

# CLASSIFICAÇÃO NEURAL SOM E MLP DE INDIVÍDUOS NORMAIS, CHAGÁSICOS E HIPERTENSOS POR MEIO DE ANÁLISE DA VARIABILIDADE DA FREQUÊNCIA CARDÍACA

R. R. Lima, S. F. Andrade, A. Bauchspiess, J. L. A. Carvalho

Departamento de Engenharia Elétrica/Universidade de Brasília, Brasília-DF, Brasil

joaoluiz@pgea.unb.br

**Abstract:** The use of artificial intelligence methods applied to biomedical signals has proved very useful in computer-aided diagnosis. The analysis of heart rate variability (HRV) signals allows non-invasive assessment of the vagal-sympathetic balance, controlled by the autonomic nervous system. This paper presents a system for identification of normality, mild to moderate hypertension, and Chagas' disease, through processing, feature extraction, analysis, feature selection, dimensionality reduction (using self-organizing maps), and pattern classification (using multi-layer perceptrons) of HRV signals. The proposed approach may potentially be adapted for identifying other autonomic conditions.

**Palavras-chave:** SOM, MLP, redes neurais, HRV, diagnóstico auxiliado por computador

## Introdução

A análise da variabilidade da frequência cardíaca (VFC) permite a avaliação do sistema nervoso autônomo (SNA) e de como as atividades simpática (aumento da frequência cardíaca) e parassimpática (redução na frequência cardíaca) do sistema nervoso influenciam o ritmo cardíaco [1]. Por meio dessa observação é possível detectar doenças e anormalidades que comprometem outras atividades do organismo, pois o SNA é responsável pelo controle de diversas atividades importantes do corpo humano.

A inteligência artificial tem sido usada nas mais diversas áreas da medicina, dentre as quais podem ser citadas a predição de tipos de câncer [2], a estimação do ângulo da articulação do joelho a partir de sinais eletromiográficos para controle de próteses [3] e o diagnóstico de epilepsia com sinais de eletroencefalografia por *perceptrons* multicamadas [4]. O processo de classificação pode ser dividido em: pré-processamento, processamento, extração de parâmetros principais e, enfim, a classificação por redes neurais.

Este trabalho apresenta um método de auxílio ao diagnóstico por meio da classificação entre indivíduos normais, chagásicos e hipertensos, com base nas alterações observadas nas características do sinal de VFC. As patologias a serem abordadas são pertinentes ao método, visto que geram alterações no equilíbrio do

SNA. Entretanto, outras patologias como apneia, epilepsia, sudorese gustativa, problemas de pressão sanguínea, ou até mesmo atividades físicas e de descanso poderiam ser abordadas, pelo mesmo motivo.

## Classificação de Padrões

O reconhecimento de um padrão entre os sinais de VFC dos grupos de indivíduos estudados neste trabalho não é trivial (Figura 1). Em inteligência artificial, existem diversas opções disponíveis para a classificação de padrões. Há métodos mais simples, como o *perceptron* [5] ou máquinas de vetores de suporte, que fazem a classificação de maneira linear. Entretanto, para problemas não linearmente separáveis, podem ser utilizados, por exemplo, métodos de estimação de kernel [6] e redes neurais como a rede *perceptron* de múltiplas camadas (*multi-layer perceptron*, ou MLP). Caso as dimensões não sejam linearmente separáveis, como ocorre neste trabalho, após o posicionamento das redes SOM, os métodos lineares se mostram insuficientes. Aqui, as redes MLP serão utilizadas.

**Redes SOM** - Os mapas auto-organizáveis de Kohonen (*self-organizing maps*, ou SOM) [5] são considerados uma arquitetura de redes neurais de estrutura reticulada com aprendizado competitivo. Isso significa que, diferentemente de muitas estruturas de redes neurais que necessitam de um padrão de entradas e saídas para o treinamento, em redes SOM somente o padrão de entrada é levado em consideração nessa etapa.

