



## Reconhecimento de estresse via eletrocardiograma utilizando dimensionalidade reduzida e aprendizagem de máquina

Stress recognition via electrocardiogram using reduced dimensionality and machine learning

Reconocimiento de estrés mediante electrocardiograma con dimensionalidad reducida y aprendizaje automático

Marcos Paulo de Carvalho Lopes<sup>1</sup>, Gabriel Bastos Cerquinho<sup>2</sup>, Rafael Albuquerque Pinto<sup>3</sup>, Hygo Sousa de Oliveira<sup>3</sup>, Alex Fernandes Figueirêdo<sup>3</sup>, Kevin Gustavo Montero Quispe<sup>4</sup>, Eulanda Miranda dos Santos<sup>5</sup>, Eduardo James Pereira Souto<sup>5</sup>

### RESUMO

**Descritores:**  
Aprendizado de Máquina;  
Eletrocardiografia;  
Dispositivos Eletrônicos  
Vestíveis

**Objetivo:** Reconhecer eventos de estresse de um usuário usando técnicas de redução de dimensionalidade e classificadores de aprendizagem de máquina. **Método:** Estudo realizado com sinal ECG captado através de dispositivo vestível, com extração das características dos dados obtidos e aplicação da redução de dimensionalidade sobre o conjunto, e experimentos dos modelos com e sem redução. **Resultados:** Foram realizados experimentos com *K-Nearest Neighbors* (KNN), *Naive Bayes*, *Decision Tree* e *Random Forest*. Foi observado que a maioria dos modelos conseguiu detectar estresse eficientemente, obtendo uma acurácia média de 81% sem aplicação da redução e 83,5% aplicando a redução. Sendo *Random Forest* o melhor classificador final, com acurácia de 90%. **Conclusão:** A redução de dimensionalidade demonstrou-se eficaz em melhorar o desempenho geral do método KNN. Além de que, ao ser testada em métodos mais robustos, não apresentou quedas significativas nas métricas propostas, diminuindo o custo computacional de processamento dos algoritmos.

### ABSTRACT

**Keywords:** Machine Learning;  
Electrocardiography;  
Wearable Electronic Devices

**Objective:** Recognize a user's stress events using dimensionality reduction techniques and machine learning classifiers. **Method:** Study carried out with an ECG signal captured through a wearable device, with extraction of the characteristics of the data obtained and application of the dimensionality reduction on the set, and experiments of the models with and without reduction. **Results:** Experiments were carried out with *K-Nearest Neighbors* (KNN), *Naive Bayes*, *Decision Tree* and *Random Forest*. It was observed that most models were able to detect stress efficiently, obtaining an average accuracy of 81% without applying the reduction and 83.5% applying the reduction. *Random Forest* being the best final classifier, with 90% accuracy. **Conclusion:** Dimensionality reduction proved to be effective in improving the overall performance of the KNN method. Besides, when tested in more robust methods, it did not show significant drops in the proposed metrics, decreasing the computational cost of processing the algorithms.

### RESUMEN

**Descriptores:**  
Aprendizaje automático;  
Electrocardiografía;  
Dispositivos Electrónicos  
Vestibles

**Objetivo:** Reconocer los eventos de estrés de un usuario mediante técnicas de reducción de dimensionalidad y clasificadores de aprendizaje automático. **Método:** Estudio realizado con una señal de ECG captada a través de un wearable, con extracción de las características de los datos obtenidos y aplicación de la reducción de dimensionalidad en el plató, y experimentos de los modelos con y sin reducción. **Resultados:** Los experimentos se llevaron a cabo con *K-Neighbors Neighbors* (KNN), *Naive Bayes*, *Decision Tree* y *Random Forest*. Se observó que la mayoría de los modelos fueron capaces de detectar la tensión de manera eficiente, obteniendo una precisión promedio del 81% sin aplicar la reducción y del 83,5% aplicando la reducción. *Random Forest* es el mejor classificador final, con un 90% de precisión. **Conclusión:** La reducción de la dimensionalidad demostró ser eficaz para mejorar el rendimiento general del método KNN. Además, cuando se probó en métodos más robustos, no mostró caídas significativas en las métricas propuestas, disminuyendo el costo computacional de procesar los algoritmos.

