



Sistema embarcado de diagnóstico de doenças cardíacas por redes neurais artificiais

Embedded system for diagnosing heart disease through artificial neural networks

Matheus Pabis Esteves^{*}, Tiago Piovesan Vendruscolo[†]

RESUMO

As doenças cardíacas são as principais causas de mortes no mundo, porém a tecnologia vem proporcionando avanços para prevenção de possíveis causas de patologias cardíacas. O principal objetivo deste trabalho é projetar um sistema embarcado de diagnóstico de doenças cardíacas através do eletrocardiograma. Para o diagnóstico serão utilizadas redes neurais artificiais, que são alternativas para substituição de cálculos. O desenvolvimento do trabalho será baseado em uma metodologia flexível, onde serão treinadas e validadas possíveis redes neurais, com o uso de sinais de eletrocardiograma disponíveis em bancos de dados abertos. Em conjunto com o exposto, para um melhor entendimento da área em questão, também será projetado um sistema embarcado responsável por fazer a aquisição dos sinais de eletrocardiografia, que serão gerados com um gerador de onda arbitrária. Por fim, almeja-se a disponibilização de uma ferramenta que possua confiabilidade e eficácia, facilitando e agilizando a identificação inicial (triagem) de possíveis problemas cardíacos.

Palavras-chave: Doenças cardíacas. Eletrocardiograma. Sistema embarcado. Redes neurais artificiais.

ABSTRACT

Heart disease is the leading cause of death worldwide, but technology has provided advances in preventing possible causes of heart disease. The main objective of this work is to design an embedded system for diagnosing heart disease through the electrocardiogram. For the diagnosis, artificial neural networks will be used, which are alternatives for calculus replacement. The development of the work will be based on a flexible methodology, where possible neural networks will be trained and validated, using electrocardiogram signals available in open databases. In conjunction with the above, for a better understanding of the area in question, an embedded system responsible for acquiring the electrocardiography signals will also be designed, which will be generated with an arbitrary wave generator. Finally, the aim is to provide a tool that has reliability and effectiveness, facilitating and speeding up the initial identification (screening) of possible heart problems.

Keywords: Heart diseases. Electrocardiogram. Embedded system. Artificial Neural Networks.

1 INTRODUÇÃO

Diagnosticar doenças corretamente é um trabalho complexo, que em muitos casos necessitam uma série de exames de alto custo, os quais nem sempre o médico possui à disposição. Dessa forma, a introdução de novas técnicas de diagnóstico que sejam simples e acessíveis poderá auxiliar na identificação de patologias. Por isso, houve empolgação da comunidade da saúde com a ideia que uma Inteligência Artificial (IA) poderia tornar a tarefa mais precisa e fácil (BELLUZ, 2019).

^{*} Engenharia de Computação; mth.pesteves@gmail.com.

[†] Coordenação de Engenharia de Computação; tvendruscolo@utfpr.edu.br.

Para ilustrar alguns casos de uso de IA na medicina, pesquisadores do Google desenvolveram um algoritmo de aprendizado profundo com 98% de precisão para detecção de retinopatia diabética. Os médicos do Moorfields Eye Hospital, em Londres, treinaram um algoritmo que recomenda o tratamento com 94% de precisão para mais de 50 doenças oculares. Médicos na China usaram IA para diagnosticar pólipos no cólon durante uma colonoscopia, aumentando para 29% de precisão comparado com os 20% que eram diagnosticados (GULSHAN et al., 2016)(DEEPMIND, 2018)(WANG et al., 2019).

Assim ainda, a tecnologia atual está longe de criar uma máquina portátil para diagnosticar qualquer doença, porém com pequenas contribuições este objetivo pode ser alcançado (BELLUZ, 2019). Contextualizado a realidade atual, define-se o tema para o presente trabalho: Aplicação de redes neurais artificiais para o diagnóstico de doenças utilizando dados de eletrocardiogramas.

Pode-se então assimilar o seguinte questionamento: É possível gerar um equipamento que ajude profissionais da saúde a encontrar doenças cardíacas em pacientes que precisam de um rápido diagnóstico?

