

Identificação Biométrica A Partir De ECG De Derivação Única Utilizando Perceptron Multicamadas e Transformada de Stockwell

A. Barbosa* P.P. Rebouças Filho**

* Instituto Federal de Educação, Ciência e Tecnologia do Ceará, CE,
(e-mail: amaury.barbosa03@aluno.ifce.edu.br).

** Instituto Federal de Educação, Ciência e Tecnologia do Ceará, CE,
(e-mail: pedrosarf@ifce.edu.br)

Abstract: Nowadays digital security systems are ordinary tools on a day by day, going by biometrics such as digital and facial recognition to the traditional users and passwords methods. Noticing the popularization of wearables, this paper proposes a biometric recognition method using ECG signals that can be obtained by the current technology of smartwatches, that differ from traditional 12-lead ECGs. First it was used a blind segmentation method to the electrocardiogram signal, which was treated with a Butterworth filter to attenuate signal noise. It was applied the Stockwell transform to the signal, shifting it from time domain to time-frequency domain, therefore obtaining the unidimensional complex trajectories of each sample as the MLP's input. The proposed MLP model were able to obtain an 95,96% of accuracy using a data window of 500 discrete samples, showing its ability to set apart each subject signal.

Resumo: Atualmente os sistemas de segurança digitais são ferramentas comuns no dia a dia, desde o uso da biometria, como a digital e reconhecimento facial, até o uso tradicional de usuários e senhas. Observando a popularização dos *wearables*, esse artigo propõe um método de reconhecimento biométrico utilizando sinais de ECG que podem ser obtidos através da tecnologia atual dos *smartwatches*, que diferem dos ECG tradicionais de 12 derivações. Primeiramente foi utilizado o método de segmentação às cegas do sinal de eletrocardiograma, a qual foi tratado com um filtro Butterworth para atenuar os ruídos do sinal. Foi aplicado ao sinal a transformada de Stockwell, transformando-o do domínio do tempo para o domínio da frequência, a qual foram utilizadas as trajetórias complexas unidimensionais de cada amostra como entrada da MLP. O modelo proposto da MLP conseguiu os resultados de precisão de 95,96% utilizando uma janela de dados de 500 amostras discretas, demonstrando a capacidade de diferenciar os sinais de cada indivíduo.

Keywords: ECG; Biometric Identification; Multilayer Perceptron; Neural Networks.

Palavras-chaves: ECG; Identificação Biométrica; Multilayer Perceptron; Redes Neurais.

1. INTRODUÇÃO

Nas últimas décadas, o uso de dados biométricos para a identificação de pessoas tem se tornado cada vez mais frequente. Eles podem ser obtidos de diversas fontes: DNA, orelha, rosto, veias da mão, digital, íris, voz, entre outros (Sufi et al., 2010). Recentemente há crescido o número de estudos propondo identificação de pessoas utilizando a morfologia do coração, considerando sua singularidade para cada pessoa.

Em paralelo, também vem se popularizando os *wearables*, dispositivos que podem ser vestidos, como relógios e óculos inteligentes. Novos modelos de *smartwatches* estão sendo fabricados com sensores de eletrocardiograma (ECG) de uma derivação, abrindo aplicativos nativos que obtêm o ECG e que classificam irregularidades obtidas. Tais dispositivos, em lojas de varejo, indicam uma menor restrição na obtenção dos sinais de eletrocardiograma, abrindo mais uma opção de identificação biométrica em larga escala,

como atualmente se encontram as identificações por digital e rosto.

Os métodos de identificação por sinais biométricos se dão popularmente por reconhecimento de padrão (PR). Recentemente, as redes neurais artificiais (ANN) vem sendo amplamente utilizada na literatura quando aplicadas a PR. As ANN referem-se a modelo de dados estatísticos não-lineares que replicam o funcionamento das redes neurais biológicas (Abiodun et al., 2019), onde camadas de neurônios artificiais são ativados com o peso a eles admitido, criando uma resposta em suas saídas ao receberem um sinal da entrada. As redes neurais são excelentes identificadores de padrões e tendências em sistemas complexos com numerosos parâmetros de entrada (Abiodun et al., 2018).

Ainda que diversos sistemas de segurança biométrica estejam disponíveis para o grande público de forma solidificada, é importante o estudo e desenvolvimento de novos métodos de aquisição de dados, processamento de sinais e

modelos de reconhecimento, considerando que muitos dos atuais métodos mais difundidos podem ser impeditivos a certos grupos populacionais por diversos motivos como: membros amputados, condições genéticas, acesso limitado de processamento computacional, entre outros. Assim, o objetivo desse estudo é criar um modelo de perceptron de multicamadas (MLP) capaz de diferenciar com acurácia os sinais de eletrocardiograma de pessoas distintas com diferentes amostras de ECG de uma derivação.

