



DESENVOLVIMENTO DE UM PROTOCOLO DE DETECÇÃO E CLASSIFICAÇÃO DE ARRITMIAS CARDÍACAS UTILIZANDO RNA

Gabriel Fernandes Cyrino¹, Diogo Aparecido Cavalcante¹, Reidner Santos Cavalcante¹, Leonardo Nery Carrijo Santos¹, Leandro Resende Mattioli¹, Keiji Yamanaka¹, Alexandre Cardoso¹ e Edgard Lamounier¹

¹FEELT - Universidade Federal de Uberlândia

Resumo - As arritmias cardíacas são ritmos anormais do coração que podem causar vários riscos e consequências na vida das pessoas, podendo até levar à morte. As arritmias podem ser detectadas e classificadas por meio de algoritmos específicos ou métodos inteligentes aplicados sobre dados presentes no eletrocardiograma (ECG) de uma pessoa. Nesse sentido, este trabalho visa apresentar um estudo sobre Redes Neurais Artificiais (RNA), mais precisamente, uma Rede Neural do tipo Learning Vector Quantization (LVQ) e aplicá-la utilizando a base *MIT-BIH Arrhythmia Database* (pertencente a Physionet), afim de detectar e classificar quatro tipos de arritmias cardíacas: Contração Prematura Atrial (CPA), Contração Prematura Ventricular (CPV), Bloqueio do Ramo Esquerdo (BRE) e Bloqueio do Ramo Direito (BRD). Os resultados foram satisfatórios, tendo alcançado uma assertividade próxima dos 98%.

Palavras-Chave- Arritmia, Eletrocardiograma, Learning Vector Quantization, Redes Neurais Artificiais.

DEVELOPMENT OF A PROTOCOL FOR DETECTION AND CLASSIFICATION OF CARDIAC ARRHYTHMIAS USING ANN

Abstract - Cardiac Arrhythmias are abnormal rhythms of the heart that can cause various risks and consequences in people's lives and can even lead to death. In addition, it is known that arrhythmias can be detected and classified by means of specific algorithms or intelligent methods applied to the data contained in the patient's electrocardiogram exams. Thus, this work aims to apply an Artificial Neural Network (ANN) LVQ (Learning Vector Quantization), in datasets of the *MIT-BIH Arrhythmia Database* (Physionet), in order to detect and classify four types of cardiac arrhythmias: Premature Atrial Contraction (PAC), Premature Ventricular Contraction (PVC), Left Bundle Branch Block (LBBB) and Right Bundle Branch Block (RBBB). The results were satisfactory, reaching an assertiveness close to 98%.

Keywords - Arrhythmia, Artificial Neural Networks, Electrocardiogram, Learning Vector Quantization.

*gabrielcyrino@hotmail.com

I. INTRODUÇÃO

As doenças cardiovasculares são uma das principais causas de mortes em diversos países, representando cerca de um terço das mortes em adultos no Brasil [1]. No que tange sua prevenção, observa-se que essas doenças poderiam ser evitadas se fossem detectadas e classificadas previamente por meio de um eletrocardiograma (ECG). Dentre as diversas doenças cardíacas, as mais comuns são as arritmias, que tratam-se de ritmos anormais do coração, as quais podem causar sérios riscos à saúde, inclusive levar alguém à morte.

Nesse sentido, o referente artigo visa apresentar uma alternativa prática e automática para a detecção de arritmias, a qual será norteada pela utilização de algoritmos específicos e métodos inteligentes sobre um exame de ECG [2]. Acerca desses métodos, destacam-se as Redes Neurais Artificiais (RNA), as quais são métodos inteligentes que, a partir de algoritmos matemáticos, realizar tarefas como: controle de processos, reconhecimento e classificação de padrões, agrupamento de dados (clusterização), sistemas de previsão, otimização de sistemas [3].

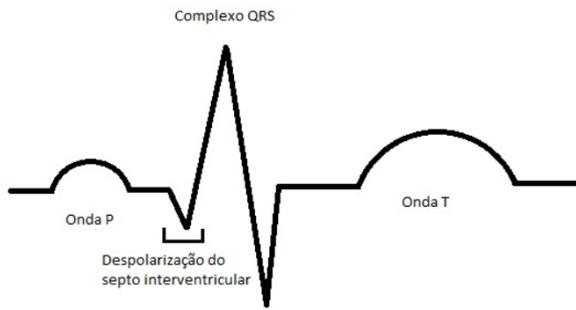
Dessa forma, este trabalho tem como objetivo utilizar a rede neural *Learning Vector Quantization* (LVQ) para encontrar e classificar quatro tipos de arritmias: Contração Prematura Atrial (CPA), Contração Prematura Ventricular (CPV), Bloqueio do Ramo Esquerdo (BRE) e Bloqueio do Ramo Direito (BRD).