**Redes *perceptron* de múltiplas camadas** - As redes MLPs [5] são caracterizadas pela presença de pelo menos uma camada intermediária (escondida) de neurônios, situada entre a camada de entrada e a respectiva camada neural de saída. A rede MLP pertence à arquitetura *feedforward*, cujo treinamento é efetuado de forma supervisionada (leva em consideração a entrada e a saída desejada). A propagação de sinais de entrada das redes MLP é sempre realizada num único sentido, da camada de entrada em direção à camada de neural de saída. Já o processo de treinamento de uma rede MLP pode ser dividida em duas fases: *forward* e *backward*, e ocorre enquanto o erro quadrático médio for maior que determinado valor [5].

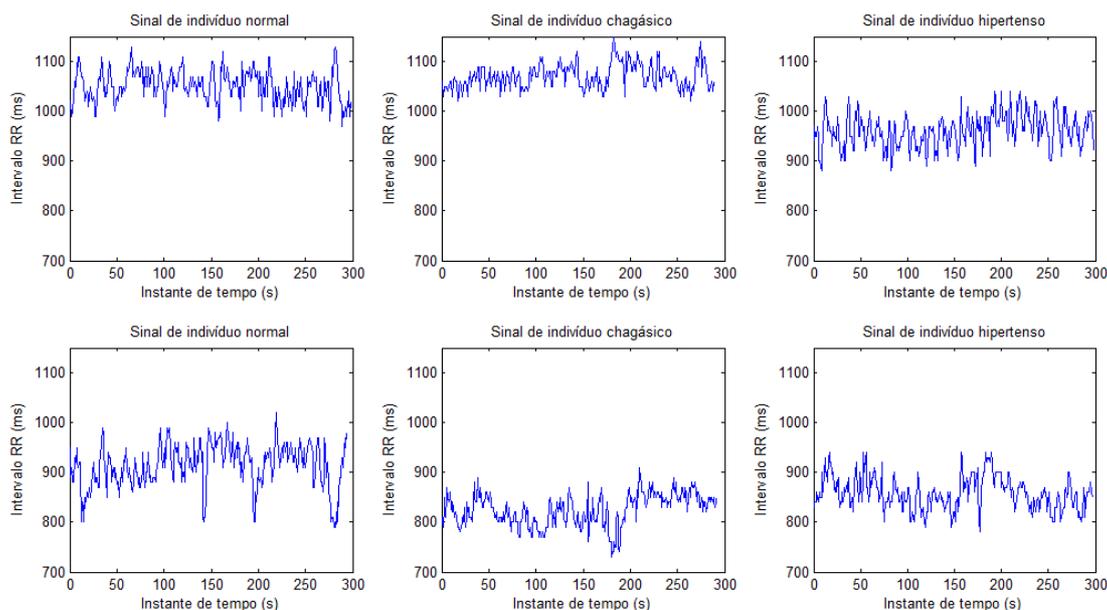


Figura 1: Amostra de sinais de intervalos RR para os três tipos de indivíduos a serem classificados. Nem sempre o reconhecimento de um padrão visual é direto, pois os sinais variam muito de um indivíduo para outro.

## Materiais e Métodos

Foram utilizados 58 sinais de VFC (séries de intervalos RR tratados) com aproximadamente 5 minutos de duração cada. Os primeiros 32 sinais lidos correspondem a indivíduos normais [7,8]; os 13 seguintes a indivíduos com hipertensão leve ou moderada [8] e os 13 últimos correspondem a indivíduos vagais [9]. Essa ordem foi assim convencionada para favorecer o desenvolvimento do algoritmo. A análise foi feita usando o software MATLAB (MathWorks, Natick).

**Processamento dos sinais** – Cada sinal foi processado e dele foram extraídos diversos parâmetros, a saber: os percentis de 25%, 50% e 75%; a faixa de valores RR (diferença entre o maior e o menor valor de cada sinal); média; desvio padrão; variância; coeficiente de variação (desvio padrão dividido pela média); porcentagem do sinal com tendência ao aumento ou diminuição da frequência (se duas diferenças entre amostras sucessivas mostram aumento no intervalo RR, isso configura uma tendência à redução da frequência cardíaca, e vice-versa); o coeficiente de correlação entre amostras sucessivas; centroide do *plot* de Poincaré [1]; o valor quadrático médio das diferenças entre duas amostras sucessivas; a porcentagem de diferenças sucessivas superiores a 50 ms; as energias associadas às altas e baixas frequências (definidas aqui como de 0,15 Hz a 0,40 Hz, e de 0,05 Hz a 0,15 Hz, respectivamente), calculadas a partir do espectro densidade de potência, obtido a partir do modelo auto-regressivo; e a razão entre a energia de baixa e a de alta frequência.

