

Classificação de anomalias cardíacas a partir de exames de Eletrocardiograma

Rodolfo de F. Dalvi¹, Rodrigo V. Andreão¹, Gabriel T. Zago¹

¹Instituto federal de Educação, Ciência e Tecnologia do Espírito Santo - IFES
Av. Vitória, 1729 Jucutuquara – 29.045-780 – Vitória – ES – Brasil

rodolfodalvi@hotmail.com, rodrigova@ifes.edu.br, gtzago@gmail.com

Abstract. *This paper presents an algorithm to classify electrocardiograms according to some types of abnormalities in order to assist the expert in the triage of critical exams. The cardiac abnormalities are related to typical cardiac arrhythmias such as: right bundle branch block (R), left bundle branch block (L), premature ventricular (V), premature atrial (A) and paced beat (PB). A pre-processing step is performed through signal filtering and baseline line removal which is performed after the detection of heartbeat. A vector of 106 features based on the RR interval and the beat morphology were extracted from ECG signal. The size of the feature vector was reduced by the Principal Component Analysis (PCA) method. The reduced feature vector were employed as input of a Artificial Neural Network (ANN). The classification performance on a test set of 18 ECG recordings of 30 min each were an accuracy of 96.97%, sensitivity of 95.05%, specificity of 90.88%, positive predictive value of 95.11% and a negative predictive value of 92.7%. The results make the automatic triage a feasible strategy to prioritize abnormal ECGs to the cardiologist interpretation in a Telecardiology Service.*

Resumo. *Neste trabalho é apresentado um algoritmo capaz de classificar o exame de eletrocardiograma segundo alguns tipos de anomalias com a finalidade de auxiliar o especialista na triagem de exames críticos. As anomalias analisadas estão relacionadas com alterações cardíacas típicas tais como: Bloqueio do ramo direito (R), Bloqueio do ramo esquerdo (L), batimento ventricular prematuro (V), batimento atrial prematuro (A) e batimento estimulado (PB). Um pré-processamento é realizado através da filtragem e alinhamento do sinal, o qual depende de uma etapa de detecção dos batimentos. Para a classificação foi utilizado um vetor com 106 características ligadas aos intervalos RR e à segmentação do ECG. Este vetor foi reduzido através da técnica de Análise de Componentes Principais (Principal Component Analysis – PCA) para então ser aplicado à entrada de uma Rede Neural Artificial (RNA). O desempenho de classificação de arritmias sobre uma base de teste de 18 registros de 30 min cada foi de uma precisão de 96,97%, sensibilidade de 95,05%, especificidade de 90,88%, valor preditivo positivo de 95,11% e valor preditivo negativo de 92,7%. O resultado torna viável o uso da triagem para priorizar os exames com alterações para análise do cardiologista em um serviço de Telecardiologia.*

1. Introdução

O desenvolvimento tecnológico e o barateamento do serviço de acesso à internet têm contribuído no crescimento da oferta de serviços de Telemedicina e Telessaúde. A principal contribuição destes serviços é percebida em situações onde há carência de profissionais de saúde especializados e longas distâncias devem ser percorridas até o centro de referência mais próximo. Uma de suas modalidades é a Telecardiologia que é a prestação remota de serviços de cardiologia. O principal serviço de telecardiologia é o diagnóstico à distância de exames de Eletrocardiograma (ECG), os quais são enviados através de uma rede de dados até uma central de laudos [Marcolino et al. 2012]. O laudo com o diagnóstico do exame é então enviado de volta para o profissional de saúde que solicitou o serviço. O tempo de resposta do telediagnóstico neste caso é crítico dependendo da gravidade do diagnóstico do exame de ECG, ou seja, doenças graves demandam atendimento prioritário, diagnóstico rápido e tratamento imediato. De forma a agilizar o atendimento nestes casos, os serviços de Telecardiologia possibilitam ao profissional requerente a opção de classificar manualmente a requisição como urgente. Os exames que não são pré-classificados manualmente com urgentes, são analisados seguindo a ordem de chegada da requisição [Andreão et al. 2013]. Em [Sparenberg 2012], foi constatado que cerca de 14% dos exames de ECG via Telecardiologia foram pré-classificados manualmente como urgentes, onde a grande maioria deles era de pessoas saudáveis que não necessitam de urgência. Por outro lado, a grande parte dos exames de ECG anormais não está sendo tratada com prioridade, fazendo com que muitos exames fiquem na fila de exames não urgentes aguardando laudo do especialista. O atraso gerado pela análise de exames dentro dos padrões normais pode prejudicar os pacientes que apresentam alguma anomalia, visto que para algumas doenças é fundamental que o tratamento se dê com rapidez.