II. ELETROCARDIOGRAMA E ARRITMIAS CARDÍACAS

A. Eletrocardiograma (ECG)

A medida que o impulso cardíaco percorre o coração, correntes elétricas se propagam para os tecidos que cercam o coração e uma pequena fração dessas correntes atinge a superfície do corpo [4]. Quando colocados eletrodos sobre a pele em pontos opostos do coração, os potenciais elétricos gerados por essas correntes são registrados no ECG. Na Figura 1 é mostrado um esquema de um exame de ECG para um batimento cardíaco normal.

Figura 1: Representação de uma onda normal de um ECG.



B. Arritmias cardíacas

As arritmias cardíacas são distúrbios cardíacos comuns que podem causar graves riscos e consequências na vida das pessoas, podendo até mesmo levar ao óbito. Elas são caracterizadas pela alteração da frequência cardíaca ou pelo próprio ritmo do batimento [5]. Em geral, as arritmias podem ser causadas por uma ou mais anormalidades no ritmo do coração [3], sendo o ECG o melhor e mais confiável diagnóstico. Acerca dessa irregularidade no comportamento cardíaco, destacam-se as arritmias mais comuns:

1) Contração Prematura Atrial (CPA)

Uma contração prematura ocorre antes do momento em que deveria ocorrer uma contração normal [2]. A CPA ocorre com maior frequência em pessoas as quais fumam, apresentam sono irregular e ingerem café álcool de forma excessiva, porém, também é muito comum em pessoas saudáveis [4]. A Figura 2 mostra um trecho de captura onde ocorre uma CPA.

Figura 2: Contração Prematura Atrial. Extraído do registro 100 da base MIT-BIH [6]. Intervalo da grade: 0.2 sec, 0.5mV.



2) Contração Prematura Ventricular (CPV)

Também conhecida como Despolarização Ventricular Prematura, a CPV ocorre na maioria das pessoas em algum momento. No que tange suas causas, nota-se que são parecidas com a CPA, podendo incluir certos medicamentos, álcool, algumas drogas ilegais, cafeína, tabaco, exercícios físicos ou ansiedade. Algumas CPV podem ser originadas pelos mesmos fatores da CPA. Ademais as CPV podem resultar de sinais reentrantes que se originam ao redor dos limites de áreas cardíacas infartadas ou isquêmicas, podendo

desenvolver fibrilação ventricular espontânea, o que é letal [4]. A Figura 3 mostra um trecho de captura onde ocorre uma CPV.

Figura 3: Contração Prematura Ventricular. Extraído do registro 100 da base MIT-BIH [6]. Intervalo da grade: 0.2 sec, 0.5mV.



3) Bloqueio do Ramo Esquerdo (BRE)

Também conhecido como *Left Bundle Branch Block* (LBBB), no BRE normalmente o septo é ativado da esquerda para a direita, produzindo pequenas ondas Q nas derivações laterais. À medida que os ventrículos são ativados sequencialmente (direita, esquerda) em vez de simultaneamente, há a produção de uma onda R larga ou entalhada (em forma de M) nas derivações laterais. Além disso, sabe-se que o BRE pode ser causado por estenose aórtica, doença cardíaca isquêmica, hipertensão, cardiomiopatia dilatada, doença degenerativa primária (fibrose) do sistema condutor, doença de Lenegre, hipercaliemia, toxicidade por digoxina [7]. A Figura 4 mostra um trecho de captura onde ocorre uma BRE.

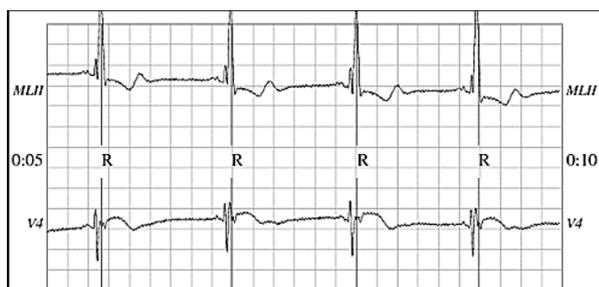
Figura 4: Bloqueio do Ramo Esquerdo. Extraído do registro 109 da base MIT-BIH [6]. Intervalo da grade: 0.2 sec, 0.5mV.