As variáveis, mapeadas, foram numeradas assim:

- 1 – percentil de 25%;
- 2 – percentil de 50% (mediana);
- 3 – percentil de 75%;
- 4 – faixa de valores RR;
- 5 – média;

- 6 – desvio padrão;
- 7 – variância;
- 8 – coeficiente de variação;
- 9 – porcentagem de diminuição da frequência cardíaca;
- 10 – porcentagem de aumento da frequência cardíaca;
- 11 – RMSSD (valor quadrático médio entre duas diferenças sucessivas);
- 12 – pNN50 (porcentagem das diferenças entre intervalos RR sucessivos as quais são maiores que 50 ms);
- 13 – valor no eixo x do centroide de Poincaré
- 14 – valor no eixo y do centroide de Poincaré
- 15 – energia de alta frequência;
- 16 – energia de baixa frequência;
- 17 – razão entre energias de baixa e alta frequência;
- 18 – coeficiente de correlação.

Com esse conjunto de coeficientes para representar cada sinal, foi montada, seguindo a ordem listada acima, uma matriz 18x58, a fim de possibilitar uma inspeção visual que permita extrair os dados mais relevantes para passar à rede SOM (Figura 2).

A partir da análise dessas variáveis (ver seção de Resultados), constatou-se que algumas delas tinham mais correlação com a distinção entre normais e patológicos e outras apresentavam maior influência na distinção entre os vagais e os hipertensos. Portanto, a identificação do grupo foi feita em duas etapas.

**Seleção das variáveis e rede SOM na primeira classificação** – Esta etapa consistiu em separar os indivíduos normais dos patológicos. Com base na análise dos resultados obtidos na etapa anterior, foram selecionadas as variáveis 4, 9 e 11. Estas variáveis são determinantes na separação entre os dois grupos, contudo sem apresentar grande correlação entre si.

Tais variáveis foram inseridas numa rede SOM com 9 linhas de neurônios e 8 colunas. Para isso, outro aspecto importante realizado foi o embaralhamento dos sinais dentro de uma matriz, contudo, mantendo suas

posições conhecidas. O conhecimento da classificação correta de cada uma ficou conhecido pela definição de um *target* igualmente embaralhado. Esse processo de embaralhamento permitiu o melhor ajuste de cada amostra na saída da rede SOM, durante o treinamento.

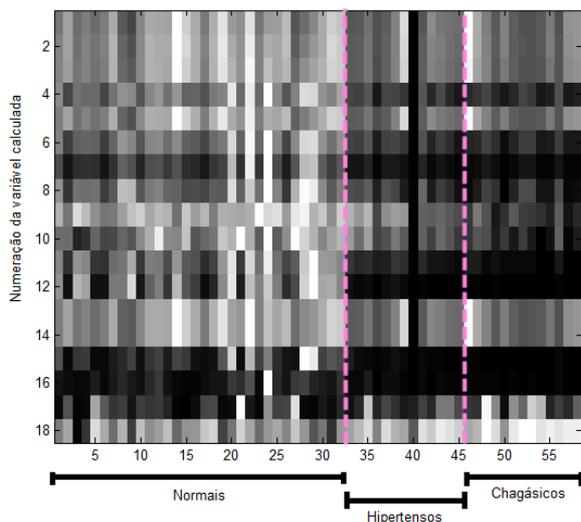


Figura 2: Variáveis de 1 a 18 para cada sinal, conforme a ordem estabelecida para indivíduos normais (1 a 32), hipertensos (33 a 45) e chagásicos (46 a 58). Para obter o gráfico, as variáveis foram normalizadas e tiveram seu valor mínimo subtraído, para facilitar a visualização. Os valores maiores estão em cores claras.

