Uso de Mapas Auto-Organizáveis na Classificação de Quantificadores de Mapa de Recorrência de Batimentos Cardíacos

Liu, Y. L.[1], **Macau, E. E. N.**[1], **Barroso, J. J.**[1]

[1]Instituto Nacional de Pesquisas Espaciais, 12227-010, São José dos campos, SP, Brasil.

{liu.ling,elbert}@lac.inpe.br, barroso@plasma.inpe.br

Resumo. *As doenças cardiovasculares têm sido a maior causa de morte por doença em todo o território nacional. Atualmente, uma das grandes aliadas para a realização de estudo da fisiopatologia de sistemas biológicos, no campo das doenças do coração, é a técnica conhecida como Variabilidade da Freqüência Cardíaca (VFC). Porém, a VFC apresenta comportamento complexo, o que dificulta a identificação de padrões de doenças específicas. Neste trabalho utilizamos redes neurais do tipo de Mapas Auto-Organizáveis (SOM) para a Análise de Quantificação de Recorrência (RQA) em dados de VFC, sendo que o objetivo principal é determinar qual dos dois conjuntos de diagnósticos (tradicionais ou baseados em RQA) contém mais informação para diferenciar os grupos de pacientes.*

Abstract. *Cardiovascular diseases are the major cause of death in our country. Currently, a main ally to the realization of the pathophysiology studies of biological systems in the field of heart diseases is the technique known as the heart rate variability (HRV). However, the HRV has a complex behavior, making it difficult to identify patterns of specific diseases. In this work, we use the self-organized maps neural networks for the recurrence quantification analysis (RQA) on data from HRV, having as the main objective is to determine which of two sets of diagnoses (based on traditional or RQA) contains more information to distinguish between groups of patients.*

1. Introdução

No mundo atual há um aumento considerável do número de pessoas afetadas por doenças de ordem cardiovascular. Em decorrência desse fato, especialistas trabalham continuamente na busca por mecanismos que permitam reverter esse quadro ou minimizar seus efeitos na vida dessas pessoas. Nesse sentido, vem sendo explorado com sucesso nos últimos anos técnicas para diagnóstico antecipado de doenças cardíacas baseadas na análise da variabilidade da freqüência cardíaca. Estudos recentes mostram que a Variabilidade da Freqüência Cardíaca (VFC) fornece um poderoso meio de observar a interação entre o sistema nervoso simpático e parassimpático.

A VFC é um sinal não-estacionário, cuja variação pode nos fornecer indicadores de doença ou avisos antecipados sobre doenças cardíacas iminentes. Esses indicadores podem estar presentes em todos os momentos ou ocorrer esporadicamente durante certos

intervalos do dia. Por conseguinte, eles se caracterizam por serem ferramentas não invasivas e pouco dispendiosas para avaliação do estado de saúde do sistema circulatório [Rajendra Acharay 2006].

O sinal de VFC consiste de uma série de intervalos de tempo entre as ondas R do ECG - série de intervalos RR (veja a figura(1)). A freqüência dos batimentos cardíacos pode ser facilmente determinada pelo eletrocardiograma, pois a freqüência cardíaca é a recíproca do intervalo de tempo entre dois batimentos sucessivos. Ao longo deste trabalho, o sinal de VFC é referenciado como série de intervalos RR.

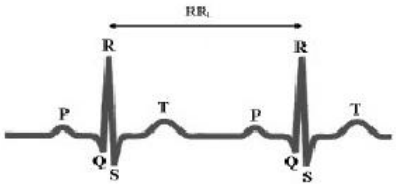

Figura 1. A série de intervalo RR é a seqüência dos intervalos de tempo entre batimentos sucessivos no ECG.

O propósito deste trabalho é o de investigar a eficácia de se usar redes neurais do tipo de mapa auto-organizável (SOM) como uma metodologia que permita identificar a partir de medidas derivadas do sinal de VFC de um recém-nascido, se este apresenta ou não alguma doença coronariana. A rede é treinada a partir de dados provenientes de duas populações de recém-nascidos, uma com problemas e outra não. Os sinais de VFC são previamente processados, usando-se métodos não-lineares de análise de sinais, cujos resultados obtidos para cada população são empregados no treinamento da rede. Dentre os vários métodos possíveis de serem aplicados, usamos para processamento a razão SD1/SD2, derivada do mapa de Poincaré, função de autocorrelação e quantificadores obtidos a partir do mapa de recorrência (RP). Na seção seguinte, apresentamos esses métodos.