4) Bloqueio do Ramo Direito (BRD)

Também conhecido como *Right Bundle Branch Block* (RBBB), no BRD a ativação do ventrículo direito é adiada, visto que a despolarização, possivelmente, se espalhará pelo septo do ventrículo esquerdo. A ativação retardada do ventrículo direito também dá origem a anormalidades secundárias de repolarização, com depressão ST e inversão da onda T nas derivações precordiais direitas. No que tange às causas, essa arritmia tem relação direta com a hipertrofia ventricular direita, embolo pulmonar, doença cardíaca isquêmica, doença cardíaca reumática, miocardite ou cardiomiopatia, doença degenerativa do sistema de condução, doença cardíaca congênita [7]. A Figura 5 seguir mostra um trecho de captura onde ocorre um BRD.

Figura 5: Bloqueio do Ramo Direito. Extraído do registro 124 da base MIT-BIH [6]. Intervalo da grade: 0.2 sec, 0.5mV.



III. REDES NEURAIS ARTIFICIAIS E LVQ

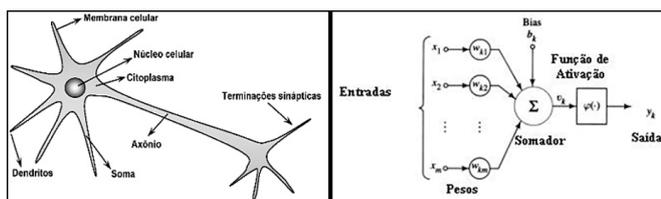
A. Redes Neurais Artificiais (RNA)

Inicialmente, nota-se que as RNAs são modelos computacionais inspirados no sistema nervoso de seres vivos [3]. Nesse sentido, observa-se que esses modelos constituem um sistema de processamento de informações o qual apresenta certas características de desempenho em comum com a biologia, em que se utiliza a generalização de modelos matemáticos afim de simular a capacidade de cognição humana [8].

Por outro lado, há teorias as quais afirmem que as RNAs são técnicas computacionais que apresentam um modelo baseado na estrutura neural de organismos inteligentes (neurônios) e que adquirem conhecimento através da experiência [9].

Dessa forma, conclui-se que, ainda que os neurônios artificiais são inspirados no neurônio biológico, estes constituem modelos bem simplificados se comparados com os originais, haja visto que foram projetados a partir de conhecimento humano [3]. Assim sendo, a Figura 6 apresenta um esquema acerca dos dois neurônios, para efeito de comparação.

Figura 6: Neurônio humano (à esquerda) e neurônio artificial (à direita) [8].



Como dito anteriormente, uma RNA deve simular o funcionamento do neurônio humano, para isso, são utilizados modelos matemáticos os quais são processados por várias unidades (neurônios) de processamento as quais irão simular o comportamento. Contudo o comportamento inteligente também depende das interações entre as unidades de processamento da rede. Acerca desses neurônios artificiais, destaca-se que estes podem estar presentes em três camadas destinadas dentro de uma RNA como as vistas a seguir:

- Camada de entrada: onde os padrões são apresentados à rede.
- Camadas Intermediárias ou Escondidas: onde é feita a maior parte do processamento, através das conexões

ponderadas; podem ser consideradas como extratoras de características.

- Camada de Saída: onde o resultado final é concluído e apresentado.

O processo de aprendizagem de uma RNA depende do seu processo de treinamento, no sentido de que esse tem o intuito de ajustar os pesos e os limiares de cada neurônio (modelo matemático) presente dentro da RNA [3]. Entretanto, existem vários tipos de treinamento dentre os quais se destacam:

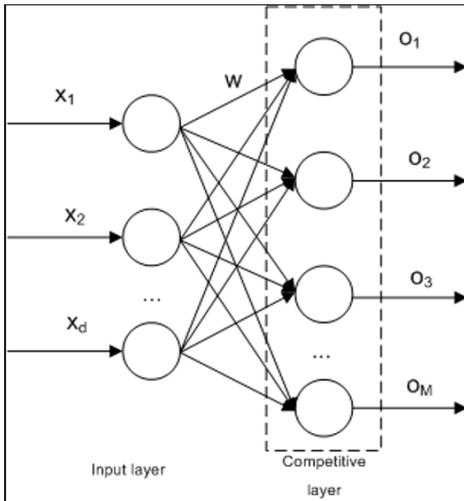
- Aprendizado Supervisionado: Onde a RNA é treinada com auxílio de um supervisor. Para tanto, a rede deverá possuir pares de entrada e saída, ou seja, um conjunto de entradas e um conjunto com as saídas desejadas para cada entrada. Toda vez que for apresentada à rede uma entrada, deverá ser verificado se a saída obtida confere com a saída desejada para aquela entrada. Sendo diferente, a rede deverá ajustar os pesos de forma que armazene o conhecimento desejado.
- Aprendizado Não Supervisionado ou auto organizado: É quando não existe um agente externo indicando a resposta desejada para os padrões de entrada, este tipo de aprendizado também é conhecido como aprendizado auto supervisionado ou de auto-organização por que não requer saída desejada e/ou não precisa usar supervisores para seu treinamento.

B. Learning Vector Quantization (LVQ)

As redes LVQ foram criadas por Teuvo Kohonen em 1990, sendo considerada por muitos uma versão supervisionada dos mapas auto organizáveis das redes SOM (*Self Organization Maps*) [3].

A respeito do treinamento desses neurônios, há um método de classificação padrão em que cada unidade de saída representa uma determinada classe ou categoria (várias unidades de saída devem ser usadas para cada classe). Durante o processo, as unidades de saída são posicionadas (ajustando seus pesos através de treinamento supervisionado) para aproximar as superfícies de decisão do classificador. Assim, assume-se que um conjunto de padrões de treinamento com classificações conhecidas é fornecido, juntamente com uma distribuição inicial de vetores de referência (cada um dos quais representa uma classificação conhecida). Após o treinamento, uma rede LVQ classifica um vetor de entrada, atribuindo-o à mesma classe que a unidade de saída que possui seu vetor de peso (vetor de referência) mais próximo do vetor de entrada [8]. Dessa forma, tem-se que o treinamento dos neurônios nessa rede neural é executado de forma competitiva, uma vez que os neurônios competem entre si [10]. A Figura 7 exemplifica uma arquitetura LVQ.

Figura 7: Arquitetura da Rede LVQ [9].

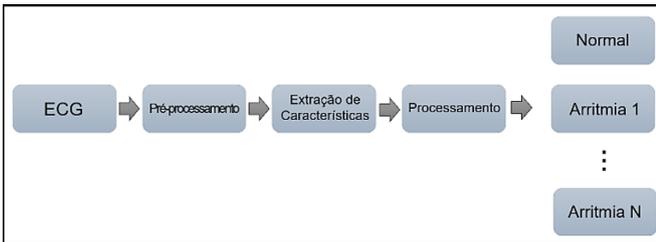


Quando um registro de entrada é apresentado a rede, apenas um neurônio responderá a este sinal, o qual é chamado de neurônio vencedor [10]. Normalmente dois algoritmos de treinamento LVQ, denominados LVQ-1 e LVQ-2 são utilizados para ajustes de pesos dos neurônios vencedores, de modo que o algoritmo LVQ-1 ajusta os pesos somente do neurônio vencedor, enquanto o LVQ-2 ajusta os pesos do neurônio vencedor e do seu vice.

IV. METODOLOGIA

A detecção automática de arritmias a partir do ECG pode ser obtida de duas maneiras, utilizando algoritmos específicos ou por meio de métodos inteligentes. Para a efetiva realização da detecção automática de arritmias, o trabalho foi dividido em três etapas: pré-processamento, extração de características e processamento. A Figura 8 apresenta essas etapas.

Figura 8: Etapas para a detecção de arritmias.



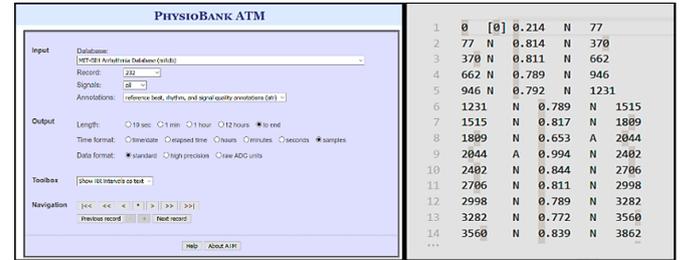
A. Obtenção de Dados do ECG

As informações foram obtidas através da base de dados MIT-BIH Arrhythmia Database, pertencente a Physionet. A base foi criada pelo Boston's Beth Israel Hospital entre os anos de 1975 e 1979 e publicada em 1980. No que tange essa base de dados, sabe-se que essa contém 48 registros de ECG de diversos pacientes, coletados em vários lugares, de modo que essa seja recomendada para realização de trabalhos e pesquisas que necessitam de diversas amostras de problemas cardíacos.