O posicionamento dos neurônios seguiu a topologia *hextop*, que corresponde ao arranjo reticulado hexagonal entre os neurônios. Foram utilizadas cerca de 2500 épocas para o treinamento. O resultado de tal classificação permitiu a redução de dimensionalidade, de três para duas variáveis de entrada, correspondentes ao posicionamento resultante das amostras. Além disso, uma das vantagens da aplicação da rede SOM antes da rede MLP é a capacidade que a SOM tem de permitir a conferência da separação das amostras (permite visualizar se as amostras de treinamento, cujo *target* é conhecido, estão bem separadas). As saídas da rede SOM corresponderam a entradas para a rede MLP.

**Rede MLP na primeira classificação** – Para o treinamento de redes MLP, a fim de separar os indivíduos normais dentre os demais, foram utilizados 20 neurônios. Foi utilizada a função de ativação *logsig*.

O *target* foi previamente definido como uma matriz  $2 \times 58$ . As colunas correspondem aos diferentes indivíduos. A cada indivíduo é atribuído o vetor coluna  $(1,0)^T$  se normal ou  $(0,1)^T$  se patológico.

Ao todo, foram testadas redes com um total de 10 a 40 neurônios, com 70% dos dados para treino, 15% para validação e 15% para teste. Esta classificação visa somente separar indivíduos normais dos patológicos.

**Seleção das variáveis e rede SOM na segunda classificação** – A segunda classificação teve como objetivo fazer a distinção entre os chagásicos e os hipertensos (portanto, trabalhou-se apenas com 26 sinais, sendo 13 de cada grupo). Foram analisadas então

as variáveis que melhor auxiliariam na classificação desta etapa. As variáveis escolhidas para serem usadas na rede SOM, neste caso, foram 9, 10 e 11.

Os indivíduos foram embaralhados e suas variáveis lançadas à rede em uma matriz 3 (número de variáveis utilizadas) por 26 (número de indivíduos patológicos).

Como na primeira classificação, aqui o *target* criado ficou conformemente embaralhado para permitir a identificação posterior de cada sinal. Foi utilizada uma rede com 8 linhas e 5 colunas de neurônios, e posicionamento do tipo *hextop*. Foram utilizadas cerca de 3000 épocas para o treinamento. As saídas da rede SOM corresponderam à entrada da MLP.

**Rede MLP na segunda classificação** – Foram utilizados 10 neurônios para a MLP, com função de ativação *logsig* para a classificação entre os indivíduos patológicos. O *target* foi previamente definido como sendo composto de uma matriz de 2 linhas por 26 colunas. Cada coluna corresponde a um indivíduo. A cada indivíduo é atribuído o vetor coluna  $(1,0)^T$  se hipertenso ou  $(0,1)^T$  se chagásico.

Como aqui se tem menos dados do que na primeira classificação (26, contra 58 da primeira), não se julgou estatisticamente adequado utilizar dados de validação. Cada dado tinha muita importância para o treinamento. Não foram, entretanto, utilizados todos os dados com esta finalidade, visto que, caso isso fosse feito, a avaliação da porcentagem de acertos poderia não atentar para o fato de a rede não estar preparada para considerar casos novos. Foram utilizados, portanto, na primeira abordagem, 80% de dados para treino e 20% para teste, e em seguida 70% de treino e 30% de teste.

## Resultados

**Primeira classificação** – Por meio da primeira classificação, que pode ser caracterizada como a identificação de patologia, após o treinamento e simulação da rede SOM com todos os dados, foi obtida a topologia registrada na Figura 3. Nota-se que, apesar de a rede ter um processo de treinamento não-supervisionado, a separação entre os indivíduos patológicos e normais ficou evidente. Infere-se ainda que os parâmetros escolhidos foram bons para a correta separação entre normais (lado esquerdo, com o símbolo estrela) e os demais (lado direito, com o símbolo circular e a letra 'h' para os hipertensos; o ponto e a letra 'c' para os chagásicos).

Em seguida, foi realizado o treino da rede MLP, utilizando como entrada uma parte dos dados de posicionamento correspondentes aos obtidos pela topologia SOM. Depois, foi feita a etapa de teste com o restante dos dados de posicionamento. Os resultados obtidos nesta etapa foram considerados relevantes: cada simulação feita resultava em nenhum erro ou erro na classificação de apenas 1 dos dados (correspondendo a cerca de 98% de acerto no total). Considerando somente os dados da simulação (30% dos totais), isso corresponde a um acerto de cerca de 93,3%.