Nesse contexto, o projeto Telessaúde Espírito Santo (<http://telessaude.ifes.edu.br>), está propondo um serviço de triagem automática de exames de ECG [Andreão et al. 2013], onde os casos que necessitam de maior urgência são priorizados na fila de exames a serem laudados. O serviço de Telecardiologia é totalmente baseada na Web. O ECG gerado por um eletrocardiógrafo digital é anexado a uma requisição de Telecardiologia e enviado via plataforma Salus até o servidor, ficando disponível para o cardiologista realizar o laudo. A ideia da triagem é classificar automaticamente cada exame de ECG armazenado na plataforma, onde os registros anômalos são colocados nas primeiras posições da fila de exames à espera do laudo. Toda vez que um exame é armazenado na plataforma, uma notificação via SMS e e-mail é enviado ao cardiologista [Andreão et al. 2013].

A etapa principal do serviço de triagem é a classificação automática dos exames. Quanto melhor for o desempenho de classificação, maior será o impacto da triagem no atendimento dos casos urgentes. Na literatura existem diferentes trabalhos que buscam realizar esta classificação de anomalias a partir do ECG. Esta classificação normalmente é realizada por uma abordagem baseada no aprendizado de máquina, tal como: redes neurais [Mohamad et al. 2013], [Kim et al. 2011]; máquina de vetor suporte [Zhang et al. 2013], [She et al. 2010]; lógica fuzzy [Arif et al. 2009]; discriminantes lineares [Chazal et al., 2004]. Este trabalho propõe uma abordagem de classificação baseada em redes neurais. O diferencial do trabalho está na etapa de seleção de características extraídas do exame para a classificação eficiente do exame. O desempenho da abordagem de classificação é avaliado no banco de dados da Physionet

e seis classes são consideradas. Os resultados são comparados com os principais trabalhos publicados no assunto.

2. Metodologia

O sistema desenvolvido propõe basicamente três etapas: pré-processamento do sinal, extração das características de cada batimento e, por fim, a sua classificação automática.

O diagrama de blocos de todo o sistema pode ser visualizado na figura 1.