<sup>1</sup> Discente de Graduação do curso de Ciência da Computação no Instituto de Computação, Universidade Federal do Amazonas – UFAM, Manaus (AM), Brasil.

<sup>2</sup> Discente de Graduação do curso de Engenharia de Software no Instituto de Computação, Universidade Federal do Amazonas – UFAM, Manaus (AM), Brasil.

<sup>3</sup> Discente de Mestrado em Informática, Universidade Federal do Amazonas – UFAM, Manaus (AM), Brasil.

<sup>4</sup> Discente de Doutorado Informática, Universidade Federal do Amazonas – UFAM, Manaus (AM), Brasil.

<sup>5</sup> Professor Associado do Instituto de Computação, Universidade Federal do Amazonas – UFAM, Manaus (AM), Brasil.

## INTRODUÇÃO

O estresse é uma condição psicológica há tempos conhecida e que tem se tornado cada vez mais presente na sociedade moderna, causando grandes impactos negativos que se estendem da saúde das pessoas às finanças das empresas. Hassard et al.<sup>(1)</sup> relatam que, só em 2013, o estresse relacionado ao trabalho custou 25 bilhões de euros aos negócios da União Europeia. No mesmo estudo, estima-se que o custo anual de absenteísmo e presentismo, causado principalmente pelo estresse, em toda a Europa é de 272 bilhões de euros e o custo da perda de produtividade é de 242 bilhões de euros.

O estresse é caracterizado pela descarga de hormônios como o cortisol e pode ser provocado por vários estímulos cotidianos, como agitação ocasionada pelo trânsito, ansiedade provocada por apresentações de trabalho ou adrenalina gerada pela exibição de séries televisivas. O padrão clássico para o diagnóstico de estresse envolve extrações de cortisol de várias fontes: cabelo, saliva, sangue e urina. Essas medições ocorrem de forma invasiva e envolvem um processo trabalhoso de análise<sup>(2-3)</sup>, o que dificulta o tratamento da doença em um tempo hábil. No entanto, o crescente avanço tecnológico criou meios alternativos para o diagnóstico de estresse via sensores vestíveis, viabilizando métodos de diagnósticos não invasivos e o monitoramento de sinais fisiológicos de forma contínua.

O estudo do monitoramento dos estados afetivos e cognitivos humanos por meios computacionais é regido pela Computação Afetiva<sup>(4)</sup>, que faz a combinação das áreas de ciência da computação, engenharia com ciências cognitivas, fisiologia e psicologia. Geralmente, esse estudo é feito através de modelos de aprendizagem de máquina baseados em biossinais capturados por sensores. Esses modelos, por sua vez, são sistemas computacionais sensíveis, capazes de perceber, interpretar o sentimento humano e fornecer respostas inteligentes às solicitações humanas<sup>(5)</sup>.

As medidas fisiológicas de estresse podem ser obtidas por meio dos sensores de Eletrocardiograma (ECG) e Resposta Galvânica da Pele (GSR). O ECG realiza o monitoramento da atividade elétrica do coração, sendo

comumente usado no monitoramento de estresse e, devido a isso, será o utilizado neste estudo. Outro sensor presente nos dispositivos vestíveis e utilizado para medidas fisiológicas de estresse é o de Resposta Galvânica da Pele (GSR), que mede a resistência atual da pele em espessura. Neste trabalho, o GSR é usado no processo de rotulagem de dados.

Com sensoriamento ECG, é possível calcular a frequência cardíaca (HR, do inglês *Heart Rate*) através da diferença entre os intervalos RR consecutivos de cada onda, demonstrado na Figura 1, que são especificamente a diferença entre dois batimentos cardíacos medidos em milissegundos. Por intermédio do HR, é possível derivar sua própria variação (HRV, do inglês *Heart Rate Variability*), popularmente conhecida como o arranjo de características (*features*) entre os intervalos RR, os quais são comumente extraídas a partir de cálculos estatísticos no domínio do tempo e da frequência<sup>(6)</sup>.

Apesar dessas derivações de características terem uma natureza estatística, há muitas correlações descritas na literatura entre o aparecimento de estresse e a mudança das medidas citadas anteriormente. As *features* citadas anteriormente podem ser dispostas a modelos de aprendizagem de máquina, que a partir de um conjunto de dados específico (características derivadas do sinal ECG) conseguem aprender padrões, comportamento e diferenças sobre os dados de modo a realizar predições inéditas, como classificar se um indivíduo se encontra estressado ou não.