Diversos outros estudos vem sendo desenvolvidos sobre o tema nos últimos anos, como o artigo proposto por Barros et al. (2020), que investigou passos para melhorar os resultados de identificação biométrica por ECG ao serem trabalhados com um grande numero populacional de alvos, utilizando técnicas de *data augmentation* e remoção de *outliers*, e utilizando um modelo de *Random Forest* (RF) para classificar os dados. O modelo proposto pelos autores obteve uma precisão de 78% a 92% em amostras de 1500 pessoas e 90% a 95% em amostras de 100 pessoas.

Zhao et al. (2018) propuseram um sistema biométrico de autenticação que utiliza sinais de ECG segmentados cegamente, então performaram uma transformada-s generalizada e utilizaram um modelo de Rede Neural Convolutacional (CNN) para extrair as *features* e classificar os dados. Também utilizaram banco de dados de pessoas com diversas características no coração, atingindo uma acurácia de 99% em dados em condições normais, 98% em indivíduos com fibrilação atrial e 99% em dados com ruído.

Zhang et al. (2017) propuseram um modelo que utilizasse segmentação de ECG às cegas, transformado para o domínio tempo-frequência através da transformada de Wavelet, e classificada por uma 1D-CNN para aprender as características intrínsecas da entrada. O modelo foi treinando em banco de dados de corações saudáveis e não-saudáveis, e atingiu uma acurácia de identificação de 93,5%.

2. MATERIAIS E MÉTODOS

2.1 Banco de Dados

Os dados usados para treinar o modelo foram os eletrocardiogramas de derivação única do banco de dados ECG-ID Database, que contem 310 ECG de 90 voluntários diferentes, sendo 44 pessoas de sexo biológico masculino e 46 feminino com idade entre 13 e 75 anos. O numero de ECGs variam para cada pessoa, onde pessoas com mais registros tiveram os dados coletados periodicamente durante 6 meses. Os dados brutos possuem ruídos de baixa e alta frequência, por isso o banco de dados inclui também os dados filtrados (Nermiko and Lugovaya, 2005).

A escolha desse banco de dados se deu pelo objetivo de trabalhar com ECG de derivação única, que podem obtidas através de equipamentos portáteis como os *smartwatches*. Além de existirem diversos registros para uma mesma pessoa em dias diferentes, possibilitando uma melhor generalização do modelo.

2.2 Especificações do Computador

As especificações do computador são extremamente importantes na criação de redes neurais, pois como todos

os cálculos são processados pela CPU ou pela GPU, os resultados de performance de treinamento e teste estão diretamente relacionados a esses componentes. Esse trabalho foi desenvolvido com as seguintes especificações de hardware:

- Modelo do computador: Lenovo Ideapad S145;
- Processador: Intel Core i5-8265U @1.60GHz;
- RAM instalada: 8GB;
- Placa de Vídeo: GeForce MX110 2GB;
- Sistema Operacional: Windows 11.

2.3 Pré-processamento

Considerando a possibilidade de serem obtidos ECGs brutos do banco de dados ECG-ID, decidiu-se utilizá-los ao invés dos dados já filtrados e implementar no próprio algoritmo de pré-processamento um filtro Butterworth para baixas e altas frequências para o tratamento dos dados ruidosos. Isso foi feito tendo em vista uma aplicação prática em que o sinal recém adquirido precisaria ser tratado antes de ser classificado pela MLP. Os parâmetros do filtro podem ser encontrados na Tabela 1 e os resultados na Figura 1.

Tabela 1. Parâmetros do Filtro Butterworth.

