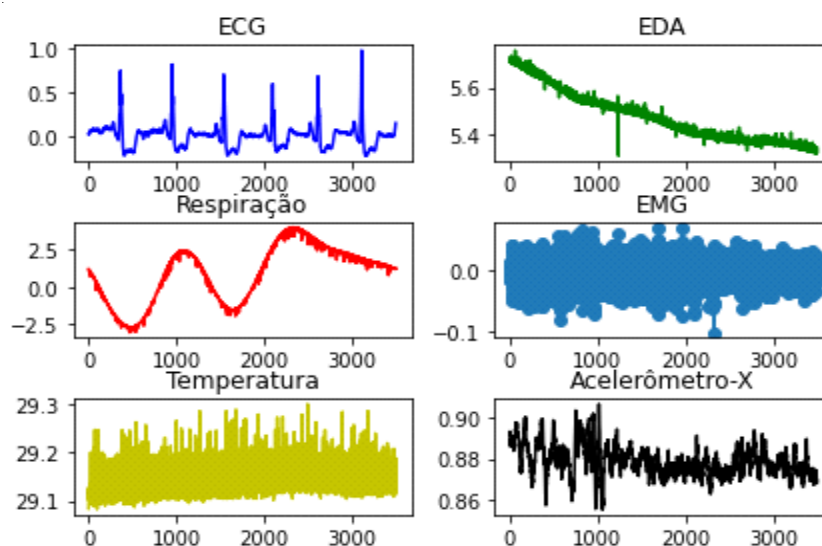


Figura 1 – Amostras de sinais fisiológicos e de movimento da base WESAD

\* <http://www.empatica.com/research/e4/>

\*\* <http://www.biosignalsplux.com/en/respiBAN-professional>

As funções de ativação presentes nas camadas da rede exercem um papel fundamental no resultado do modelo, e devem ser definidas de acordo com a natureza do problema abordado. Para problemas de classificação multiclases, como o apresentado neste trabalho, a função de ativação *softmax* é amplamente utilizada para a camada de saída da rede. Já para as camadas internas do modelo, dentre o amplo conjunto de opções disponíveis, destacam-se a unidade linear retificada (*relu*) e a tangente hiperbólica (*tanh*).

### Otimização *Grid-Search*

Grande parte dos estudos que envolvem algoritmos de aprendizagem de máquina têm como objetivo estruturar modelos capazes de capturar padrões característicos de determinada base de dados para poder realizar classificação ou regressão<sup>(15)</sup>. Em modelos de redes neurais, é comum que existam diversas propostas arquiteturais e de hiperparametrização. A arquitetura varia entre a quantidade de neurônios e camadas, enquanto a hiperparametrização é expressa por elementos como taxa de aprendizagem, função de ativação, função de perda/custo, dentre outros.

A busca por hiperparâmetros é comumente realizada de forma manual por meio de testes dentro de um conjunto de parâmetros pré-definidos<sup>(16)</sup>. Uma das técnicas que automatiza esta tarefa é denominada *Grid-Search*, a qual garante escolhas ótimas de um conjunto pré-estabelecido de possibilidades<sup>(17)</sup>. Na prática, o que um algoritmo de busca de hiperparametrização faz é encontrar o conjunto de parametrização que minimize o erro de generalização do modelo, por meio do processo

denominado como busca de hiperparâmetros ótimos<sup>(17)</sup>.

No presente trabalho, o conjunto de hiperparâmetros estabelecido para o modelo neural proposto, gerado com a biblioteca *tensorflow*<sup>\*\*\*</sup>, foi definido por meio do método *GridSearch* disponível na biblioteca *sklearn*<sup>\*\*\*\*</sup> com linguagem de programação *python*<sup>\*\*\*\*</sup>. O conjunto de parâmetros testado está apresentado no quadro 1.

### Modelo para Detecção de Estresse

O modelo proposto neste trabalho foi gerado com base na arquitetura de rede neural apresentada por Markovic et. al.<sup>(18)</sup>. Os autores realizaram a mesma tarefa de classificação de estresse por meio de uma arquitetura densa, multicamadas, de rede neural treinada e avaliada com os dados coletados do dispositivo RespiBAN fornecidos pela base de dados WESAD<sup>(10)</sup>. Ambos os modelos, de referência e o proposto neste trabalho, apresentam as seguintes características em comum:

- **Entrada:** 8 neurônios para receber um conjunto de 8 amostras simultâneas, uma para cada sinal biológico e de movimento coletados pelo sensor de peito;
- **Saída:** 3 neurônios para fornecer as possíveis classes de estresse utilizadas neste trabalho (neutro, estresse e diversão);
- **Função de Perda:** como se trata de um problema de classificação com múltiplas classes, ambos os trabalhos utilizam a função entropia cruzada categórica;
- **Função de Ativação:** Por ser uma função com grande aceitação na literatura, a unidade linear retificada (*relu*) é utilizada para ativação dos neurônios nas camadas escondidas. Para a camada de saída, é empregada a função *Softmax*, cuja utilização é indicada para problemas de