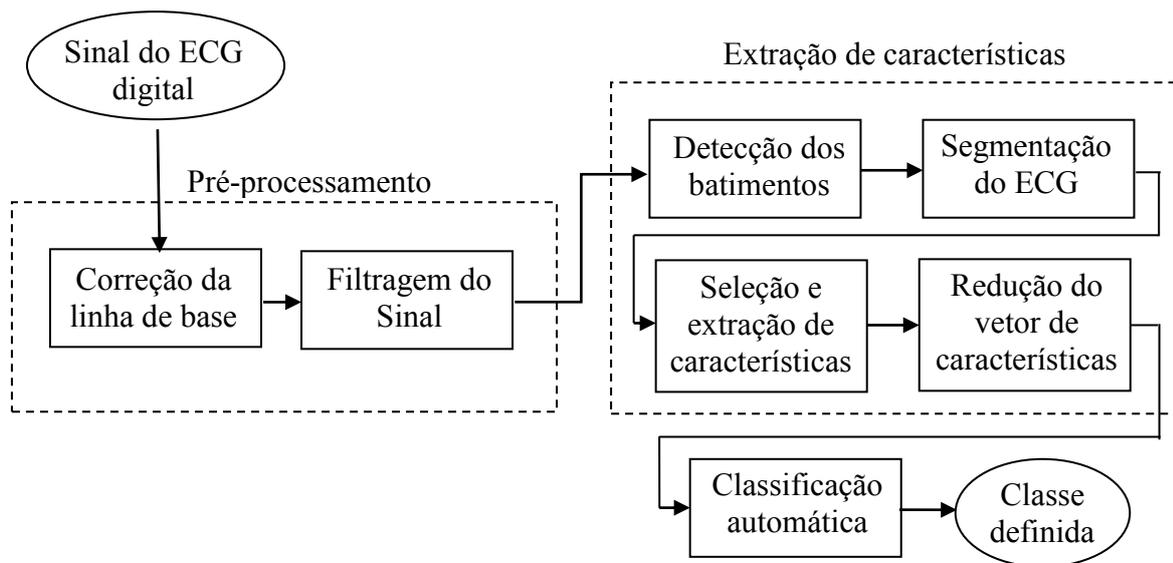


Figura 1. Diagrama de blocos do sistema desenvolvido.

2.1. Base de dados

Para o desenvolvimento de todo o trabalho foi necessária uma base de dados com exames de ECG na forma digital para análise computacional, de diferentes pacientes com diferentes quadros patológicos. Para isso foi utilizada a base de dados MIT Arrhythmia Database, amplamente empregada, fornecida de forma gratuita e disponibilizada no site do grupo Physionet [Physionet 2000].

Esta base de dados contém 48 registros de dois canais com meia hora de duração cada. Os sinais foram amostrados a uma taxa de 360 amostras/s. Além do sinal eletrocardiográfico, também são disponibilizadas as anotações referentes às anomalias presentes em cada batimento.

2.2. Pré-processamento

O sinal captado em um exame de ECG é composto pela combinação do sinal proveniente da atividade elétrica cardíaca do indivíduo com o ruído, pois o sinal de ECG é muito sensível a interferências, devido sua baixa amplitude [Igarashi 2007]. Portanto, nesta etapa, busca-se eliminar o ruído de alta frequência e as alterações da linha de base do sinal.

Para a correção da linha de base do sinal, é utilizado um filtro mediana [Chazal 2004], em que cada ponto do sinal é subtraído pela mediana do trecho, chamado de janela, ao qual pertence o ponto em questão. A correção é realizada em cada onda do batimento cardíaco detectado. A detecção do batimento e sua segmentação em ondas é

descrita nas seções 2.3 e 2.4. Para a correção das ondas P e do complexo QRS foi utilizada uma janela de 200 ms e para a correção das ondas T foi utilizada uma janela de 600 ms.

Por outro lado, para a eliminação do ruído de alta frequência foi realizada uma filtragem do sinal de ECG eliminando componentes de frequência não pertencentes ao sinal, que de acordo com Chazal (2004) são frequências acima de 35 Hz. Portanto foi utilizado um filtro FIR (*Finite Impulse Response*) passa-baixas, de ordem 12 e com frequência de corte igual a 35 Hz Chazal (2004).

2.3. Detecção dos batimentos

Para a detecção dos batimentos, foi desenvolvido um algoritmo que detecta o complexo QRS do batimento, por se tratar da onda de maior amplitude. O algoritmo empregado é baseado na transformada Wavelet do sinal. Com a finalidade de destacar o complexo QRS do restante do sinal, foi escolhida a função wavelet Chapéu Mexicano [Andreão et al. 2002][Madeiro et al. 2006]. O sinal resultante da transformada wavelet é analisado por meio de limiar, onde apenas os picos maiores que o limiar são selecionados. A separação mínima entre picos consecutivos é de 83 ms, o que é largo o suficiente para evitar que os picos positivo e negativo de um mesmo complexo QRS sejam detectados como se fossem de complexos QRS distintos. Para evitar detectar possíveis ondas P e T como complexos QRS, é aplicada uma técnica de limiar, considerando apenas os picos acima dos limiares correspondentes à amplitude do maior dos 4 picos mais próximos, e de 30% da amplitude do maior entre os 20 picos mais próximos.