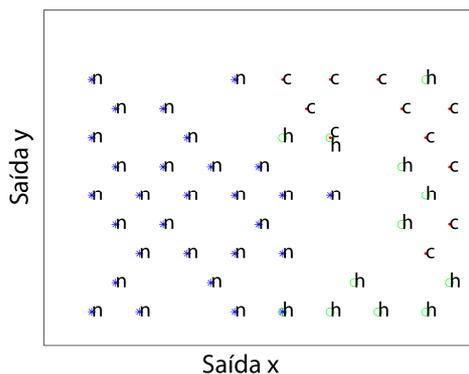


Figura 3: Mapeamento dos sinais 1 a 58 com variáveis 4, 9 e 11 de entrada.

**Segunda classificação** – Esta classificação pode ser considerada a etapa de “diagnóstico”. Para isso, foram utilizados apenas os dados dos sinais dos indivíduos patológicos. A ideia é que esta seja uma classificação posterior à primeira, que separará os indivíduos normais dos patológicos. A ocorrência de possíveis falsos positivos na classificação da primeira etapa não gera danos às demais classificações, visto que a rede já vai estar treinada originalmente, com dados conhecidos.

A Figura 4 mostra o mapeamento do comportamento das variáveis para esses 26 sinais. Nota-se que algumas variáveis dos indivíduos hipertensos têm valores mais altos que as dos demais. Entretanto, alguns sinais não obedecem a essas hipóteses, portanto, essa é uma classificação mais difícil que a anterior.

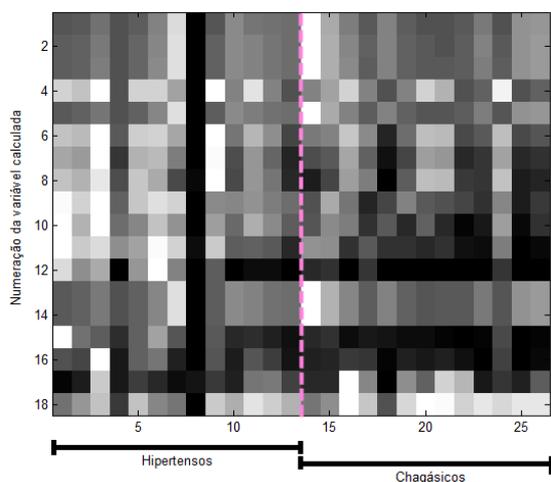


Figura 4: Comportamento das variáveis de 1 a 18 para cada sinal, conforme a ordem estabelecida, para os sinais dos indivíduos hipertensos (de 1 a 13) e chagásicos (14 a 26). Para obter o gráfico, as variáveis foram normalizadas e tiveram seu valor mínimo subtraído, para facilitar a visualização. Os valores maiores estão em cores claras.

A Figura 5 mostra o resultado da simulação após o treinamento da rede SOM, com o posicionamento resultante de cada amostra. Com algumas exceções, é possível observar um padrão na separação dos sinais nesse mapa. Apesar de algumas amostras entre as classes se misturarem, de forma geral os indivíduos hipertensos estão bem separados dos chagásicos.

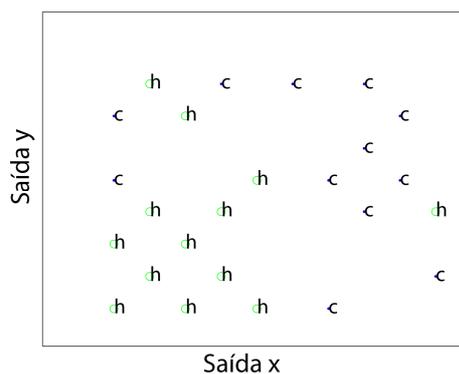


Figura 5: Mapeamento dos sinais de hipertensos e chagásicos, com variáveis 9, 10 e 11 de entrada.

Tanto na primeira abordagem (80% de treino) quanto na segunda (70%), com uma boa configuração de SOM obtida (Figura 5), foram verificados erros, na simulação, em 1 ou 2 amostras, o que corresponde a cerca de 92% a 96% de acerto entre o total dos dados, e cerca de 80% (primeira abordagem) ou 73,4% (segunda abordagem) entre os dados de teste.