B. Pré-processamento

Inicialmente foram capturados do repositório da Physionet os arquivos de anotações dos 48 registros, contendo informações da distância RR desses registros. A Figura 9 mostra a interface de geração das anotações da Physionet e um exemplo de um arquivo gerado.

Figura 9: Interface de geração de anotações (à esquerda) [11] e exemplo de arquivo de anotações, intervalos RR (à direita).



Após essa captura, foi executada a extração dos dados brutos (RAW data) dos registros para servir como base para a extração de características e serem plotados na interface desenvolvida. A Figura 10 mostra parte do arquivo com os dados capturados do registro 100.

Figura 10: Parte dos dados capturados do registro 100.

1	0,1.32520325
2	0.003,1.32520325
3	0.006,1.32520325
4	0.008,1.32520325
5	0.011,1.32520325
6	0.014,1.32520325
7	0.017,1.32520325
8	0.019,1.32520325
9	0.022,1.32317073
10	0.025,1.32317073
...	

C. Extração de características

A extração das características é feita com base nos arquivos gerados na fase de pré-processamento, ou seja, as informações de distância RR (anotações) capturadas. O resultado é um arquivo de características para o registro em questão, contendo 5 colunas: Número do Registro, Distância RR, Distância Relativa RR (obtida utilizando um cálculo de janelamento), Área da Onda e Tipo da Arritmia (em cada janela).

Após a extração das características, os valores obtidos são normalizados entre -1 e 1 para alimentar a rede, posteriormente. Esse arquivo normalizado é, então, dividido em 5 arquivos, cada um contendo o agrupamento de todas as arritmias presentes no mesmo (inclusive as ondas normais).

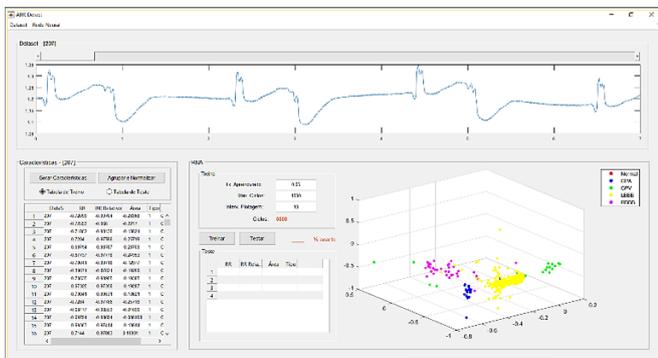
Para a posterior execução da rede serão precisos dois novos arquivos: um contendo os dados para o treinamento e outro contendo os dados para o teste, esses arquivos são gerados na fase do processamento.

D. Processamento

Após a normalização e o agrupamento dos dados, inicia-se a fase de processamento, onde é gerado um arquivo contendo ocorrências aleatórias de arritmias do registro atual, sendo 30 por cento de cada arritmia, o qual será responsável por treinar a RNA. Além disso, é gerado um arquivo contendo outras ocorrências aleatórias de arritmias, porém os 70 por cento de dados restantes não são, completamente, treinados pela rede neural. Dessa forma, tem-se os dados necessários para alimentar a RNA.

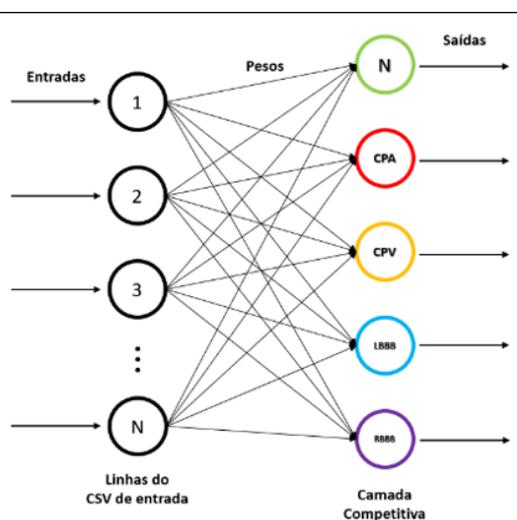
Para permitir a compreensão do que está sendo desenvolvido, a interface da aplicação desenvolvida é mostrada na Figura 11, já com os dados gerados e exibidos, referentes ao registro 207 da base. Acerca do registro, nota-se que este não contém nenhuma onda normal, porém, existe grande quantidade de arritmias na mesma. Um gráfico também é plotado, mostrando o agrupamento das arritmias presentes no mesmo.