O desempenho do algoritmo implementado para a detecção do complexo QRS foi avaliado na base de dados MIT Arrhythmia Database. Os resultados obtidos foram comparados com outros trabalhos semelhantes utilizando parâmetros estatísticos como Sensibilidade (Se) e Especificidade (PP) calculados utilizando os Verdadeiros positivos (VP), Falsos positivos (FP) e Falsos negativos (FN).

Tabela 1. Tabela comparativa dos resultados da detecção de QRS.

Detector de QRS	Anotações	VP	FP	FN	Se(%)	VPP(%)
Este Trabalho	109500	107805	1695	896	99,18	98,45
Martínez et al.	109428	109208	153	220	99,8	99,86
Hamilton et al.	109267	108927	248	340	99,69	99,77
Pan et al.	109809	109532	507	277	99,75	99,54
Andreão et al.	60259	60062	85	197	99,67	99,86
Madeiro et al.	109494	107808	1073	1686	98,46	99,01

2.4. Segmentação do ECG

Para a segmentação do batimento detectado em ondas (P, complexo QRS e T) foi desenvolvido um algoritmo com o objetivo de se obter o início, o pico e o fim de cada onda do batimento.

Primeiramente, a partir do pico do complexo QRS detectado, faz-se a marcação estimada do ponto de início e fim do batimento, onde o início está a 278 ms à esquerda

e o fim à 430ms à direita. Em seguida, inicia-se para a detecção do início e fim de cada onda do batimento. A partir do pico do complexo QRS, é feita a detecção dos picos adjacentes (onda Q, onda R ou onda S) dentro de um intervalo de tempo de 220 ms. O início e fim do complexo QRS é obtido logo em seguida como sendo o primeiro cruzamento por zero ou transição para uma região de inclinação mais suave que aparecem antes e depois do primeiro e último pico do complexo QRS respectivamente.

Para a detecção da posição das ondas P e T, foram selecionados os pontos de máxima amplitude antes e depois do complexo QRS dentro dos limites estimados para o batimento, definindo-os como a posição dos picos das ondas P e T respectivamente. A partir desses pontos foi feita a mesma análise feita no complexo QRS, adquirindo o primeiro cruzamento com zero ou primeiro trecho com inclinação suave antes e depois das posições dos picos das ondas P e T.

2.5. Seleção e extração de características

Analisando outros trabalhos semelhantes a este e as características comuns a cada anomalia a ser detectada, foram selecionadas 106 características morfológicas para serem utilizadas na classificação, apresentadas na Tabela 2.

Tabela 2. Tabela com todas as características utilizadas

Índice	Característica	Descrição
1-4	RRI(1:4)	Intervalo RR de 2 batimentos anteriores, do atual e 1 posterior.
5	RRIavg	Média dos 10 intervalos RR anteriores.
6	RRIdiv	Desvio padrão dos 10 intervalos RR anteriores.
7	Width	Largura do complexo QRS.
8-11	Pp e Pn	Amplitude máxima positiva e negativa do QRS nos dois canais.
12-17	Arp, Arn e Ar	Área positiva, Área negativa e soma das duas Áreas do complexo QRS nos dois canais.
18-21	lma e lmi	Tempo do início do QRS até o máximo e até o mínimo nos dois canais.
22-23	S1	Inclinação do início do QRS até o primeiro pico do próprio QRS nos dois canais.
24-25	S2	Inclinação do primeiro pico até o segundo pico do complexo QRS nos dois canais.
26-27	diff	Tempo entre o máximo e o mínimo do QRS nos dois canais.
28-29	diffdvt	Maior inclinação durante o QRS nos dois canais.
30-31	diffqrs	Diferença de amplitude entre o máximo e mínimo do QRS nos dois canais.
32-51	QRS_amostr(1:10)	10 amostras do centro do complexo QRS nos dois canais.
52-53	P_amp e P_dur	Amplitude e duração da onda P.
54-55	T_amp e T_dur	Amplitude e duração da onda T.
56	PR_dur	Duração do trecho PR.
57	QT_dur	Duração do trecho QT.
58-77	P_amostr(1:10)	10 amostras do centro da onda P nos dois canais.
78-97	ST_amostr(1:10)	10 amostras do centro do trecho ST nos dois canais.
98-99	P_area	Área da onda P nos dois canais.
100-101	T_area	Área da onda T nos dois canais.
102-103	No	Número de amostras com amplitude acima de 70% do valor máximo nos dois canais.