2. Métodos Não Lineares de Análise

A razão das dispersões - SD1/D2 - é calculada a partir do mapa de Poincaré. Este é um gráfico no qual cada intervalo RR, aqui identificado como $R - R(i)$, é graficado como uma função do intervalo RR anterior. O mapa de Poincaré fornece tanto informações resumidas, como detalhadas do batimento cardíaco, que podem ser usadas para diagnosticar o comportamento do coração [Rajendra Acharay 2006]. Ele pode ser analisado quantitativamente pelo cálculo das distâncias de desvio padrão do intervalo $R - R(i)$ para a linha $y = x$ e $y = -x + 2(R - R_m)$, onde $R - R_m$ é a média de todos $R - R(i)$. Os desvios padrões são referidos como SD1 e SD2, respectivamente. SD1 está relacionado com a variabilidade do batimento rápido presente na série, enquanto SD2 descreve a variabilidade de longa duração de $R - R(i)$. SD1/SD2 mostra a razão entre a variação do intervalo curto e a variação de intervalo longo. Por outro lado, a função de auto-correlação (LAG) fornece uma indicação da relação de dependência estatística (correlação) entre os valores da série temporal com seus valores atrasados em um número de intervalos de tempo.

2.1. Gráficos de Recorrência e Suas Quantificações

Como a VFC apresenta comportamento complexo e variante no tempo, é recomendável que a identificação de padrões de comportamento se faça com métodos apropriados. Nesse trabalho, utilizamos quantificadores baseados no emprego do chamado Mapa de Recorrência (RP). Essa técnica hoje é extensivamente empregada na análise de sinais complexos, que podem ser analisados através da introdução dos chamados quantificadores, que permitem quantificar o comportamento do sinal analisado. Tem-se, assim o método denominado de Análise de Quantificação de Recorrência (RQA) [Zbilut e Webber 1994, Norbert Marwan 2002]. A ferramenta RP identifica as recorrências da trajetória no espaço de fase, o que facilita a visualização das recorrências e pode ser expressa pela matriz

$$R_{i,j}(\epsilon) = \Theta(\epsilon - \|\vec{x}_i - \vec{x}_j\|), i, j = 1, .., N \tag{1}$$

onde ϵ é a distância limiar (threshold), $\Theta(x)$ é a função heaviside e $\| \quad \|$ é uma norma euclidiana. A RP mostra características de padrões em grande e pequena escala, que são causadas por comportamento dinâmico típico, ou seja, linhas pretas diagonais, horizontais ou verticais. Zbilut e Webber definem medidas usando a densidade do ponto recorrência e estruturas de linhas diagonais e verticais na recorrência gráfica e, assim, calculam o determinismo (DET), a entropia de Shannon (ENTR), a laminaridade (LAM), o comprimento médio das estruturas diagonais (Ldm) e o comprimento médio das estruturas horizontais e verticais (TT) [Norbert Marwan 2007].

1. **Medidas baseadas em linhas diagonais:** A razão entre pontos de recorrência que formam estruturas diagonais e todos os pontos de recorrências é introduzida como uma medida para *determinismo* do sistema:

$$DET = \frac{\sum_{l=l_{min}}^{N} lP(l)}{\sum_{l=1}^{N} lP(l)}. \tag{2}$$

   onde l é o comprimento da linha diagonal, l_{min} é o número mínimo de linhas diagonais que se deseja contabilizar dentro do RP e $P(l)$ é a probabilidade dessa linha diagonal ocorrer dentro do RP.
   O *comprimento médio das estruturas diagonais* é o tempo médio em que dois segmentos da trajetória ficam próximos um do outro,

$$Ldm = \frac{\sum_{l=l_{min}}^{N} lP(l)}{\sum_{l=l_{min}}^{N} P(l)}. \tag{3}$$

   A medida de *entropia* referente à entropia de Shannon da probabilidade $p(l) = P(l)/N_l$ para achar uma linha diagonal de comprimento l no RP é definida como:

$$ENTR = -\sum_{l=l_{min}}^{N} p(l) \ln p(l). \tag{4}$$

2. **Medidas baseadas em linhas verticais/horizontais:** A *laminariedade* é a razão entre os pontos de recorrência que formam as estruturas verticais e o conjunto inteiro de pontos de recorrência computada por

$$LAM = \frac{\sum_{v=v_{min}}^{N} vP(v)}{\sum_{v=1}^{N} vP(v)} \tag{5}$$

onde v é o comprimento da linha vertical, v_{min} é o número mínimo de linhas verticais que se deseja contabilizar dentro do RP e $P(v)$ é a probabilidade dessa linha vertical ocorrer dentro do RP.
A medida de *tempo de aprisionamento* é o comprimento médio das estruturas horizontais e verticais e é dado por

$$TT = \frac{\sum_{v=v_{min}}^{N} vP(v)}{\sum_{v=v_{min}}^{N} P(v)} \tag{6}$$

Dessa forma, neste trabalho estamos interessados em responder as seguintes questões: indicadores baseados em RQA são boas técnicas para separar diferentes grupos de pacientes? Qual dos dois conjuntos de diagnósticos (tradicionais ou baseados em RQA) contém mais informação para diferenciar grupos de pacientes? Como este problema é não-linear, a classificação de indicadores em RQA utilizando Redes Neurais se torna um recurso potencialmente útil para a classificação de pacientes.