Figura 11: Interface da aplicação mostrando os dados gerados.



Assim, a partir dos dados gerados para treinamento, é possível classificar as arritmias presentes no arquivo de teste. Essa classificação se deu por meio da RNA desenvolvida utilizando LVQ, possuindo 5 neurônios, 1 respectivo à onda normal e 4 respectivos aos 4 tipos de arritmias: CPA, CPV, BRE e BRD. A Figura 12 mostra a arquitetura da rede desenvolvida.

Figura 12: Arquitetura LVQ da RNA desenvolvida.



V. RESULTADOS

Para o treinamento da RNA, observou-se que valores baixos para a taxa de aprendizagem ocasionam em taxas de acerto superiores, porém quanto menor a taxa de aprendizado maior deve ser o número de ciclos para um treinamento bem-sucedido. Contudo, observou-se que com a taxa de aprendizado em 0.05 consegue-se atingir resultados satisfatórios, para a maioria dos casos, com no máximo 30 ciclos.

Durante o treinamento, é plotado um gráfico em 3D com os pontos respectivos às arritmias do arquivo de características com pesos encontrados que são plotados dinamicamente, sendo aproximados e afastados de acordo com as arritmias pertencentes ao grupo. A seguir serão apresentados duas Figuras, sendo que a Figura 13 trata-se da interface com resultados, e a Figura 14, mostra o gráfico em questão.

Figura 13: Interface contendo os resultados da execução.

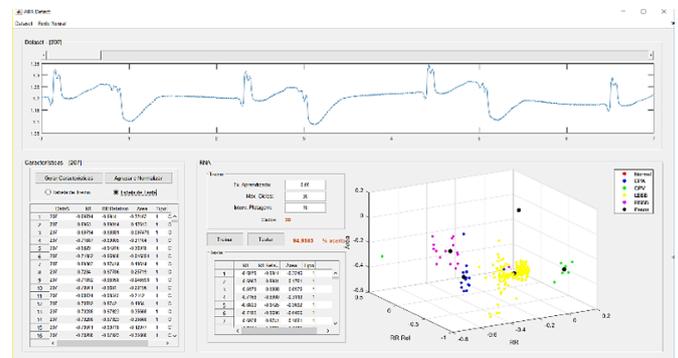
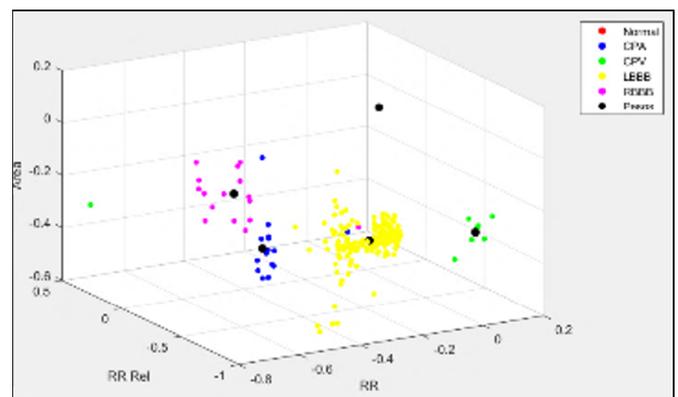
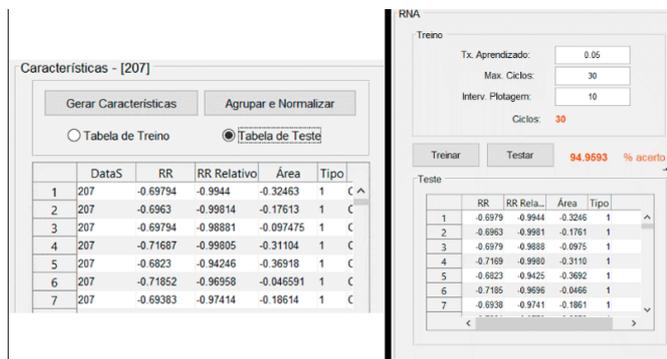


Figura 14: Gráficos com os grupos de arritmias e seus pesos.