Liu e Ulrich<sup>(8)</sup> propõem a classificação de estresse a partir de biossinais capturados por dispositivos vestíveis. Os autores utilizaram dados brutos do ECG e HRV no aprendizado de sete diferentes algoritmos, variações de *Support Vector Machine* (SVM) e *Gaussian Naive Bayes* (GNB). A média total de acurácia somando todos os classificadores foi de 82,5%. O trabalho de Christopher Ottesen<sup>(9)</sup> segue a mesma linha de experimentação, a diferença está no uso de um algoritmo para definir o melhor modelo e hiperparâmetros para o problema. O método proposto por Christopher emprega o algoritmo k-ésimo vizinho mais próximo (KNN) e obteve acurácia de 80%. Em ambos os trabalhos, os autores indicam a inviabilidade do uso dos modelos propostos em dispositivos vestíveis, devido à grande complexidade dos

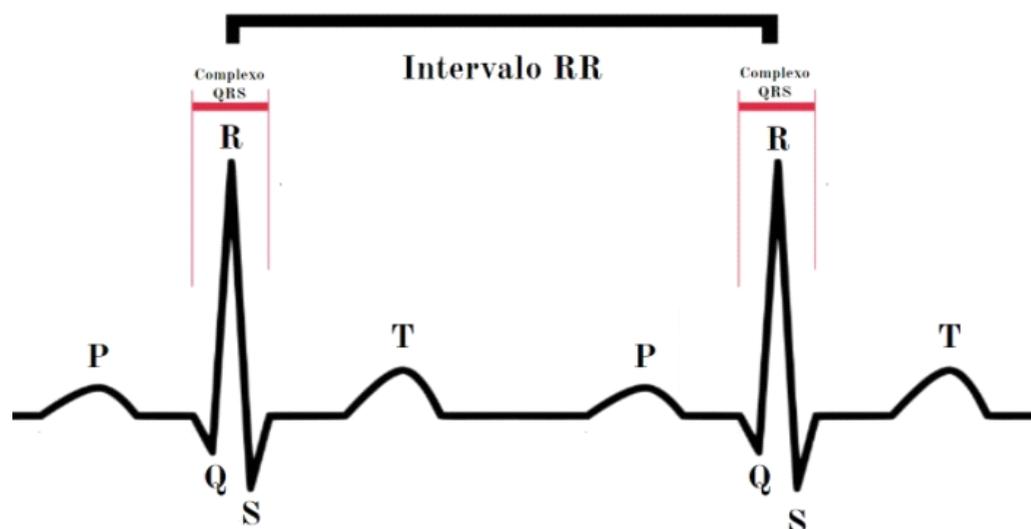


Figura 1 – Complexo de ondas QRS, intervalo RR<sup>(7)</sup>.

algoritmos gerados e baixo poder de processamento dos dispositivos.

O trabalho de Cho et al.<sup>(10)</sup> visa a predição de estresse a partir de dados ECG puros. Nesse caso, é utilizada uma rede neural artificial que aprende o comportamento desses sinais e classifica o usuário a partir de variações bruscas desse comportamento, obtendo uma acurácia final de 80%. De forma similar a Cho et al., Schmidt et al.<sup>(11)</sup> também utilizam redes neurais para propor um método de detecção de estresses. Os autores propõem uma rede neural convolutiva a partir dos sinais de fotopletismografia (PPG), atividade eletrodérmica (EDA) e temperatura (TEMP), atingindo uma acurácia de 70.5%. Os métodos citados também são inviáveis para embarcação em dispositivos vestíveis em razão da grande quantidade de características necessárias para o aprendizado da rede.