Quadro 1 – Parâmetros utilizados na técnica *grid-search*

Tipo de Parametrização		Opções
Hiperparâmetros da Rede	Estrutura de camadas	[8,5,5,3], [8,5,5,5,3], [8,5,5,5,5,3], [8,10,8,5,4,3]
	Ativação das Camadas Escondidas	<i>relu</i>
	Ativação da Saída	<i>softmax</i>
Parâmetros de Treinamento	Função de Perda	Entropia Cruzada Categórica
	Otimizador da Função de Perda	<i>Adam</i> , <i>Rmsprop</i>
	Inicialização de Pesos	<i>he_normal</i>
	Épocas de Treinamento	30
	Tamanho de Unidade de Treinamento ( <i>batch size</i> )	32, 64

Quadro 2 – Modelos proposto e de referência.

Parametrização	Modelo Proposto	Markovic et. al. <sup>(18)</sup>
Hiperparâmetros da Rede	Neurônios de Entrada	8
	Neurônios de Saída	3
	Número de Camadas Escondidas (Neurônios por camada)	2 (5, 5)
	Ativação das Camadas Escondidas	<i>relu</i>
	Ativação da Saída	<i>softmax</i>
Parâmetros de Treinamento	Função de Perda	Entropia Cruzada Categórica
	Otimizador da Função de Perda	<i>Stochastic gradient descent (SGD)</i>
	Inicialização de Pesos	<i>glorot_uniform</i>
	Épocas de Treinamento	10
	Tamanho de Unidade de Treinamento ( <i>batch size</i> )	10

\*\*\* [https://www.tensorflow.org/api\\_docs](https://www.tensorflow.org/api_docs)

\*\*\*\* [https://scikit-learn.org/stable/modules/generated/sklearn.model\\_selection.GridSearchCV.html](https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.GridSearchCV.html)

\*\*\*\*\* <https://www.python.org/doc/>

classificação com múltiplas classes.

Por outro lado, os modelos de referência e proposto diferem com relação a seleção de hiperparâmetros da rede neural e configurações de parâmetros utilizados para o seu treinamento, tais como: número de camadas escondidas, regulação de pesos, otimizador para função de perda, número de épocas e tamanho de cada unidade de treinamento (*batch size*).

Enquanto o modelo de referência realizou uma seleção manual dos parâmetros utilizados na arquitetura da rede, o modelo proposto neste trabalho empregou a técnica de *Grid-Search*, previamente apresentada, para seleção de um conjunto ótimo de hiperparâmetros da rede e parâmetros de treinamento. No quadro 2 é apresentado um comparativo dos valores finais utilizados em ambos os modelos.

## RESULTADOS E DISCUSSÃO

Para treinamento e avaliação final dos modelos proposto e de referência, a base de dados foi dividida em duas: (90%) base de treino/validação e (10%) de base de teste.

A primeira etapa de avaliação dos modelos foi realizada na base de treino/validação (90%) por meio do método de validação cruzada *k-fold*<sup>(19)</sup>. Neste método a base de dados é dividida em *k* partições de mesmo tamanho. São então executadas *k* rodadas de treino/validação, onde em cada rodada uma partição é usada apenas para validação e as demais são usadas para treinamento do modelo. Desta forma, uma determinada partição é usada uma única vez como conjunto de validação e participa vezes do conjunto de treinamento.

O resultado da validação cruzada *k-fold* pode ser representado por métricas estatísticas sobre as *k* rodadas de treino/validação, tais como acurácia média, mínima,

máxima e desvio padrão. Este método permite uma avaliação com viés reduzido se comparado a outros métodos comumente usados, como divisão única da base de dados em conjuntos de treino e teste, fornecendo uma métrica confiável de quão bem o modelo se comporta em dados nunca vistos (nível de generalização). Neste trabalho foram utilizadas 10 partições (*k* = 10) para validação cruzada. Os resultados obtidos para ambos os modelos proposto e de referência são apresentados no quadro 3.

De acordo com o quadro 3, o modelo proposto obteve uma acurácia média elevada e um baixo valor de desvio padrão, o que indica um alto nível de generalização para o problema de classificação de estresse na base de dados utilizada, desempenhando bem e de forma similar em todas as 10 partições. Já o modelo de referência, apesar de apresentar um valor de acurácia relativamente elevado no melhor caso, apresentou um alto desvio padrão, mostrando um baixo nível de generalização e alta dependência com conjuntos específicos de dados presentes em algumas partições da base de dados.