Parâmetros	Valores
Frequência de corte alta	0.3Hz
Frequência de corte baixa	50Hz
Frequência da rede	60Hz
Ordem	5

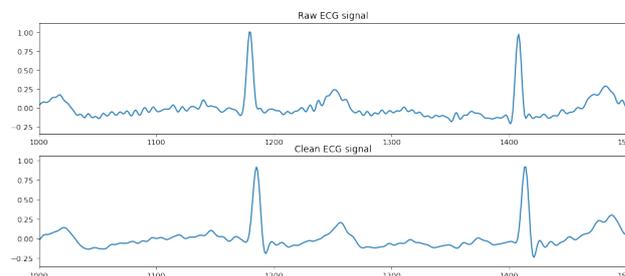


Figura 1. ECG com ruído e ECG tratado com filtro Butterworth

Após ter os dados tratados, o próximo passo do pré-processamento é a segmentação às cegas do ECG, tendo em meta evitar as complexidades de uma segmentação por métodos fiduciais. Essa segmentação é realizada de maneira randômica, em uma janela de 500 amostras discretas do sinal, para todos os registros de ECG no banco de dados. Esse tipo de segmentação proporciona que aleatoriedade de amplitudes, frequência do batimento cardíaco e localização da onda no eixo do tempo generalizem mais o modelo durante o treinamento e testes, considerando a variabilidade desse sinal no mesmo indivíduo.

2.4 Espectro Local da Transformada-S

Em trabalhos que se faz necessário transformar sinais do domínio do tempo para a da frequência durante a FE é comum a utilização da transformada de Fourier de curto termo (STFT) e da transformada de *wavelet* (WT) quando é necessário para o domínio tempo-frequência. A

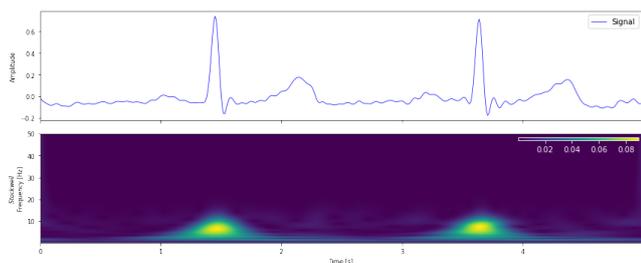


Figura 2. Transformada de Stockwell de um ECG pré-processado

transformada de Stockwell (ST) é justamente um modelo híbrido entre essas duas transformadas, capaz de descrever sinais tanto no domínio da frequência quanto no do tempo, transformando um sinal unidimensional em uma função bidimensional com as variáveis tempo e frequência $T_x(t, f)$ (Moukadem et al., 2014).

Uma das características da ST é a presença da janela gaussiana, responsável por alterar a resolução da transformada, tendo a frequência como uma de suas dependências, como pode ser observado na Equação 2. Ela permite que uma resolução de frequência menos larga para valores de alta frequência e mais larga para valores de baixa frequência (Beuter and Oleskovicz, 2019). Quando essa janela é normalizada para se obter apenas uma unidade de área (Equação 3), a média da amplitude da ST se torna o mesmo da transformada de Fourier, possibilitando assim que ela possa ser invertida.

Quando obtido os eletrocardiogramas pré-processados no domínio do tempo, foi aplicado a função da transformada de Stockwell utilizando a biblioteca *eqsig*, que por definição utiliza uma janela gaussiana normalizada. O gráfico da transformada nos eixos tempo (x) e frequência (y) pode ser observado na Figura 2.

Com a transformada-ST se é possível localizar as partes reais e as partes imaginárias do espectro no domínio tempo-frequência. A transformada resulta a matriz da Equação 1 com números complexos, onde m é a quantidade de amostras do sinal e n é igual $m/2$. Dessa forma, é possível determinar que cada coluna da matriz corresponde a um espectro local. Como o período da janela de segmentação escolhido foi de 500 amostras discretas, a dimensão da matriz retornada para o modelo será de $ST(250, 500)$.

$$ST = \begin{bmatrix} a_{1,1} + b_{1,1}i & \cdots & a_{1,m} + b_{1,m}i \\ a_{2,1} + b_{2,1}i & \cdots & a_{1,m} + b_{1,m}i \\ \vdots & \vdots & \vdots \\ a_{n,1} + b_{n,1}i & \cdots & a_{1,m} + b_{1,m}i \end{bmatrix}_{n \times m} \quad (1)$$

Cada espectro local, quando plotado no eixo real (x) e imaginário (y), retorna a trajetória tomada pelo ECG no domínio complexo, como pode ser visto no diagrama da Figura 3. Cada coluna da matriz apresentada no diagrama representa um espectro local em uma determinada amostra do ECG no domínio do tempo, mais especificamente, da esquerda para direita, as amostras 0, 26 e 92 do primeiro registro da *Pessoa 01* do banco de dados. As coordenadas dessas trajetórias são então transformadas em vetores

unidimensionais de valores reais, uma vez que as redes neurais não conseguem processar números complexos.