Para lidar com estes problemas, este trabalho propõe um estudo que comprova que modelos de aprendizagem para classificação de estresse são eficientes quando gerados adequadamente com o uso de técnicas de otimização em comparação àqueles que não são otimizados. Em aprendizagem de máquina, a otimização ou ajuste de hiperparâmetros (*tuning*) corresponde ao problema de escolher um conjunto de hiperparâmetros ideais para um algoritmo de aprendizado. Neste trabalho, nós empregamos a técnica *grid search* para realizar uma busca exaustiva por meio de um subconjunto especificado manualmente do espaço de hiperparâmetros de um algoritmo de aprendizagem. Além disso, para tratar o problema da alta dimensionalidade dos dados e reduzir o custo computacional dos modelos propostos, nós empregamos a técnica de Análise de Componentes Principais (*Principal Component Analysis* - PCA), que além de fazer a diminuição do número de características, também define os atributos mais significativos do conjunto de dados, de forma que a aplicação da redução não implique em perda de informação.

## MÉTODO

Este trabalho utiliza um método de aprendizado supervisionado, no qual classificadores são treinados a partir de um conjunto de dados processados e rotulados. As etapas de desenvolvimento, ilustradas na Figura 2, incluem o pré-processamento, definição do conjunto representativo de características, redução de dimensionalidade, particionamento da base de dados, validação dos parâmetros utilizados nos classificadores e avaliação dos classificadores com métricas de desempenho.

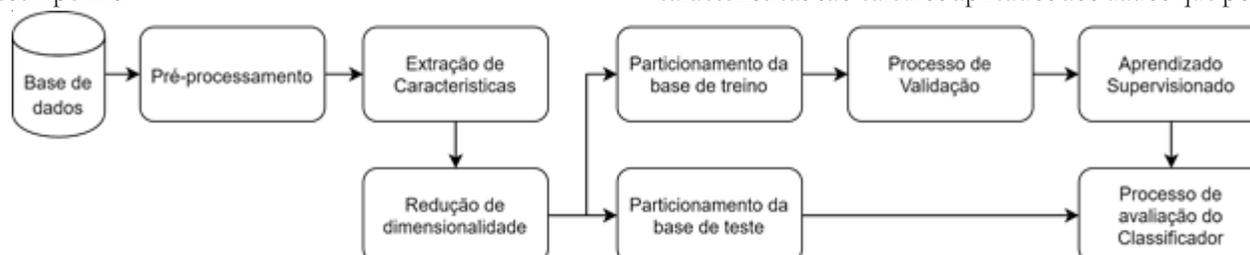


Figura 2 - Fluxo de etapas desenvolvidas no método de aprendizado supervisionado.

## Base de Dados

A base de dados utilizada para detecção de estresse foi a *Stress Recognition in Automobile Drivers*<sup>(12)</sup>, a base de dados contém 18 gravações de bio-sinais capturados por dispositivos vestíveis a partir de voluntários saudáveis dirigindo um automóvel em uma rota predefinida nas imediações da cidade de Boston, Massachusetts (EUA). A rota inclui ruas dentro da cidade, rodovias na autoestrada e um período de repouso, no qual é definida uma leitura base para o reconhecimento automático de estresse. Os bio-sinais foram gravados a uma frequência de 15,5 Hz e abrangem sinais de ECG, eletromiografia (EMG), GSR do pé, GSR da mão e respiração (RESP).

Como os sinais de cada voluntário não são diretamente rotulados em picos de estresse ou não estresse, os sinais do sensor GSR do pé foram utilizados para determinar esses rótulos<sup>1</sup>. Pesquisas têm demonstrado que o aumento do nível de estresse está diretamente relacionado ao aparecimento de suor e diminuição da resistência da pele, o que pode ser facilmente captado pelo sensor GSR<sup>(13)</sup>. Seguindo a mesma estratégia aplicada por Christopher Ottesen<sup>(9)</sup>, o valor da média de GSR de cada usuário é utilizado como ponto de corte para determinar o estado de estresse. Qualquer valor acima da média é considerado como estressado e qualquer valor abaixo é considerado como não-estressado.

## Pré-processamento

Nesta etapa, os dados são formatados e preparados para o processo de extração de características. Sinais do ECG foram tratados utilizando os filtros *Butterworth* passa-baixa<sup>(14)</sup> e *Peak Enhancement*<sup>(15)</sup>. O primeiro filtro retira ruídos de alta frequência dos sinais (5 Hz), enquanto o segundo filtro realça os picos e vales do complexo QRS. Na sequência, o conjunto de dados é segmentado em amostras individuais a partir da detecção do complexo QRS dos sinais ECG, o que é feito a partir da aplicação do método de Tompkins<sup>(16)</sup>. As implementações dos filtros e do método de segmentação estão disponíveis publicamente na biblioteca *heartpy*<sup>(17)</sup>.