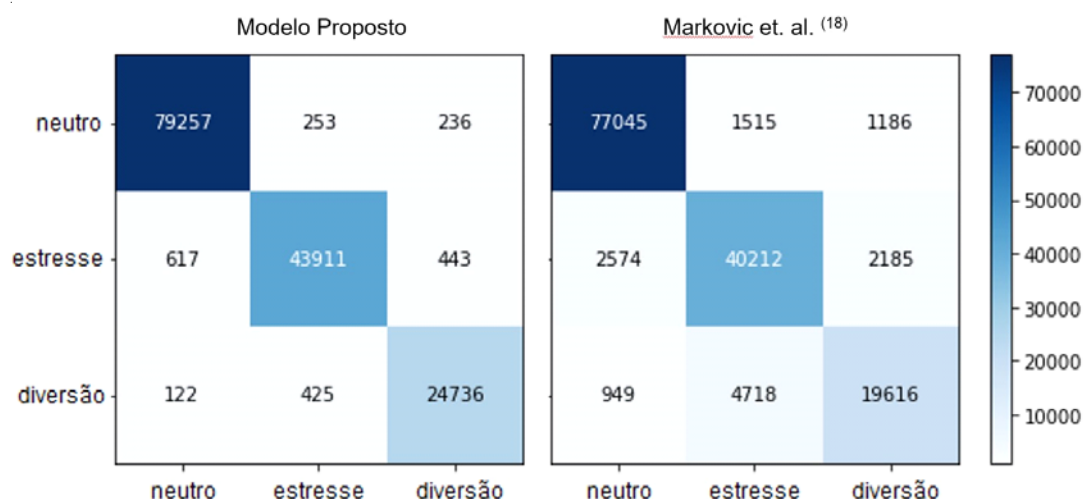
A segunda etapa de avaliação dos modelos foi realizada treinando-os na base de treino/validação (90%) e avaliando-os na base de teste (10%). Para avaliação dos modelos foi utilizada a técnica de matriz de confusão<sup>(20)</sup>. Esta é representada por uma matriz bidimensional onde o eixo vertical indica os valores reais e o eixo horizontal indica os resultados estimados pelo modelo classificador. Desta forma, pode-se observar quanto o modelo proposto está confundindo-se com relação as diferentes classes.

Na figura 3 é apresentado as matrizes de confusão obtidas no conjunto de dados de teste para ambos os modelos proposto e de referência.

A partir da matriz de confusão pode-se obter a acurácia total dos modelos para as amostras de teste, assim como a acurácia individual do modelo para cada uma das classes

**Quadro 3** – Validação cruzada com 10 partições

Métrica	Modelo proposto	Markovic et. al. <sup>(18)</sup>
Acurácia Mínima	98.09%	76.54%
Acurácia Máxima	99.07%	92.63%
Desvio Padrão	0.28%	4.61%
Acurácia Média	98.55%	86.14%



**Figura 3** – Matrizes de confusão dos modelos proposto e de referência

**Quadro 4** – Acurácias de modelos proposto e de referência

Classe	Acurácia	
	Modelo proposto	Modelo de referência
Neutro	99.08%	95.63%
Estresse	98.48%	86.58%
Diversão	97.33%	85.34%
Total	98.60%	91.25%

previstas. Estes resultados são apresentados no quadro 4.

Com base nestes resultados pode-se observar que enquanto o modelo proposto tem desempenho similar na classificação das 3 classes presentes na base, o modelo de referência possui uma elevada discrepância entre o resultado obtido para a classe “neutro” e os resultados obtidos para as duas classes restantes (“estresse” e “diversão”). Isso pode ser explicado devido a maior ocorrência de dados da classe “neutro” na base utilizada.

#### Conclusão

A combinação de técnicas de internet das coisas e inteligência artificial para melhoria dos serviços de saúde tem se tornado realidade no contexto das mais diversas doenças e síndromes crônicas. Neste sentido, destaca-se o monitoramento de estresse por meio de sinais fisiológicas e de movimento coletados por dispositivos vestíveis combinado ao uso de técnicas de aprendizagem de máquina. Os resultados obtidos neste trabalho mostram que o uso de redes neurais densas, multicamadas, apresenta um desempenho elevado na detecção de estresse por meio de sinais fisiológicos, eliminando a necessidade de métodos de pré-processamento complexos presentes em técnicas de aprendizagem de máquina clássico. Além disso, o trabalho mostra que por meio do uso de técnicas de otimização de hiperparâmetros pode-se obter resultados consideravelmente superiores aos obtidos por meio da seleção manual dos parâmetros da rede. O modelo classificador de estresse proposto obteve uma acurácia média de 98.55% na validação cruzada de 10 partições

para a tarefa de classificação de estresse entre as classes neutro, estresse e diversão, superando o modelo de referência que obteve uma acurácia média de 86.14% para o mesmo problema.