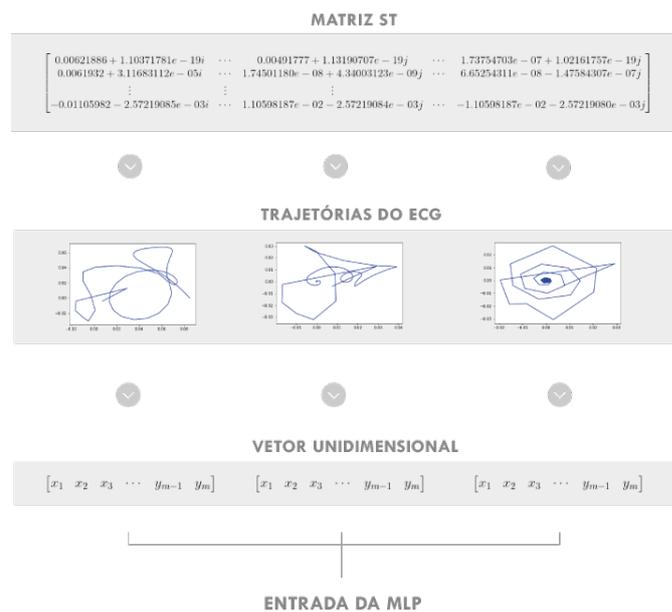


Figura 3. Diagrama do processo de aquisição das trajetórias do ECG

$$w(t, f) = \frac{1}{\sigma(f)\sqrt{2\pi}} e^{-\frac{t}{2\sigma f^2}} ; \sigma(f) = \frac{1}{|f|} \quad (2)$$

$$\int_{-\infty}^{\infty} w(t, f) dt = 1 \quad (3)$$

2.5 Arquitetura da Multi-layer Perceptron

O multi-layer perceptron (MLP) é uma das arquiteturas de redes neurais artificiais do tipo profunda, considerando a existência de mais de uma camada oculta no modelo. Uma de suas características é a utilização do perceptron, uma unidade em que por definição só consegue aprender funções linearmente separáveis. A Equação 4 representa matematicamente o funcionamento de um perceptron, onde i : camada da rede; z : entrada do perceptron; w : limite ou bias; x : dados de entrada; y : saída, $f(z)$: função de ativação.

$$y = f(z); z = \sum_{i=0}^n w_i x_i \quad (4)$$

Contudo, de acordo com Taud and Mas (2018), os perceptron, ou apenas uma camada deles, não são o suficiente para resolver problemas que não são possíveis separar linearmente, fazendo-se necessário adicionar mais de uma camada sucessivamente, criando-se assim uma MLP, onde temos que os dados de entradas x_i das camadas ocultas será o resultado da saída da camada anterior y_{i-1} . Apesar de ser chamada multi-layer perceptron, as unidades utilizadas nessa arquitetura não utilizam perceptrons e sim unidades com funções de ativação não lineares como a **sigmoide**, **ReLU** e **tangente hiperbólica**, que retornam valores entre 0 e 1, 0 e $+\infty$, e -1 e 1 respectivamente.

Após extrair todas as trajetórias da transformada de Stockwell vetorizadas unidimensionalmente, foi criado o *dataset* de treino, um conjunto de dados usados principalmente em ciência de dados e aprendizado de máquina para fins analíticos, com o propósito de armazenar todas as informações necessárias para treinar a MLP, seguindo o padrão da Tabela 2. Como o *dataset* apresenta uma estrutura tabulada, temos que cada espectro local dos registros de todas as pessoas no banco de dados ECG-ID estão distribuídas em linhas distintas e que o vetor das trajetórias mais o vetor da variável *dummy*, que transforma dados categóricos em dados binários para a distinção de amostras, onde normalmente 1 apresenta um atributo qualitativo e 0 a ausência (EKONG et al., 2021).

O *dataset* criado para o trabalho atingiu grandes dimensões devido a quantidade de amostras discretas segmentadas e o número de registros de eletrocardiogramas, chegando a conter 154380 linhas e 590 colunas para o treinamento da MLP.

O próximo passo tomado após o *dataset* foi criar a arquitetura da multi-layer perceptron. Devido as características estocásticas das redes neurais, os parâmetros foram adotados por tentativa e erro, contudo, seguindo a lógica teórica. Como os sinais de ECG segmentados são não-lineares, foi assumido que a rede neural deveria conter pelo menos mais de duas camadas ocultas. Além disso, foi escolhido utilizar o ReLU como função de ativação da camada oculta e a *Softmax* para a camada de saída, visto suas vantagens em categorizar múltiplas classes. A arquitetura escolhida está representada na Figura 4, com as seguintes características:

- 1 camada de entrada com **500** unidades;
- 9 camadas ocultas com **424** unidades e função de ativação ReLU;
- 1 camada de saída com a quantidade **n** (pessoas no banco de dados) de unidades e função de ativação Softmax.