## Discussão

A quantidade de erros foi observada em relação ao conjunto dos dados de validação, teste e treino. A fim de tomar o pior caso, considerou-se que o acerto de validação e treino era de 100%, e que todo o erro era oriundo somente de dados de teste. A porcentagem final de acerto era então calculada como o número de dados de teste subtraído dos erros totais observados, e a seguir dividido pelo número de dados de teste.

Um dos aspectos importantes de fazer a classificação em duas etapas foi o fato de que a rede SOM pôde, em cada uma, concentrar seus esforços nas variáveis que tinham maior significância na distinção entre os dados. Ao tentar separar de maneira conjunta, inicialmente, os resultados na separação não foram tão significativos. É interessante notar, nas Figuras 2 e 4, que os dados apresentados do lado esquerdo em cada uma tinham valores mais altos (representados por cores mais quentes) que os da direita, de uma forma geral. Na Figura 2, esses dados correspondem aos indivíduos normais. Na Figura 4, esses dados correspondem aos indivíduos hipertensos.

Apesar de a etapa de teste ter sido feita em grande parte sobre dados que já haviam sido utilizados para treino, não se considera esse um fator crítico, visto que, nas redes SOM, notou-se um padrão na forma como os dados se organizavam, e espera-se que novos dados sigam esse mesmo padrão, ou semelhante. Para um conjunto maior de amostras, acredita-se que os resultados seriam ainda melhores.

Um ponto importante de se esclarecer é quanto à aparente ausência de muitos dados nos mapeamentos SOM (Figuras 3 e 5). Na verdade, deve-se saber que cada amostra está associada a um neurônio, e que cada um desses neurônios ocupa uma posição bem definida. Portanto, podem ocorrer alguns casos onde há, nos mapas, mais de uma amostra ocupando a mesma

posição. Isso pode ser verificado facilmente na Figura 3, em que há um dado de indivíduo hipertenso ocupando o mesmo neurônio de um indivíduo chagásico, e outro de um indivíduo hipertenso ocupando o mesmo neurônio de um indivíduo normal, por exemplo.

Verificou-se que os parâmetros faixa de RR, porcentagem de diminuição da frequência cardíaca e RMSSD (variáveis 4, 9 e 11) tinham grande influência na classificação entre indivíduos normais e patológicos (doença de Chagas ou hipertensão), conforme apresentado na Figura 2. A inferência ao concluir este trabalho é de que, portanto, para tais patologias ocorre uma alteração no ritmo cardíaco no sentido de mantê-lo aproximadamente menos variante do que o normal, por falta de compensação adequada entre os sistemas simpático e parassimpático (tais parâmetros tinham valores menores para os chagásicos e hipertensos). Além disso, da literatura, sabe-se que o RMSSD tem alta correlação com as energias de alta frequência, portanto, com o sistema nervoso parassimpático, uma vez que este responde mais rápido que o simpático, de forma geral. Portanto, nesse caso, pode-se inferir que os indivíduos normais têm a atividade parassimpática mais elevada que os patológicos. No caso dos hipertensos, isso se deve provavelmente à hiperatividade não devidamente compensada do sistema nervoso simpático, como costuma ocorrer entre esses indivíduos (a existência de uma hiperatividade simpática tem sido frequentemente associada à hipertensão arterial) [10].

Verificou-se um evento semelhante na classificação entre os hipertensos e os chagásicos, sendo que estes apresentavam valores um pouco menores do que aqueles (ver Figura 4), para porcentagem de aumento ou diminuição da frequência cardíaca e RMSSD (variáveis 9, 10 e 11). Portanto, uma inferência semelhante pode ser feita (indivíduos com hipertensão leve ou moderada têm maior atividade parassimpática que os chagásicos).

Deve-se levar em conta que, além de se estar considerando mais de um nível de hipertensão (leve e moderada), a dificuldade de classificação é aumentada pelo fato de que usualmente os indivíduos têm características fisiológicas distintas entre si e, portanto, a comparação em apenas um fator (no caso, hipertensão vs. doença de Chagas, ou normalidade vs. patologia) pode não ser totalmente evidente. Portanto, os resultados de acerto acima de 90% e a rede SOM com classes bem separadas superaram as expectativas.