3. Mapa de Auto-Organizável (SOM)

As redes de mapas auto-organizáveis, SOM (Self-Organising Maps), também chamadas de redes de Kohonen, utilizam um algoritmo de aprendizado competitivo e não-supervisionado. O objetivo do mapa auto-organizável é transformar um padrão de entrada de dimensão arbitrária em um mapa discreto uni ou bidimensional de uma maneira adaptável e topologicamente ordenada [Haykin 2001]. Há três processos essenciais na formação do mapa auto-organizável que são: competição, cooperação e adaptação sináptica (usando a aprendizagem Hebbiana).

Na fase de treinamento, os neurônios da camada de saída competem para serem os vencedores em cada iteração. Esta competição é chamada, "o vencedor leva tudo", ou seja, para uma entrada, somente um neurônio apresenta um valor lógico um na sua saída, enquanto outros estão em zero. Depois no treinamento, a rede SOM agrupa as entradas em classe (cluster).

O objetivo do trabalho foi avaliar o comportamento de Redes Neurais do tipo SOM para classificação de diagnósticos baseados em métodos não lineares e em RQA para grupos de pacientes.

4. Resultados Experimentais

4.1. Metodologia

Foram utilizadas séries de 1000 pontos de intervalos RR de 74 pacientes, todos recém-nascidos, sendo que 37 deles apresentavam doenças coronárias (PC), enquanto outros 37 eram clinicamente considerados normais (EE). Computou-se, para todas as séries, os valores dos diagnósticos não lineares, ou seja, SD1/SD2 e LAG, e dos indicadores em RQA, isto é, DET, ENTR, LAM, LDM e TT.

Primeiramente, foi feito o histograma para a visualização da distribuição de cada técnica para grupos EE e PC. O uso de histograma é aconselhado para evitar a impressão

de dados pareados. Posteriormente, foi feita a separação dos tipos de diagnósticos entre os tradicionais e os novos, para que fosse possível discrimar os grupos baseando-se apenas nos dados dos diagnósticos tradicionais por uma rede R1. Uma segunda rede R2 foi treinada, utilizando apenas os dados dos diagnósticos do RQA. E de forma complementar, uma terceira rede R3 foi treinada, utilizando os dados de todos os 7 diagnósticos.

Os pesos foram utilizados de forma randômica e a taxa de aprendizagem é inicialmente baixa (menor e igual 0.1). A função que pondera a correção nos vizinhos do vencedor é a função gaussiana

$$h_{j,i} = \exp(-d_{j,i}^2/2\sigma^2), \tag{7}$$

na qual σ é a largura efetiva da vizinhança topológica e d é uma distância euclidiana. Os resultados podem ser afetados por alguns fatores do treinamento como a taxa de aprendizagem η, taxa de redução da região de vizinhança σ e os números de neurônios da grade.

4.2. Dados de entrada

Graficou-se os dados (não normalizados) com histograma e conseguiu-se uma distinção direta entre os grupos EE e PC que é razoavelmente bem caracterizada com o uso da laminaridade, porque a maioria dos pacientes EE estão entre os valores de 0.8 e 1.0, enquanto os pacientes de PC em relação à laminaridade estão bem distribuídos em todos os valores.

4.3. Treinamento

(i). Os parâmetros adequados para redes R1:
As entradas da rede R1 são de pacientes de EE e PC em diagnósticos tradicionais (Sd1/Sd2 e LAG). A entrada de matriz foi 2x74 (onde os 37 primeiros valores são referentes a Sd1/Sd2 de EE e os 37 restantes se referem a LAG de EE, da mesma forma ocorre para a segunda linha de PC). Utilizou-se a taxa de aprendizagem de 0.09, a largura efetiva da vizinhança de 0.6 e a grade 2D com 3 neurônios. O número de época foi 1000. A figura (2) mostra a formação nítida de dois grupos A e B (com as cores azul e vermelho, respectivamente).

(ii). Para rede R2:
As entradas são de pacientes de EE e PC de diagnósticos baseados em RQA, com a entrada da matriz 2x185 (onde os 37 primeiros valores são referente a DET de EE, os próximos 37 são ENTR de EE, os próximos 37 são LAM de EE, os próximos 37 são Ldm de EE e os 37 restos são TT de EE, de mesma forma ocorre para a segunda linha de PC). Utilizou-se também a taxa de aprendizagem de 0.09, a largura efetiva da vizinhança de 0.6 e a grade 2D com 5 neurônios. O número de época foi 1000. A figura (3) mostra a formação nítida de dois grupos A e B (com as cores de azul e vermelho, respectivamente).