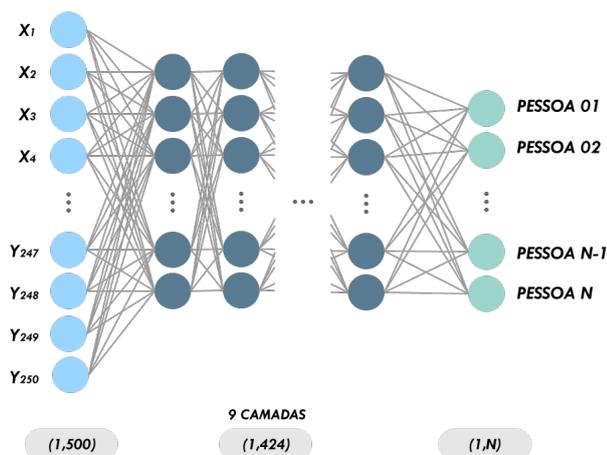


Figura 4. Multi-layer perceptron proposto

2.6 Treinamento e Teste da MLP

Considerando a quantidade e complexidade dos cálculos realizados durante o treinamento de uma rede neural, foi escolhido utilizar a GPU dedicada do computador para realizar esse processo devido a sua capacidade de processar dados de forma mais rápida em relação a CPU. Dito isso, foi implementado o uso do *framework* **CUDA**, desenvolvido para placas de vídeo da NVIDIA, que possibilita a programar na GPU.

O treinamento do modelo foi realizado utilizando a técnica do *mini-batch gradient descent*, que se diferencia por conseguir treinar o modelo mais rápido devido a aplicação dos *batches*.

Como o treinamento da MLP é realizada pela GPU, o tamanho do *batch* escolhido foi de 512, considerando a característica dos núcleos físicos da GPU de processamento com múltiplos de dois. Com esse tamanho, o gradiente de descida é realizado a cada 0,19% do *dataset*. Considerando a quantidade escolhida de 1500 *epochs* para o treinamento, os mesmos dados do *dataset* passam 4 vezes novamente na camada de entrada para a estimação dos pesos durante a *backpropagation*.

A função de custo utilizada para treinar o modelo foi a *binary crossentropy* e o foi aplicado o otimizador de Adam, um algoritmo de otimização de funções estocásticas objetivas baseado em gradiente feito para ser aplicado em problemas com grandes *datasets*, combinando os métodos de otimização AdaGrad e RMSProp para ser mais eficiente computacionalmente e requerer menos memória de processamento (Kingma and Ba, 2015).

Para testar o modelo foi criado um novo *dataset* com todos os registros em uma nova janela aleatória de 500 amostras para validação do modelo, habilitando a avaliação de *overfitting* do modelo ao comparar a curva de perda do treinamento e do teste. Além disso, um novo *dataset* com novas janelas amostrais foi utilizado para testar o modelo outra vez, calculando sua acurácia e foi criado a matriz de confusão para determinar como o modelo se comporta com falsos positivos e falsos negativos.

3. RESULTADOS

As métricas tomadas para medir o quanto o modelo é capaz de resolver o problema proposto foram: tempo de treinamento; tempo de teste; acurácia; curva de perda; matriz de confusão; e TRR, TAR, FRR e FAR.

3.1 Tempo de treinamento e teste

Considerando que o tempo de processamento varia de acordo com a configuração de cada computador, os valores obtidos para o tempo de treinamento e de teste correspondem ao resultados obtidos com as configurações de máquina descritas no Tópico 2.2.