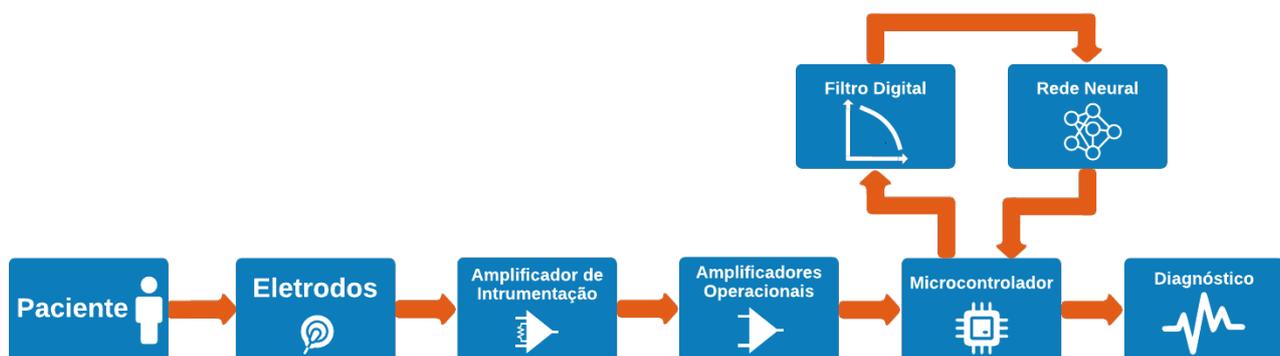
Para justificar este trabalho constata-se a contribuição para área de instrumentação médica, pois abrange um exame/equipamento vital para o diagnóstico de doenças cardíacas, o eletrocardiograma, e redes neurais artificiais. A junção destas duas áreas traz à tona possíveis equipamentos que podem mudar a maneira com que profissionais da saúde tratam seus pacientes.

2 MÉTODO

Todos os passos descritos neste capítulo são para um sistema que faz o diagnóstico das patologias relacionadas à frequência cardíaca, ou seja, arritmias, sendo elas extrassístoles, bradiarritmias e taquiarritmias. Tais doenças demandam a implementação de uma derivação, pois a frequência cardíaca é compartilhada em todas.

A Figura 1 representa o fluxograma de funcionamento do sistema completo.

Figura 1 – Fluxograma de funcionamento



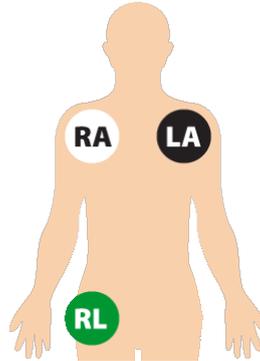
Fonte: Autoria Própria (2021).

Partindo da Figura 1, o presente trabalho irá desenvolver duas ferramentas:

1. Sistema embarcado de um eletrocardiógrafo: Esse sistema será desenvolvido com o intuito de auxiliar no entendimento de como os sinais de eletrocardiograma são adquiridos e se comportam. Esse sistema será validado utilizando sinais de eletrocardiograma gerados por um gerador de onda arbitrário.
2. Rede Neural Artificial: Será desenvolvida com o intuito de identificar as patologias mais comuns a partir de sinais de eletrocardiograma provenientes de bancos de dados open source.

Para a aquisição de sinais de eletrocardiograma em humanos, pode-se ver na Figura 2, o posicionamento dos eletrodos: na posição RA (Right arm) no ombro direito, LA (Left arm) no ombro esquerdo, e RL (Right leg) na parte direita da barriga, assim podemos ter um eletrocardiograma (ECG) de monitoramento com 1 derivação.

Figura 2 – Localização dos eletrodos



Fonte: Autorial Própria (2021).

O eletrodo é demonstrado na Figura 3, que por sua vez são adesivos que possuem uma solução em gel que forma uma camada de condução entre a pele e o metal.

Figura 3 – Eletrodo



Fonte: (DAVIS MEDICAL ELECTRONICS, 2020)

Os ritmos cardíacos recebidos dos eletrodos seguirão para um amplificador de instrumentação, que amplificará o sinal e reduzirá o erro. O amplificador de instrumentação escolhido para esta aplicação é o INA128, que possui um CMRR mínimo de 120 dB e um ganho ajustável de 1 a 10000 pelo resistor R_G dado pela Equação (1).

$$G = 1 + \frac{50k\Omega}{R_G} \quad (1)$$

Com o sinal amplificado, através de amplificadores operacionais será ajustado o sinal para a leitura do Conversor Analógico-Digital (ADC) do microcontrolador. Para tal etapa escolheu-se o circuito integrado TL082 que possui dois amplificadores operacionais.

O microcontrolador escolhido para esta aplicação foi o ESP32, devido ao seu ADC de 12 bits e a possibilidade da visualização do sinal através do seu DAC (Conversor Digital-Analógico).