## Extração de características

A etapa de extração de características tem como finalidade transformar os dados brutos (segmentos do sinal ECG) em dados representativos capazes de definir bem os padrões existentes nas ondas, possibilitando a discriminação em classes na etapa de classificação. Para isto, 14 características são geradas em dois domínios<sup>(18)</sup>: domínio do tempo e domínio da frequência. Essas características são cálculos aplicados aos dados que podem

<sup>1</sup>Devido a ruídos causados pelas movimentações da mão, o sensor GSR da mão não foi selecionado.

ser utilizados para identificar as diferentes propriedades do sinal, seus padrões e tendências. Os quadros 1 e 2 descrevem, respectivamente, as medidas utilizadas neste trabalho para cada domínio.

As características do domínio do tempo são baseadas principalmente em cálculos estatísticos entre os intervalos RR. Essas medidas fornecem informações sobre a distribuição da série temporal completa ou entre intervalos de tempo, como a média de todos os intervalos, o desvio padrão e entre outros.

As características do domínio da frequência são derivadas a partir do periodograma de Lomb-Scaglie, uma variante da transformada de Fourier, descrito na Equação 1. Esse algoritmo é bastante conhecido na detecção e caracterização periódica de séries temporais com amostras irregulares<sup>(19)</sup>, que é o caso dos intervalos RR.

$$P(f) = \frac{A^2}{2} \left( \sum_n g_n \cos(2\pi f[t_n - \tau]) \right)^2 + \frac{B^2}{2} \left( \sum_n g_n \sin(2\pi f[t_n - \tau]) \right)^2 \quad (1)$$

### Redução de dimensionalidade

Nesta etapa, os dados das características extraídas são submetidos à redução de dimensionalidade aplicando a Análise de Componentes Principais (*Principal Component Analysis* - PCA)<sup>(20)</sup>. O PCA é um procedimento estatístico que transforma ortogonalmente as  $n$  coordenadas originais de um conjunto de dados em um novo conjunto de  $n$  coordenadas chamadas componentes principais. Manter apenas os primeiros  $m < n$  componentes reduz a dimensionalidade dos dados, ao mesmo tempo que retém a maior parte das informações. Primeiro, os dados são normalizados para remover qualquer problema com escala e valores discrepantes. Em seguida, a matriz de covariância é calculada a partir dos dados normalizados. A partir da matriz de covariância são calculados os elementos de autovalores e autovetores para identificar os principais componentes, que podem ser utilizados como novas características construídas a partir das

combinações lineares das características iniciais. Além disso, como o ganho de informações se concentra nos primeiros componentes, há a possibilidade de retirar algumas dessas novas características sem uma perda significativa sobre o padrão dos dados, o principal intuito da técnica de redução<sup>(21)</sup>. A implementação do PCA está disponível na biblioteca aberta do Scikit-Learn<sup>(22)</sup>.

### Algoritmos de classificação, particionamento e validação

Os algoritmos de aprendizagem de máquina supervisionados aplicados para detecção de estresse foram: *Naive Bayes* (NB), *Decision Tree* (DT), *K-Nearest Neighbors* (KNN) e *Random Forest* (RF). A escolha dos algoritmos levou em consideração as diferentes abordagens teóricas na construção de cada um, como

probabilidade (*Naive Bayes*), representação do conhecimento (*Decision Tree*), conjuntos de preditores (*Random Forest*) e cálculos de similaridade (KNN).

Cada modelo possui hiperparâmetros que permitem adaptar o comportamento do algoritmo ao conjunto de dados específico do problema, por exemplo, o KNN possui o número de vizinhos e RF o número de estimadores do conjunto. Da mesma forma, PCA também possui hiperparâmetros na sua definição. A escolha do número de componentes depende principalmente da natureza dos dados, e pode piorar ou melhorar o aprendizado dos modelos se definido de forma aleatória.