## Conclusão

Este trabalho apresentou um método de classificação entre indivíduos normais, com hipertensão (leve ou moderada) e com doença de Chagas, a partir de sinais pré-processados de cerca de 5 minutos cada. De uma maneira geral, este trabalho apresentou resultados bastante satisfatórios. O sucesso de classificação para a identificação entre normais e patológicos foi de 93,3% (considerando somente os dados de teste) e para a classificação entre chagásicos e hipertensos foi de até 80% (somente dados de teste). Essas taxas de acerto são

comparáveis a de outros trabalhos semelhantes (que tratam da identificação por redes neurais aplicadas a sinais de VFC), com acerto de cerca de 85-95% [11]. O método proposto pode ser útil na investigação de parâmetros e variáveis com maior ou menor influência em cardiopatias, bem como ser um facilitador no diagnóstico de diversas patologias.

Em trabalhos futuros, propõe-se que novos estudos sejam feitos com uma quantidade maior de dados. Propõe-se ainda um estudo de diagnóstico diferencial entre indivíduos cardiopatas e os patológicos tratados aqui, a fim de evitar falsos positivos na classificação.

## Agradecimentos

Os autores agradecem ao Prof. Luiz Fernando Junqueira Jr. e à equipe do Laboratório Cardiovascular da Faculdade de Medicina da Universidade de Brasília, por fornecerem os sinais utilizados neste trabalho.

## Referências

- [1] Carvalho, J.L.A. (2003), *Ferramenta para análise tempo-frequencial da variabilidade da frequência cardíaca*, Dissertação de Mestrado, Departamento de Engenharia Elétrica, FT/UnB, Brasília, 113 p., fev.
- [2] Khan, J. et al (2001), "Classification and diagnostic prediction of cancers using gene expression profiling and artificial neural networks", *Nature Medicine*, USA, v. 7, n. 6, p. 673-79.
- [3] Delis, A.L. et al (2009), "Estimation of knee joint angle from surface electromyographic signals for active control of leg prostheses", *Physiological Measurement*, UK, v. 30, n. 9, p. 931-46.
- [4] Isik, H. and Sezer, E. (2012), "Diagnosis of Epilepsy from Electroencephalography Signals Using Multilayer Perceptron and Elman Artificial Neural Networks and Wavelet Transform", *Journal of Medical Systems*, v. 36, n. 1, p. 1-13.
- [5] Silva, I.N., Spatti, D.H., Flauzino, R.A. (2010), *Redes neurais artificiais para engenharia e ciências aplicadas*, São Paulo: Artliber editora.
- [6] Shawe-Taylor, J., Cristianini, N. (2004), *Kernel Methods for Pattern Analysis*, Cambridge: Cambridge University Press.
- [7] Jesus, P.C. (1996), *Considerações Metodológicas e Caracterização de Procedimentos Implicados nas Análises Temporal e Espectral da Variabilidade da Frequência Cardíaca para Avaliação Clínica da Função Autonômica Cardíaca*, Dissertação de Mestrado, Faculdade de Saúde, Universidade de Brasília.
- [8] Correia Filho, D. (2000), *Avaliação Clínico-Funcional, Bioquímica e Imunológica do Sistema Nervoso Autônomo em Residentes em Área Endêmica da Doença de Chagas*, Tese de Doutorado, Universidade Federal de Minas Gerais.
- [9] Junqueira Jr L.F., Oliveira L.C., Pereira F., Jesus P.C., Carvalho H. (2001), "Depressed Sympathetic and Enhanced Parasympathetic Reflex Responses of Heart Rate in Arterial Hypertension", *Rev. Fed. Arg. Cardiol*, v. 30, p. 357-58.
- [10] Guzzetti, S., Piccaluga, E., Casati, R., et al. "Sympathetic predominance in essential hypertension: a study employing spectral analysis of heart rate variability", *J Hypertens*, v.6, n. 9, p. 711-7.
- [11] Acharya, U. R. et al. "Classification of heart rate data using artificial neural network and fuzzy equivalence relation", *Pattern Recognition*, v. 36, n. 2003, p. 61-8.