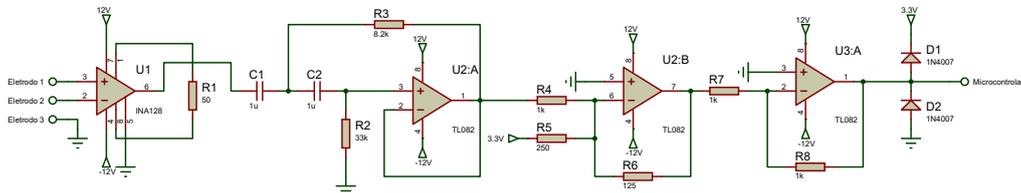
Serão implementados no ESP32 filtros digitais com a finalidade de retirar a interferência elétrica da rede (60 Hz) e sinais superiores a 100 Hz que prejudicam a qualidade do sinal. Tais filtros foram projetados através de algoritmos desenvolvidos em Python.

As amostras de dados para o treinamento e testes da rede neural artificial foram adaptadas da base de dados disponível em <http://storage.googleapis.com/download.tensorflow.org/data/ecg.csv>.

Foram testados diversos circuitos de aquisição e amplificação do sinal cardíaco, e na Figura 4 demonstra-se o esquema mais completo e que satisfaz as simulações computacionais. Considera-se ainda que devido ao sinal

conter uma amplitude muito pequena, algumas alterações devido a ruídos deverão ser aplicadas no circuito.

Figura 4 – Circuito de Aquisição do ECG



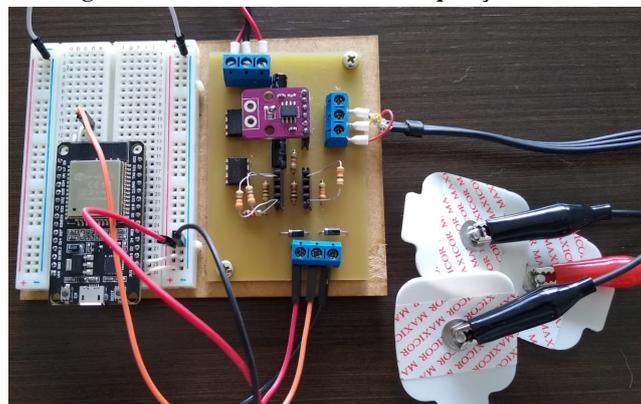
Fonte: Autoria Própria (2021).

No circuito da Figura 4 inicialmente temos o amplificador de instrumentação INA128 com um R_G de 50Ω , ou seja, pela Equação (1), conseguimos um ganho aproximado de 1000, portando para um sinal de amplitude de $1 mV$ conseguimos amplificá-lo para $1 V$ de amplitude.

O circuito em seguida, demonstra um filtro passa-altas de segunda ordem com um frequência de corte próxima a $0 Hz$, ou seja, com o objetivo de retirar o *offset DC*. Posteriormente temos um amplificador somador inversor com ganho de $\frac{1}{2}$ para centralizar o sinal na faixa de entrada do ADC do ESP32. Em seguida, um amplificador inversor de ganho unitário para retornar o sinal a sua fase original e por fim dois diodos de proteção para o ADC.

Com o esquemático definido realizou-se o projeto da placa de circuitos impressa (PCI) e montou-se o projeto de aquisição do ECG com ESP32, demonstrado na Figura 5.

Figura 5 – Sistema Embarcado de Aquisição do ECG



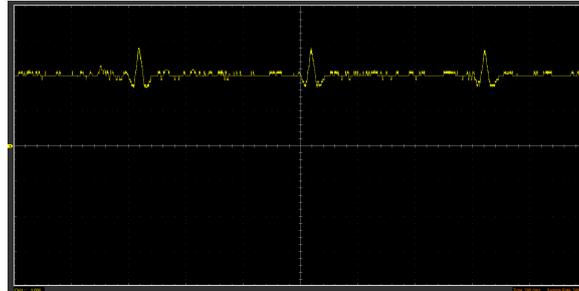
Fonte: Autoria Própria (2021).

Os filtros digitais para atenuação dos ruídos foram projetados em Python no domínio do tempo contínuo e então discretizados com a transformação bilinear, ou Tustin. De início testou-se filtros de 1^a e 2^a ordem passa-baixas com frequência de corte em $100 Hz$ e filtros de 1^a , 2^a e 4^a ordem rejeita-faixa com banda de atenuação de $55 Hz$ à $65 Hz$. A melhor configuração obtida foi um 2^a ordem passa baixas e 4^a ordem rejeita-faixa, e portanto a configuração utilizada na aquisição dos resultados.

3 RESULTADOS

Com a utilização do DAC do ESP32 e de um osciloscópio USB Hantek 6022BE obteve-se o seguinte resultado demonstrado na Figura 6, utilizando um gerador de ondas arbitrário para a geração do sinal de ECG.