A combinação das técnicas *K-fold cross validation* e *grid search* foi empregada para definir os melhores hiperparâmetros de cada algoritmo. A base foi dividida em 5 partes (*5-fold cross validation*), sendo uma parte para validação, outra para teste e o restante para treino. A

**Quadro 1** - Características utilizadas no domínio do tempo.

Característica	Abreviação	Unidades
Desvio padrão de todos os intervalos sinusais normais (NN).	SDNN	msec
Desvio padrão das médias dos intervalos NN em todos os segmentos de 5 minutos de toda a gravação.	SDANN	msec
Raiz quadrada da média dos quadrados das diferenças entre os intervalos NN adjacentes.	RMSD	msec
Média dos desvios padrão dos intervalos NN em todos os segmentos de 5 minutos de toda a gravação.	SDNN Index	msec
Desvio padrão das diferenças entre intervalos NN adjacentes.	SDSD	msec
Número de pares de intervalos NN adjacentes que diferem em mais de 50 ms.	NN50 count	msec
Porcentagem de diferenças entre intervalos NN adjacentes que são maiores do que 50 ms.	pNN50	%

**Quadro 2** - Características utilizadas no domínio da frequência.

Característica	Abreviação	Unidades
Qualquer frequência do HRV deve estar entre 0.000 - 0.500.	HRV	Hz
Qualquer frequência com poder espectral entre 00.000 - 0.003.	ULF	Hz
Qualquer frequência com poder espectral entre 0.003 - 0.040.	VLF	Hz
Qualquer frequência com poder espectral entre 0.040 - 0.150.	LF	Hz
Qualquer frequência com poder espectral entre 0.150 - 0.400.	HF	Hz
Qualquer frequência com poder espectral entre 0.400 - 0.500.	VHF	Hz
Divisão da frequência baixa pela frequência alta.	LF/HF	Hz

**Tabela 3** – Resultados de desempenho dos classificadores de aprendizagem de máquina, com e sem a aplicação de redução de dimensionalidade.

Método	Resultados sem PCA				Resultados com PCA			
	AC	F1	PR	SE	AC	F1	PR	SE
KNN	0.78	0.70	0.62	0.79	0.84	0.85	0.87	0.83
Naive Bayes	0.70	0.71	0.70	0.71	0.75	0.64	0.56	0.75
Random forest	0.90	0.91	0.87	0.93	0.89	0.90	0.86	0.90
Decision tree	0.86	0.87	0.87	0.85	0.86	0.86	0.87	0.86

métrica utilizada para esta seleção considerou a acurácia dos classificadores com os hiperparâmetros testados, ou seja, os parâmetros dos modelos que apresentaram melhor acurácia foram selecionados. Feita a variação dos hiperparâmetros, é verificado que o melhor número de componentes para os classificadores NB, AD, KNN e RF foi 11, 10, 7, e 12, respectivamente. Nos experimentos, são realizados testes para definir os hiperparâmetros de KNN e RF, mais especificamente o número de vizinhos de KNN encontrado é de 1 e o número estimadores de RF é 30.

Após a iteração na base de validação, é feita a avaliação dos modelos com a melhor combinação do número de componentes e hiperparâmetros na base de teste, onde são obtidos os valores das métricas de avaliação. O resultado de cada métrica representa a média aritmética de todas as partições de teste, uma vez que o método de validação cruzada faz a troca de todos os conjuntos entre treino, teste e validação, utilizando toda a base no aprendizado.

### Métricas de Avaliação

Para avaliar o desempenho dos classificadores de estresse, são utilizadas as seguintes métricas: acurácia ( $AC$ ), precisão ( $PR$ ), sensibilidade ( $SE$ ) e F1-score ( $F1$ ), representadas pelas equações (2), (3), (4) e (5) respectivamente. Para o cálculo dessas métricas são considerados os números de falsos positivos (FP), verdadeiros positivos (TP), falsos negativos (FN) e verdadeiros negativos (TN).

$$AC = \frac{TP+TN}{TN+TP+FP+FN} \quad (2) \quad PR = \frac{TP}{TP+FP} \quad (3) \quad SE = \frac{TP}{TP+FN} \quad (4) \quad F1 = 2 * \frac{SE * PR}{SE + PR} \quad (5)$$

A acurácia diz respeito à proporção de casos que foram corretamente previstos em relação a todas as predições, tanto negativas quanto positivas. A precisão verifica a proporção de casos positivos que foram corretamente previstos em relação a todos os verdadeiros positivos e falsos negativos. A sensibilidade diz respeito à proporção de casos positivos que foram identificados corretamente. O F1 mostra a média entre precisão e sensibilidade.