104-105	Av1	Soma do valor absoluto das velocidades da onda nos dois canais.
106	Freq	Componente de frequência de maior amplitude do sinal.

2.6. Redução da dimensão do vetor de características

Em um vetor de 106 características, é provável que tenhamos redundância e forte correlação entre algumas características extraídas do sinal. Além disso, a complexidade da etapa de classificação cresce com o aumento do número de características. Por conta disso, foi implementada a técnica de Análise de Componentes Principais (*Principal component analysis - PCA*) visando reduzir a dimensão do vetor de características. O PCA é uma técnica estatística útil a qual encontrou aplicação em campos como reconhecimento facial e compressão de imagem, e é muito utilizada para achar padrões em dados de alta dimensão [Smith 2002]. Esta técnica consiste em reduzir um vetor de características, através de uma transformação linear, de forma a perder o mínimo de informação possível.

Neste trabalho, foi aplicada esta técnica no vetor de características, resultando na redução da dimensão de 106 para 25, mantendo 99,93% da informação.

2.7. Classificação automática

Para a classificação automática, foi utilizada uma RNA que é um tipo de classificador baseado em modelos matemáticos que se assemelham às estruturas neurais biológicas e que tem capacidade computacional adquirida por meio de aprendizado e generalização [Assis 2009].

A RNA utilizada foi uma rede Perceptron multicamadas (PMC) composta por uma camada de entrada de dimensão 25, relativa ao vetor de características que é fornecido a ela, duas camadas ocultas com 25 neurônios cada e uma camada de saída com 6 neurônios relativos ao número de classes desejado. Como função de ativação, utilizada para limitar a saída de cada neurônio, foi utilizada a tangente hiperbólica. A configuração da RNA foi definida de forma empírica a partir de experimentos sobre a base de dados.

Para o treinamento da RNA foi utilizado um algoritmo chamado de retropropagação (*backpropagation*), realizando mil épocas, com um gradiente de performance mínima de 10^{-6} , e máximo de falhas de validação igual a 100. A base de dados foi dividida em treinamento, validação e testes. Para isso foram selecionados dois grupos de registros dentro da base de dados utilizada, de forma a se obter uma maior generalização dos dados, além de buscar um equilíbrio entre as quantidades de batimentos de cada classe. Os grupos foram os seguintes: G1 (100, 101, 104, 106, 109, 112, 113, 117, 118, 119, 201, 203, 207, 208, 212, 214, 217, 219, 223, 232, 233, 234) e G2 (103, 105, 107, 111, 115, 116, 121, 122, 123, 202, 205, 209, 210, 220, 221, 222, 230, 231). O grupo G1 foi subdividido em treinamento, com 80% dos batimentos, e validação, com 20% dos batimentos. O grupo G2 foi utilizado apenas para testes.

3. Resultados e Discussão

Com a finalidade de avaliar o desempenho do classificador, alguns parâmetros estatísticos amplamente utilizados foram calculados: Sensibilidade (Se), Especificidade (PP), Valor preditivo positivo (VPP), Valor preditivo negativo (VPN) e Precisão (Ac).