A métrica utilizada para o treinamento é o tempo percorrido para treinar o ECG de uma pessoa. Como o modelo demorou aproximadamente 14,16 segundos em média para treinar 302 amostras de cada *epoch*, e cada pessoa possui um registro de 500 amostras, foi realizada uma estimativa de acordo com a Equação 5 de **23,45** segundos. Para o

Tabela 2. Modelo de informações contidas no *dataset*

Espectro Local	X_0	X_1	X_2	\dots	Y_{498}	Y_{499}	Pessoa 01	Pessoa 02	\dots	Pessoa 90
01	$X_{1,0}$	$X_{1,1}$	$X_{1,3}$	\vdots	$Y_{1,248}$	$Y_{1,249}$	1	0	\dots	0
02	$X_{2,0}$	$X_{2,1}$	$X_{2,3}$	\vdots	$Y_{2,248}$	$Y_{2,249}$	1	0	\dots	0
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\dots	\vdots
500	$X_{500,0}$	$X_{500,1}$	$X_{500,3}$	\vdots	$Y_{500,248}$	$Y_{500,249}$	1	0	\dots	0
01	$X_{1,0}$	$X_{1,1}$	$X_{1,3}$	\vdots	$Y_{1,248}$	$Y_{1,249}$	0	1	\dots	0
02	$X_{2,0}$	$X_{2,1}$	$X_{2,3}$	\vdots	$Y_{2,248}$	$Y_{2,249}$	0	1	\dots	0
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\dots	\vdots
500	$X_{500,0}$	$X_{500,1}$	$X_{500,3}$	\vdots	$Y_{500,248}$	$Y_{500,249}$	0	1	\dots	0
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\dots	\vdots
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\dots	\vdots

tempo de teste também foi medido o tempo por registro, no qual o modelo conseguiu estimar as classes de uma amostra em **0,5** segundos.

$$tempo\ de\ treinamento = \frac{(tempo\ por\ epoch) \cdot 500}{302} \quad (5)$$

3.2 Acurácia

Na Figura 5 é possível observar a curva de acurácia obtida pelo modelo proposto. Em 1500 interações de treinamento no *dataset* de treinamento foi observado que a acurácia tende a se estabilizar depois de aproximadamente 600 interações. Esse foi o melhor resultado obtido durante a fase de desenho da arquitetura da MLP. Tal resultado aponta que o modelo é capaz de solucionar o problema de identificação através de ECG de maneira confiável. As métricas obtidas podem ser encontradas na Tabela 4.

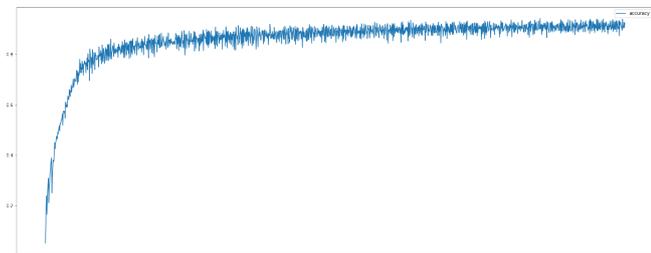


Figura 5. Curva de acurácia do modelo proposto

Tabela 3. Acurácia e perda do modelo proposto em 3 *datasets*

	<i>Dataset</i> de treinamento	<i>Dataset</i> de validação	<i>Dataset</i> de teste
Acurácia (%)	95,92	93,68	90,96
Perda (Loss) (%)	0,38	0,50	0,51
Tempo total de treinamento (h)	5,90	5,90	-

A curva de perda da Figura 6 também permite dizer que tendeu a se estabilizar perto de zero, como o esperado, e que a diferença de perdas entre os dados de treinamento e de validação não são grandes, mostrando que o modelo não apresentou *overfitting* ou *underfitting*, assim apresentando uma boa generalização do modelo.

3.3 Matriz de Confusão

A matriz de confusão normalizada (Figura 7) aponta que os dados de acurácia e perda fazem sentido, uma vez que

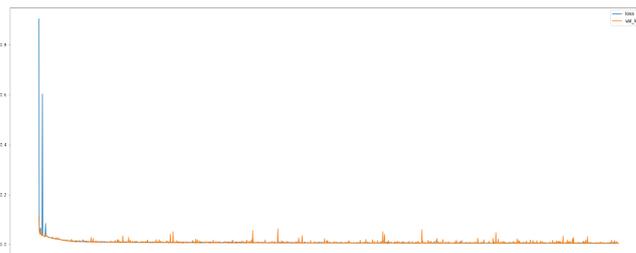


Figura 6. Curva de acurácia do modelo proposto

a diagonal do *plot* matricial mostra uma forte presença de verdadeiro e falso positivos, e poucos falso e verdadeiro negativos. Na Tabela 4 é possível verificar os resultados obtidos pelo modelo de taxa de verdadeiro positivo (TAR), taxa de verdadeiro negativo (FAR), taxa de falso positivo (TRR) e taxa de falso negativo (FRR).