Após o treinamento, é possível executar o processo de teste dos pesos da RNA para a comprovação do resultado do treinamento. Na maioria dos casos, conseguiu-se uma taxa de acerto entre 93 por cento e 98 por cento na classificação, dependendo do arquivo de dados informados. Observou-se que arquivos que possuíam grande quantidade de arritmias de tipos diversos tiveram melhores resultados. A Figura 15 mostra os resultados com a classificação feita no teste do arquivo 207 da base de dados. É possível comparar a tabela de características com a tabela de teste, para a comprovação da taxa de acerto.

Figura 15: Classificação de dados referente ao registro 207 (à esquerda), características da rede e tabela de teste (à direita). Ambos mostrando as distâncias entre cada onda (RR, RR Relativo), a área da onda e o tipo da arritmia.



VI. CONCLUSÕES

Este trabalho propôs a aplicação de uma Rede Neural LVQ desenvolvida para a detecção e classificação de arritmias cardíacas a partir de amostras contendo grande diversidade de dados capturados da base de dados *MIT-BIH Arrhythmia Database*.

Conforme observado, a rede LVQ se mostrou muito eficiente na classificação de padrões de arritmias, conseguindo atingir uma assertividade de até 98 por cento, contudo, se mostra muito dependente da qualidade da amostra de dados coletada.

Anteriormente, o método de geração de características era feito utilizando a junção de todos os 48 registros da base de dados, treinando e testando a rede com os mesmos separados. Observou-se, então, que esse método se mostrava falho, pois cada registro pertence a um tipo de pessoa, e cada pessoa possui tipos diferentes de sinais ECG. Dessa forma, optou-se pelo método apresentado.

Como trabalhos futuros, pretende-se automatizar o processo de detecção e classificação, melhorando tanto a extração de características e pré-processamento quanto a própria RNA desenvolvida. Pretende-se, também expandir os registros utilizados, englobando outras bases de dados.

Sendo assim, a rede desenvolvida é totalmente indicada para a classificação das arritmias cardíacas CPA, CPV, BRE e BRD, podendo auxiliar no diagnóstico profissional.

REFERÊNCIAS

- [1] RIQUE, A. B. R. (2002). *Nutrição e exercício na prevenção e controle das doenças cardiovasculares*. Bras Med Esporte, Rio de Janeiro, p.244-254, 15 ago. 2018.
- [2] Júnior, S. R. R. (2008). *Deteção e classificação de arritmias cardíacas utilizando redes neurais artificiais auto-organizáveis* (Tese de Doutorado, Pontifícia Universidade Católica do Paraná).
- [3] Da Silva, I. N., Spatti, D. H., Flauzino, R. A. (2010). *Redes Neurais Artificiais para engenharia e ciências aplicadas curso prático*. São Paulo: Artliber.
- [4] Guyton, A. C., Hall, J. E., Guyton, A. C. (2006). *Tratado de fisiologia médica*. Elsevier Brasil.
- [5] Frownfelter, D., Dean, E. W. *Fisioterapia Cardiopulmonar: Princípios e Prática*. Terceira Edição. Revinter, 2004.
- [6] Physionet. PhysioBank. *MIT-BIH Arrhythmia Database*. Disponível em: <http://www.physionet.org/physiobank/database/mitdb>. Acesso em: 02 de junho de 2017.
- [7] Fields, J. M., Goyal, M. (2008). *Venothromboembolism*. *Emergency Medicine Clinics*, 26(3), 649-683.
- [8] Fausett, L. (1994). *Fundamentals of neural networks: architectures, algorithms, and applications*. Prentice-Hall, Inc.
- [9] Ben, K., Van der Smagt, P. *An introduction to neural networks*. University of Amsterdam. 8ª ed, 1996.
- [10] Bonifacio, F. N. (2010). *Comparação entre as Redes Neurais Artificiais MLP, RBF e LVQ na Classificação de Dados*. Universidade Estadual do Oeste do Paraná–Centro de Ciências Exatas e Tecnológicas-CCET.
- [11] Physionet. PhysioBank ATM. Disponível em: <https://physionet.org/cgi-bin/atm/ATM>. Acesso em: 02 de junho de 2017.