A Sensibilidade (Se), define a sensibilidade do algoritmo em detectar o maior número de anomalias corretamente. A especificidade, é a capacidade do algoritmo em detectar os verdadeiros negativos, ou seja, classificar corretamente quando o batimento não possui determinada anomalia. O Valor Preditivo Positivo (VPP) é a proporção de anomalias detectadas corretamente entre o total de detectadas. O Valor Preditivo Negativo (VPN) é a proporção de exames classificados como não obtendo uma anomalia de forma correta entre todos os exames classificados como não obtendo esta anomalia. A precisão (Ac) é a proporção de acertos de exames com anomalias ou não sobre o total de exames.

A tabela 3 apresenta os resultados do classificador neural com apenas 25 características após a aplicação do método PCA. A matriz confusão informa em cada coluna o resultado da classificação obtida pela rede neural, enquanto que as linhas indicam a anotação manual feita pelo cardiologista. O número de linhas e colunas estão relacionados com as 6 classes citadas anteriormente: Normal (N), bloqueios de ramo esquerdo (L) e direito (R), batimento estimulado (PB), e batimentos ventriculares (V) e atriais (A) prematuros.

Tabela 3. Resultados estatísticos dos testes realizados.

Real	Resultados							Estatísticas								
	N	L	R	PB	V	A	Total	VP	FN	VN	FP	Se (%)	PP (%)	VPP (%)	VPN (%)	Ac (%)
N	32404	189	7	39	206	162	33007	32404	603	6305	777	98,17	89,03	97,66	91,27	96,56
L	67	1754	0	9	222	71	2123	1754	369	37731	235	82,62	99,38	88,19	99,03	98,49
R	117	13	960	0	3	161	1254	960	294	38820	15	76,56	99,96	98,46	99,25	99,23
PB	6	10	0	2056	6	0	2078	2056	22	37952	59	98,94	99,84	97,21	99,94	99,8
V	65	22	8	11	754	38	898	754	144	38726	465	83,96	98,81	61,85	99,63	98,48
A	522	1	0	0	28	178	729	178	551	38928	432	24,42	98,9	29,18	98,6	97,55
Total	33181	1989	975	2115	1219	610	38106	Total: 95,05 90,88 95,11 92,7 96,97								

Os resultados obtidos são satisfatórios, atingindo uma precisão de quase 97%, tendo melhores resultados com batimentos estimulados por terem características bem destacadas, além dos batimentos normais por serem abundantes na base de dados.

O resultado do classificador neural com e sem a redução de dimensão do vetor de características foi comparado a outros trabalhos que utilizaram a mesma base de dados, conforme apresentado na tabela 4. É importante ressaltar que o agrupamento dos batimentos em classes variou entre os trabalhos, sendo que neste trabalho foram selecionadas as 6 classes mais abundantes na base de dados, sem realizar nenhum tipo de agrupamento.

Tabela 4. Resultados estatísticos dos testes realizados.

Trabalho	Nº de classes	Se (%)	PP (%)	VPP (%)	VPN (%)	Ac (%)
Este Trabalho (Sem PCA)	6	95,89	90,99	95,04	94,9	97,41
Este Trabalho (Com PCA)	6	95,05	90,88	95,11	92,7	96,97
Christov et al. (2006)	5	96,22	98,43	96,64	94,02	97,54
Chazal et al. (2004)	5	85,87	94,35	95,06	52,55	88,58
Chazal et al. (2006)	5	93,89	95,52	96,53	71,24	94,8

Ince et al. (2009)	5	95,58	86,76	95,84	84,26	96,63
Kim et al. (2011)	5	97,51	85,08	97,26	96,6	97,94
Llamedo et al. (2011)	4	78,00	96,70	95,83	41,71	81,45
Zhang et al. (2013)	4	88,35	93,34	95,31	57,24	90,19

4. Conclusões e propostas futuras

O trabalho desenvolvido conseguiu alcançar os objetivos propostos, uma vez que foi desenvolvido um algoritmo capaz de classificar cada batimento em um sinal de ECG, obtido na forma digital, em seis classes diferentes: Normal (N), Bloqueio do ramo direito (R), Bloqueio do ramo esquerdo (L), Ventricular prematuro (V), Atrial prematuro (A) e batimento estimulado (PB). A definição do número de classes dependeu da disponibilidade de bases de dados com quantidade de exemplos significativa para cada classe implementada. Em trabalhos futuros, utilizando outras bases de dados, é possível ampliar o número de classes, seguindo a metodologia proposta neste trabalho.