Devido à grande quantidade de parâmetros e o respectivo esforço computacional exigido para treinamento das redes neurais densas, multicamadas, assim como ao tamanho da base de dados utilizada, o processo de treinamento e validação dos modelos foi realizado em um conjunto reduzido de dados. Como trabalho futuro, pode-se utilizar modelos de aprendizagem profunda, como redes neurais com camadas convolucionais e/ou recorrentes, que sejam otimizados com relação ao uso de recursos computacionais e mantenham um desempenho similar ao obtido neste trabalho. Estes modelos, por serem mais leves, podem apresentar vantagens para uso em aplicações reais de monitoramento contínuo de estresse.

#### AGRADECIMENTOS

Este trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001; além de, conforme previsto no Art. 48 do decreto nº 6.008/2006, ser parcialmente financiado pela Samsung Eletrônica da Amazônia Ltda, nos termos da Lei Federal nº 8.387/1991, através de convênio nº 003/2019, firmado com o ICOMP/UFAM. Por isso, expressamos nosso profundo agradecimento pelo apoio e financiamento recebido.

#### REFERÊNCIAS

- Picard RW. *Affective Computing*. Cambridge, MA, USA: MIT Press; 1997.
- Picard RW. *Affective computing: challenges*. *International Journal of Human Computer Studies* [Internet]. 2003 Jul;59(1-2):55-64. Available from: [http://dx.doi.org/10.1016/S1071-5819\(03\)00052-1](http://dx.doi.org/10.1016/S1071-5819(03)00052-1).
- Picard RW, Vyzas E, Healey J. *Toward machine emotional intelligence: analysis of affective physiological state*. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2001;23(10):1175-1191.
- World Health Organization [Internet]. *Stress at the workplace*; c2020 [Acessado em 20 de Set de 2020].
- Calculating the costs of work-related stress and psychosocial risks: literature review. [Internet]. LU: Publications Office; 2014.
- Sioni R, Chittaro L. *Stress Detection Using Physiological Sensors*. *Computer* [Internet]. 2015 out;48(10):26-33.
- Can YS, Arnrich B, Ersoy C. *Stress detection in daily life scenarios using smart phones and wearable sensors: A survey*. *Journal of Biomedical Informatics* [Internet]. 2019 abr;92:103139..
- Greene S, Thapliyal H, Caban Holt A. *A Survey of Affective Computing for Stress Detection: Evaluating technologies in stress detection for better health*. *IEEE Consumer Electron Mag* [Internet]. 2016 out; 44-56.
- Mozgovoy V. *Stress Pattern Recognition Through Wearable Biosensors in the Workplace: Experimental Longitudinal Study on the Role of Motion Intensity*. In: 2019 6th Swiss Conference on Data Science (SDS); 2019. p.37-45.
- Schmidt P, Reiss A, Duerichen R, Marberger C, Van Laerhoven K. *Introducing WESAD, a Multimodal Dataset for Wearable Stress and Affect Detection*. In: *Proceedings of the 20th ACM International Conference on Multimodal Interaction*. ICMI '18. New York, NY, USA: Association for Computing Machinery; 2018. p. 400-408.
- Jain AK, Jianchang Mao, Mohiuddin KM. *Artificial neural networks: a tutorial*. *Computer* [Internet]. 1996 mar;29(3):31-44
- Bishop CM. *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Berlin, Heidelberg: Springer-Verlag; 2006.
- Kubat M. *An Introduction to Machine Learning*. 1st ed. Springer Publishing Company, Incorporated; 2015.
- Haykin S. *Neural Networks and Learning Machines (3rd Edition)*. Prentice Hall, 2009.
- Claesen M, Moor BD. *Hyperparameter Search in Machine Learning*. CoRR.2015;abs/1502.02127.
- Hinton GE. In: Montavon G, Orr GB, Muller KR, editors. *A Practical Guide to Training Restricted Boltzmann*

- Machines. Berlin, Heidelberg: Springer Berlin Heidelberg; 2012. p. 599–619.
17. Bergstra J, Bengio Y. Random Search for Hyper-Parameter Optimization. *J Mach Learn Res.* 2012 Feb;13(null):281–305.
  18. Markovic D, Vujicic D, Stojic D, Jovanovic Z, Pesovic U, Randic S. Monitoring System Based on IoT Sensor Data with Complex Event Processing and Artificial Neural Networks for Patients Stress Detection. In: 2019 18th International Symposium INFOTEH-JAHORINA (INFOTEH) [Internet]. IEEE; 2019
  19. Refaizadeh P, Tang L, Liu H. Cross-Validation. In: *Encyclopedia of Database Systems* [Internet]. Springer US; 2009. p. 532–8.
  20. Sammut C, Webb GI, organizadores. *Encyclopedia of Machine Learning and Data Mining* [Internet]. Springer US; 2017.