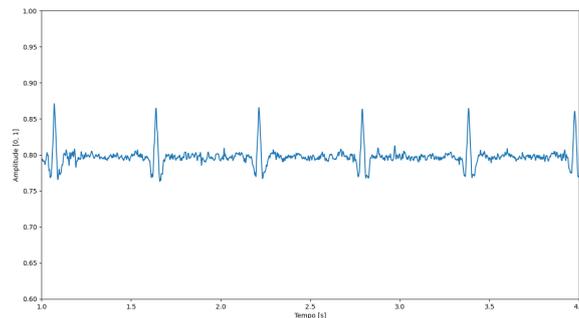
Figura 6 – Sinal adquirido através do DAC do ESP32



Fonte: Autoria Própria (2021).

Para melhorar a visualização do sinal adquirido, foi realizada uma leitura de 3 segundos do sinal e normalizado sua amplitude entre 0 e 1, portanto na Figura 7 tem-se o sinal que será utilizado para treinar a rede neural artificial.

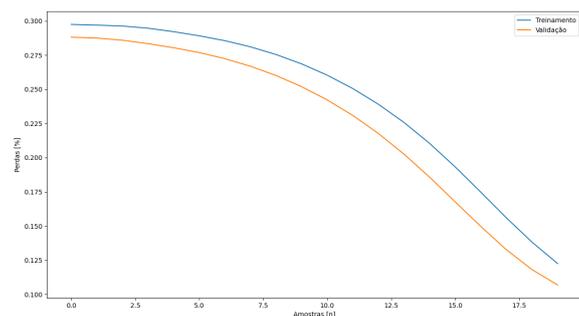
Figura 7 – Sinal adquirido através do DAC do ESP32



Fonte: Autoria Própria (2021).

A rede neural artificial desta aplicação está em desenvolvimento e inicialmente foi treinada para diferenciar eletrocardiogramas de uma pessoa saudável de eletrocardiogramas com anomalias, a Figura 8 demonstra o gráfico de perdas, tanto no treinamento quanto na validação, nota-se que conforme o número de amostras utilizadas tanto no treinamento quanto na validação aumenta, a perda encontrada é menor.

Figura 8 – Perdas no treinamento e na validação da rede neural artificial



Fonte: Autoria Própria (2021).



Pensando no ECG como uma série temporal, foram divididas amostras de 1 segundo para treinar e testar a rede neural, outro fator em séries temporais é o desvio padrão que neste caso ficou de 0,1742 normalizado, portanto 17,42% do sinal esta fora do esperado. Obteve-se um acerto de 50% dos casos de teste.

O resultado que se espera desta pesquisa é a conclusão do software e hardware, que servirá como um passo inicial para trabalhos futuros no desenvolvimento de um sistema embarcado completo que possa fazer a aquisição de sinais de eletrocardiograma e informar instantaneamente possíveis patologias cardíacas, acelerando o processo de investigação por parte da equipe médica.

4 CONCLUSÕES

A pesquisa encontra-se com a fase do sistema embarcado concluído, considerando a baixa amplitude do sinal de um ECG e ruídos adventícios, seu uso em situação real possivelmente demandará de algumas adaptações na parte de filtragem e/ou amplificação.

A rede neural artificial está em fase de testes para ECG com anomalias, espera-se adequar sua acurácia para continuar o desenvolvimento baseado em arritmias cardíacas.

Corroborado a confiabilidade e a eficácia, espera-se que esse equipamento, em fase inicial, possibilite o desenvolvimento de uma ferramenta prática e útil no cotidiano de profissionais da saúde, bem como possua baixa ou quase nula manutenibilidade. Portanto melhorando a agilidade e segurança no diagnóstico para os usuários.

AGRADECIMENTOS

Os autores agradecem o suporte financeiro da UTFPR por meio do Edital 05/2020 - DIRPPG-TD.

REFERÊNCIAS

- BELLUZ, Julia. **3 ways AI is already changing medicine**. [S.l.: s.n.], 2019. Disponível em: [🔗](#).
- DAVIS MEDICAL ELECTRONICS. **Kendall Medi-Trace 210 Foam, Snap Monitoring Electrode CASE/500**. [S.l.: s.n.], 2020. Disponível em: [🔗](#).
- DEEPMIND. **Predicting eye disease with Moorfields Eye Hospital**. [S.l.: s.n.], 2018. Disponível em: [🔗](#).
- GULSHAN, Varun et al. **Development and Validation of a Deep Learning Algorithm for Detection of Diabetic Retinopathy in Retinal Fundus Photographs**. [S.l.: s.n.], 2016. Disponível em: [🔗](#).
- WANG, Pu et al. **Real-time automatic detection system increases colonoscopic polyp and adenoma detection rates: a prospective randomised controlled study**. [S.l.: s.n.], 2019. Disponível em: [🔗](#).