O sistema desenvolvido foi capaz de pré-processar o sinal do ECG, preparando-o para as etapas de detecção do complexo QRS (também chamada de detecção do batimento) e segmentação do batimento. A detecção dos complexos QRS atingiu uma sensibilidade de 99,18%, um valor preditivo positivo de 98,45%. Foi realizada uma segmentação do sinal de ECG através de técnicas simples, baseada em limiares de amplitude e duração. A partir dessa segmentação e da localização de cada batimento, foi extraído um vetor de 106 características morfológicas diretamente do sinal de ECG. Este vetor de características por ser muito grande para ser aplicado diretamente no classificador, foi reduzido utilizando a técnica de PCA. Apesar da redução da dimensão de 106 características para 25, o resultado da classificação não sofreu uma queda muito significativa.

Os resultados de uma maneira geral foram considerados muito bons se comparados aos outros trabalhos da literatura atingindo uma precisão de quase 97% e uma sensibilidade de 95%. Apesar disso, após uma análise dos erros encontrados, identificou-se algumas limitações que serão objeto de trabalhos futuros. A maior delas está na classificação de batimentos atriais prematuros (A) que foram confundidos com batimentos normais (N). Isto se deve ao fato destas duas classes de batimentos terem morfologias semelhantes, apresentando uma pequena diferença no valor do intervalo RR que antecede o batimento atual. Também ocorreram problemas na classificação de batimentos de bloqueio de ramo direito (R) que são mais dificilmente identificados em determinadas derivações, e como a base de dados utiliza diferentes derivações nos diferentes registros, isto pode ter prejudicado os resultados. Outro problema identificado foi na classificação de batimentos ventriculares prematuros (V) que pode ter ocorrido em situações em que a sua principal característica, que é a ocultação da onda P, não tenha sido percebida.

Este trabalho será adaptado e utilizado posteriormente em um sistema real de triagem a ser implementado na Plataforma Salus de Telecardiologia do Programa Telessaúde Espírito Santo. Conseqüentemente, o pré-diagnóstico obtido pelo algoritmo desenvolvido será utilizado pela Plataforma na reordenação dos exames de ECG enviados pelas Unidades de Saúde, de forma que os médicos que irão realizar o

diagnóstico, analisem primeiramente os exames pré-classificados com anomalias mais urgentes.

Agradecimento

Os autores agradecem o suporte financeiro do CNPq na realização desta pesquisa.