Tabela 4. Acurácia e perda do modelo proposto em 3 *datasets*

	TRR	TAR	FRR	FAR
<i>Dataset</i> de treinamento (%)	99,95	93,95	6,04	0,04
<i>Dataset</i> de teste (%)	99,89	86,99	13,00	0,10



Figura 7. Matriz de confusão normalizada

Com os dados obtidos através da matriz de confusão, pode-se dizer que, para um sistema de identificação biométrica, o modelo proposto é capaz de determinar com alta precisão se a classe predita realmente é do ECG do indivíduo em específico, considerando as altas taxas de acerto de predição de verdadeiros e a relativamente baixa taxa de falsos. Além disso, a maioria dos indivíduos obtiveram

Tabela 5. Comparação do modelo proposto com o estado da arte.

Autores	Segmentação	Extração de Características	Classificador	Resultados
Modelo proposto	<i>Blind</i> (a cegas)	Nenhuma	MLP	Acc: 95,96%
Zhao et al. (2018)	<i>Blind</i> (a cegas)	Nenhuma	CNN	Acc: 96,63% (Db= ECG-ID)
Alduwaile and Islam (2021)	<i>Heartbeat</i> (batimento cardíaco)	<i>Entropy enhancement</i> (aumento de entropia)	GoogLeNet	Acc: 99,33% (Db= ECG-ID) Acc: 78% 92%
Barros et al. (2020)	<i>Blind</i> (a cegas)	Complexo QRS	<i>Random Forest</i>	(Entre 1500 pessoas) Acc: 90% 35% (Entre 100 pessoas) Acc: 91%
Rehman et al. (2018)	Não-funducial	Exclusão dos zeros da Transformada Wavelet	<i>Sum of Squared Difference</i>	Acc: 91% (Db= ECG-ID)
Hong et al. (2019)	<i>Heartbeat</i> (batimento cardíaco)	CNN	Softmax	Acc: 97,84%
Zhang et al. (2017)	<i>Blind</i> (a cegas)	Autocorrelação e seleção de componentes de uma transformada Wavelet	1D-CNN	Acc: 93,5%

altas taxas de acurácia, porém alguns poucos apresentaram taxas mais baixas. As razões para esse fenômeno não foram exploradas nesse estudo.

3.4 Comparação com Estado da Arte

O modelo proposto, quando comparado com outros modelos do estado da arte, atinge métricas de acurácia próximas aos de seus pares, demonstrando ser um abordagem ainda relevante e que produz resultados satisfatórios dentro da área de reconhecimento biométrico. Ele se distingue de outros trabalhos por explorar as características únicas que a transformada de Stockwell pode oferecer a sinais de eletrocardiograma e implementá-lo diretamente à entrada da rede neural, não passando por um processo de extração de características previamente. Uma vantagem do modelo proposto em relação aos outros trabalhos citados na Tabela 5 é o tempo de execução de predição.

Apesar do estudo ter sido efetuado com um poder de processamento mais tímido, a Multilayer Perceptron mostrou-se extremamente eficaz em relação ao tempo que leva para predizer quem o indivíduo sendo testado realmente é quem ele diz ser quando comparado com os classificadores utilizados por outros autores, como o de Zhao et al. (2018), que utiliza a mesma abordagem da transformada de Stockwell, porém classificando os dados com uma rede neural convolucional.

4. CONCLUSÃO

Os resultados obtidos nesse estudo apontam que o modelo foi capaz de identificar as amostras de eletrocardiograma de todas as pessoas dentro do *dataset*, obtendo uma performance de acurácia geral de 95,96%, demonstrando ser relevante para o reconhecimento biométrico utilizado ECG de derivação única.

O método de derivação às cegas mostrou-se também eficiente em segmentar os o eletrocardiograma no domínio do tempo, em janelas de 500 amostras, sem perder informações relevantes que acentuassem a individualidade de cada sinal, demonstrando inclusive que outras janelas de mesma dimensão segmentadas em posições aleatórias no ECG (*Dataset* de teste) apresentou a mesma capacidade de reconhecimento de indivíduos.

O modelo também não precisou fazer extrações de características da transformada de Stockwell, diminuindo assim a necessidade de algoritmos para o tratamento desses dados, reduzindo a complexidade da resolução do problema. Dessa forma, o modelo permite que as trajetórias da transformada possam ser utilizadas diretamente na entrada da MLP.

A arquitetura escolhida, utilizando o método da tentativa e erro, de 9 camadas ocultas contendo 424 unidades com função de ativação ReLU, apresentou ser capaz de modelar e generalizar o problema, além de executar com extrema rapidez suas predições de classes, demonstrando ser uma boa ferramenta para o reconhecimento biométrico utilizando ECG.