## RESULTADOS

A Tabela 3 apresenta os resultados obtidos da análise comparativa entre os diferentes algoritmos de classificação para detecção de estresse, com e sem a aplicação de redução de dimensionalidade. Para o grupo de classificadores que não aplicaram o PCA, o algoritmo *Random Forest* mostra 91% de F1, o melhor entre os demais

classificadores do grupo. Para o grupo de classificadores que aplicaram o PCA, *Random Forest* também obteve o melhor desempenho, mas com uma queda de 1% no F1 em relação ao desempenho obtido sem a aplicação do PCA, provando que mesmo com a redução do conjunto de características, o modelo ainda conseguiu ter um aprendizado eficiente sobre os dados.

Para o classificador KNN, a redução de dimensionalidade produziu uma melhora no desempenho geral, com um melhor ganho de 25% para a métrica de precisão, o que é ótimo para modelos envolvendo saúde, já que a confiabilidade do modelo em relação à classe positiva (estressado) é maior, ou seja, se o modelo diz que você está estressado você tem grandes chances de realmente estar.

O *Naive Bayes* apesar de ter apresentado melhora na acurácia e sensibilidade com a utilização do PCA, demonstrou uma queda no F1 e precisão. Esse fenômeno é ocasionado pela definição dos componentes mais significativos, o qual, nesse caso, priorizou uma componente que representa mais fielmente dados da classe negativa (não estressado).

Após uma análise da tabela, percebe-se que a utilização de técnicas de redução de dimensionalidade dos dados, em geral, não ocasionou nenhum tipo de perda significativa no aprendizado dos modelos. Logo, mesmo que a aplicação da técnica não resulte em uma melhora representativa na acurácia, precisão e F1 dos modelos, a mesma continua sendo persistente ao diminuir o poder computacional necessário para realizar o aprendizado, uma

vez que o método consegue reduzir o número de características sem perder informação sobre o conjunto. Esse ponto em questão aproxima mais ainda o uso desses modelos em dispositivos vestíveis, dado que as restrições de recursos como espaço de armazenamento em memória e custo de processamento estão entre os principais problemas enfrentados para embarcar os modelos de aprendizagem de máquina nesses dispositivos.

## CONCLUSÃO

Em geral, os modelos de aprendizagem de máquina clássicos com PCA conseguiram identificar o estresse com valores bastante competitivos em relação a outros métodos da literatura que não utilizam o tratamento dimensional, provando que o uso da técnica é eficaz ao manter as informações significativas e diminuir o tempo

de processamento dos algoritmos. Esses modelos podem auxiliar pacientes no tratamento de estresse ao fazerem previsões sobre a saúde do usuário a partir de biossinais captados por sensores embutidos em dispositivos vestíveis, avisando-os sobre qualquer desnível do seu estado normal. Como trabalhos futuros, seria interessante trocar a metodologia do problema para a classificação multi-classe, isto é, além de verificar se o usuário está estressado ou não, definir o nível de estresse naquele exato momento. Como os dispositivos vestíveis provêm uma quantidade massiva de dados a cada segundo, também há a possibilidade da aplicação de redes neurais profundas

para o problema, dispensando a necessidade de uma etapa de geração de características.

## AGRADECIMENTOS

Esta pesquisa foi financiada pela Samsung Eletrônica da Amazônia Ltda., realizada no âmbito do Projeto Samsung-UFAM de Ensino e Pesquisa (SUPER), conforme previsto no Artigo 48 do Decreto nº 6.008 / 2006 (SUFRAMA), 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.