Referências

- Andreão, R. V.; Dorizzi, B.; Cortez, P. C.; Mota, J. C. M. (2002) “Efficient ECG multi-level wavelet classification through neural network dimensionality reduction”, CAPES/COFECUB projeto nº 266/99-I.
- Andreão, R. V.; Sarti T.; Clestrini, J.; Schimidt, M. Q. (2013) “Automatic Triage of Electrocardiograms”, *Global Telemedicine and eHealth Updates: Knowledge Resources*, vol. 6, p. 143-147.
- Arif, M.; Akram, M. U.; Afsar, F. A. (2009) “Arrhythmia Beat Classification using Pruned Fuzzy K-Nearest Neighbor Classifier”, *International Conference of Soft Computing and Pattern Recognition*.
- Assis, P. O. (2009) “que são Redes Neurais?”, <http://www.tecmundo.com.br/programacao/2754-o-que-sao-redes-neurais-.htm>, fevereiro de 2015.
- Chazal, P. D.; O’Dwyer, M.; Reilly, R. B. (2004) “Automatic Classification of Heartbeats Using ECG Morphology and Heartbeat Interval Features” *IEEE Transactions on Biomedical Engineering*, vol. 51, no. 7, p. 1196-1206.
- Chazal, P.D.; Reilly, R. (2006) “A patient-adapting heartbeat classifier using ECG morphology and heartbeat interval features”, *IEEE Trans Biomed Engineering*, vol. 53, p. 2535-2543.
- Christov, I.; Gómez-Herrero, G.; Krasteva, V.; Jekova, I.; Gotchev, A.; Egiazarian, K. (2006) “Comparative study of morphological and time-frequency ECG descriptors for heartbeat classification”, *Medical Engineering & Physics*, vol. 28, p. 876–887.
- Hamilton, P. S.; Tompkins, W. (1986) “Quantitative investigation of QRS detection rules using the MIT/BIH arrhythmia database”, *IEEE Trans Biomed Engineering*, vol. 33, p. 1157-1165.
- Igarashi, M. O. (2007) “Utilização de filtros para remoção de interferência de sinais de eletrocardiograma”, Trabalho de graduação interdisciplinar, Escola de Engenharia da Universidade Presbiteriana Mackenzie, São Paulo.
- Ince, T.; Kiranyaz, S.; Gabbouj, M. (2009) “A generic and robust system for automated patient-specific classification of ECG signals”, *IEEE Trans Biomed Engineering*, vol. 56, p.1415-1426.
- Kim, J.; Min, S. D.; Lee, M. (2011) “An arrhythmia classification algorithm using a dedicated wavelet adapted to different subjects” *BioMedical Engineering OnLine*.
- Llamedo, M.; Martínez, J. (2011) “Heartbeat classification using feature selection driven by database generalization criteria”, *IEEE Trans Biomed Engineering*, vol. 58, p. 616–625.

- Madeiro, J. P. V.; Cortez, P. C.; Oliveira, F. I.; Siqueira, R. S. (2007) "A new approach to QRS segmentation based on wavelet bases and adaptive threshold technique", *Medical Engineering & Physics*, vol. 29, p. 26–37.
- Marcolino, M.; Alkmim, M. B.; Palhares, D.; Ribeiro, A. L. (2012) "Prevalence of Normal Electrocardiograms in Primary Care Patients: a Study by a Telemedicine Service in Brazil", *Global Telemedicine and eHealth Updates: Knowledge Resources*, vol. 5, p. 615-618.
- Martínez, J. P.; Almeida, R.; Olmos, S.; Rocha, A. P.; Laguna, P. (2004) "A wavelet-based ecg delineator evaluation on standard databases", *IEEE Transactions on Biomedical Engineering*, v. 51, p. 570–581.
- Mohamad, F. N.; Megat Ali, M. S. A.; Jahidin, A. H.; Saaid, M. F.; Noor, M. Z. H. (2013) "Principal Component Analysis and Arrhythmia Recognition Using Elman Neural Network", 4th Control and System Graduate Research Colloquium, Shah Alam, Malásia.
- Pan, J.; Tompkins, W.J. (1985) "A real-time QRS detection algorithm", *IEEE Trans. Biomed Engineering*, vol. 32, p.230-236.
- Physionet (2000) "Physionet o recurso de pesquisa para sinais fisiológicos complexos", <http://www.physionet.org>, janeiro de 2014.
- She, L.; Song, Y.; Zhang, S.; Xu, Z. (2010) "A Precise Ambulatory ECG Arrhythmia Intelligent Analysis Algorithm Based On Support Vector Machine Classifiers" 3rd International Conference on Biomedical Engineering and Informatics.
- SMITH, L. I. (2002) "A Tutorial on Principal Component Analysis".
- Sparenberg, A.;Fetter, G.. (2012) "A Public Telecardiology Network in Southern Brazil: Results of Phase II (1st Year)", *Global Telemedicine and eHealth Updates: Knowledge Resources*, Vol. 5, p. 598-602.
- Zhang, Z.; Dong, J.; Luo, X.; Choi, K.; Wu, X. (2013) "Heartbeat classification using disease-specific feature selection" *Computers in Biology and Medicine*, vol. 46, p. 79–89.