REFERÊNCIAS

- Abiodun, O.I., Jantan, A., Omolara, A.E., Dada, K.V., Mohamed, N.A.E., and Arshad, H. (2018). State-of-the-art in artificial neural network applications: A survey. *Heliyon*, 4(11), e00938. doi:10.1016/j.heliyon.2018.e00938. URL <https://doi.org/10.1016/j.heliyon.2018.e00938>.
- Abiodun, O.I., Jantan, A., Omolara, A.E., Dada, K.V., Umar, A.M., Linus, O.U., Arshad, H., Kazaure, A.A., Gana, U., and Kiru, M.U. (2019). Comprehensive Review of Artificial Neural Network Applications to Pattern Recognition. *IEEE Access*, 7(February 2017), 158820–158846. doi:10.1109/ACCESS.2019.2945545.
- Alduwaile, D.A. and Islam, M.S. (2021). Using convolutional neural network and a single heartbeat for eeg biometric recognition. *Entropy*, 23(6). doi:10.3390/e23060733.
- Barros, A., Resque, P., Almeida, J., Mota, R., Oliveira, H., Rosário, D., and Cerqueira, E. (2020). Data improvement model based on eeg biometric for user authentication and identification. *Sensors (Switzerland)*, 20(10). doi:10.3390/s20102920.
- Beuter, C. and Oleskovicz, M. (2019). S Transform:from main concepts to some power quality applications. *IET Signal Processing*, 14. doi:10.1049/iet-spr.2019.0042.
- EKONG, N., MOFFAT, I., USORO, A., and MATTHEW, I. (2021). A Comparative Study of the Impact of Dummy Variables on Regression Coefficients and Canonical Correlation Indices: An Empirical Perspective. *International Journal of Analysis and Applications*, 19(4), 576–586. doi:10.28924/2291-8639-19-2021-576.

- Hong, P.L., Hsiao, J.Y., Chung, C.H., Feng, Y.M., and Wu, S.C. (2019). ECG Biometric Recognition: Template-Free Approaches Based on Deep Learning. *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, 2633–2636. doi:10.1109/EMBC.2019.8856916.
- Kingma, D.P. and Ba, J.L. (2015). Adam: A method for stochastic optimization. *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*, 1–15.
- Moukadem, A., Ould Abdeslam, D., and Dieterlen, A. (2014). *Time-Frequency Domain for Segmentation and Classification of Non-stationary Signals: The Stockwell Transform Applied on Bio-signals and Electric Signals*. ISTE-WILEY.
- Nermiko, A. and Lugovaya, T. (2005). Biometric human identification based on electrocardiogram. In *XII-th Russian Conference on Mathematical Methods of Pattern Recognition*, 387–390. MAKS Press, Moscou. doi: <https://doi.org/10.13026/C2J01F>. URL <http://www.mmro.ru/files/2005-mmro-12.pdf>.
- Rehman, A., Saqib, N.A., Danial, S.M., and Ahmed, S.H. (2018). ECG based authentication for remote patient monitoring in IoT by wavelets and template matching. *Proceedings of the IEEE International Conference on Software Engineering and Service Sciences, ICSESS*, 2017-November, 91–94. doi:10.1109/ICSESS.2017.8342871.
- Sufi, F., Khalil, I., and Hu, J. (2010). ECG-Based Authentication. In *Handbook of Information and Communication Security*, chapter 17, 309–331. Springer Berlin Heidelberg, Berlin, Heidelberg. doi:10.1007/978-3-642-04117-4_17. URL http://link.springer.com/10.1007/978-3-642-04117-4_17.
- Taud, H. and Mas, J.F. (2018). Multilayer Perceptron (MLP) BT - Geomatic Approaches for Modeling Land Change Scenarios. 451–455. URL https://doi.org/10.1007/978-3-319-60801-3_27.
- Zhang, Q., Zhou, D., and Zeng, X. (2017). HeartID: A Multiresolution Convolutional Neural Network for ECG-Based Biometric Human Identification in Smart Health Applications. *IEEE Access*, 5(c), 11805–11816. doi:10.1109/ACCESS.2017.2707460.
- Zhao, Z., Zhang, Y., Deng, Y., and Zhang, X. (2018). ECG authentication system design incorporating a convolutional neural network and generalized S-Transformation. *Computers in Biology and Medicine*, 102, 168–179. doi:10.1016/j.combiomed.2018.09.027.