## REFERÊNCIAS

- Hassard J, Teoh K, Cox T, Dewe P, Cosmar M, Gründler R, Flemming D, Cosemans B, Van den Broek K. Calculating the cost of work-related stress and psychosocial risks. Luxembourg: Publications Office of the European Union; 2014. <http://doi.org/10.2802/20493>.
- Russell E, Koren G, Rieder M, Van Uum S. Hair cortisol as a biological marker of chronic stress: Current status, future directions and unanswered questions [revisão]. *Psychoneuroendocrinology*; 2012; 37(5):589–601.
- Hellhammer DH, Wüst S, Kudielka BM. Salivary cortisol as a biomarker in stress research. *Psychoneuroendocrinology*; 2009; 34(2):163–71.
- Picard RW. *Affective Computing*. 1ª edição. Cambridge: MIT Press; 2000.
- Dziedzicki A, Kaklauskas A, Bucinskas V. Human Emotion Recognition: Review of Sensors and Methods [revisão]. *Sensors (Basel)*; 2020;20(3):592.
- Taelman J, Vandeput S, Spaepen A, Van Huffel S. Influence of Mental Stress on Heart Rate and Heart Rate Variability. *Proceedings of 4th European conference of the international federation for medical and biological engineering*; Berlim, Heidelberg:Springer; 2009. p. 1366-1369.
- Sannino G, Giuseppe DP. A deep learning approach for ECG-based heartbeat classification for arrhythmia detection. *Future Generation Computer Systems* 86; 2018: 86(9):446-455.
- Liu D, Ulrich M. Listen to Your Heart: Stress Prediction Using Consumer Heart Rate Sensors [Internet]. 2014 [citado em 29 jan. 2021]; Disponível em : <http://cs229.stanford.edu/proj2013/LiuUlrich-ListenToYourHeart-StressPredictionUsingConsumerHeartRateSensors.pdf>.
- Ottesen C. Investigating heart rate variability: a machine learning approach [dissertação]. London: Queen Mary University of London; 2017.
- Cho Y, Bianchi-Berthouze N, Julier S. DeepBreath: Deep learning of breathing patterns for automatic stress recognition using low-cost thermal imaging in unconstrained settings. *Seventh International Conference on Affective Computing and Intelligent Interaction*; 2017 Oct 23-26; San Antonio, TX.
- Schmidt P, Dürichen R, Reiss A, Van Laerhoven K, Plötz T. Multi-target affect detection in the wild. *Proceedings of the 23rd International Symposium on Wearable Computers*; New York, NY, USA: Association for Computing Machinery; 2019. p.211-219.
- Healey J. *Wearable and automotive systems for affect recognition from physiology* [Ph.D]. Massachusetts, USA: Massachusetts Institute of Technology; 2000.
- Villarejo M, Zapirain B, Zorrilla A. A Stress Sensor Based on Galvanic Skin Response (GSR) Controlled by ZigBee. *Sensors*. 2012;12(5):6075-6101.
- Butterworth S. On the Theory of Filter Amplifiers. *Wireless Engineer*. 1930; 7(6):536-541.
- Boashash B, Mesbah M. Signal Enhancement by Time-Frequency Peak Filtering. *IEEE Transactions on Signal Processing*. 2004; 52(4):929-937.
- Lee J, Jeong K, Yoon J, Lee M. A simple real-time QRS detection algorithm. *Proceedings of 18th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. 1996 31 Oct.-3 Nov. Amsterdam: IEEE; 2002.
- Van Gent P, Farah H, Nes N, van Arem B. Heart Rate Analysis for Human Factors: Development and Validation of an Open Source Toolkit for Noisy Naturalistic Heart Rate Data. In *Proceedings of the 6th HUMANIST Conference*; 2018 June; Lyon; 2018. p. 173-178.
- Hjortskov N, Rissén D, Blangsted AK, Fallentin N, Lundberg U, Søgaard K. The effect of mental stress on heart rate variability and blood pressure during computer work. *European journal of applied physiology*. 2004 Jun;92(1-2):84-9.
- VanderPlas J. Understanding the Lomb–Scargle Periodogram. *The Astrophysical Journal Supplement Series*. 2018 maio 11; 236(1):16.
- Jolliffe IT. In: *International Encyclopedia of Statistical Science*. Principal Component Analysis. 2ª edição. New York: Springer-Verlag; 2011.
- Carreira-Perpiñán M. *A Review of Dimension Reduction Techniques* [relatório técnico-científico]. Sheffield: University of Sheffield, Department of Computer Science. 1997 jan. 27. Tech Report CS-96-09.
- Varoquaux G, Buitinck L, Louppe G, Grisel O, Pedregosa F, Mueller A. *Scikit-learn*. *GetMobile: Mobile Computing and Communications*. 2015;19(1):29-33.