(iii).Os parâmetros adequados para redes R3:
As entradas da rede R3 combinaram as entradas da rede R1 e R2, pois tem o tamanho

de matriz 2x259. Foi utilizado o mesmo número de parâmetros com R2. A figura (4) mostra a formação nítida de dois grupos A e B (com as cores azul e vermelho). Note que existe uma pequena região que não pertence a nenhum dos grupos. Portanto, os mesmos parâmetros e números de neurônios da grade em rede R1 foram utilizados. Os resultados são mostrados no próximo item.

(iv). A rede R1 com 5 neuronios:
Para comparar a rede R1 com 3 neurônios, colocou-se 5 neurônios da rede R1com os mesmos parâmetros da rede R1 anterior. O resultado é mostrado na figura abaixo(5). Note que a rede R1 (com 5 neurônios) não obteve melhor desempenho em comparação com a rede R1 (com 3 neurônios), pois a rede não separou bem os dois grupos, além disso existe alguma região intermediária que não pertence a nenhum dos grupos.

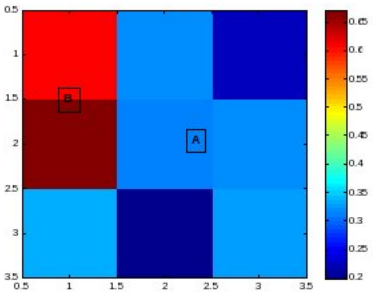

Figura 2. R1: clusterização de 2 grupos com 3 neurônios.

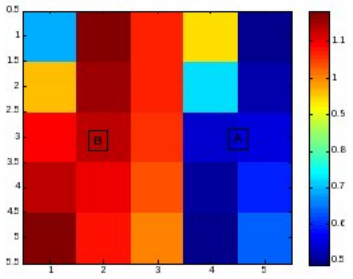

Figura 3. R2: clusterização de 2 grupos com 5 neurônios.

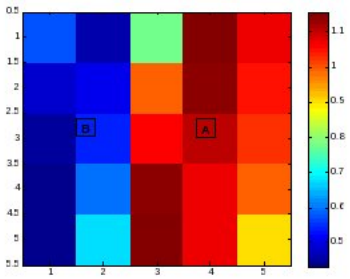

Figura 4. R3: clusterização de 2 grupos com 5 neurônios.

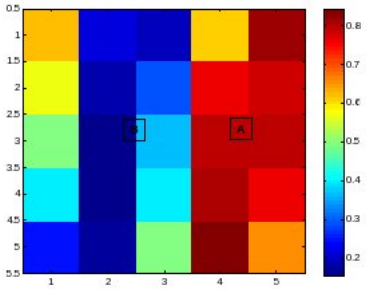

Figura 5. R1: clusterização de 2 grupos com 5 neurônios.

5. Conclusões

Pode-se concluir que o uso da RNAs para a separação entre os diferentes grupos de pacientes obteve bons resultados no trabalho proposto. As redes conseguiram separar os dados de entradas em dois grupos distintos com as sete técnicas.
De acordo com os experimentos de SOM, podemos dizer que para os parâmetros adequados, como taxa de aprendizagem de 0.09, a largura efetiva da vizinhança de 0.6 e números de épocas 1000 e a grade de 5 neurônios, a rede R2 apresenta um melhor resultado para

clusterização de grupos, com neurônios ativados mais bem distribuídos do que os da rede R1.

Referências

Everton, G.S., “Caracterização de Sistemas Dinâmicos Através de Gráficos de Recorrência”, Dissertação de mestrado, UFPR, 2008.

Guyton e Hall, “Fisiologia Human e Mecanismos das Doenças”, Ed. Guanabara Koogan, 1998.

Haykin, S., “Redes Neurais: Princípios e prática”, Bookman, 2001.

Nobert Marwan, Wessel, N., Meyerfeldt, U., Schirdewan, A., Kurths, J., “Recurrence plot based measures of complexity and its application to heart rate variability data”, Phys. Rev. E 66 (2) 026702, 2002.

Nobert Marwan, et al, “Recurrence plots for the analysis of complex systems”, Physics Reports 438 (237-329), Germany, 2007.

Rajendra Acharay, U., et al, “Heart rate variability: a review”, Review Article. Med Bio Eng Comput 44:1031-1051, 2006.

Webber Jr., C.L., Zbilut, J.P., “Dynamical assessment of physiological systems and states using recurrence plot strategies”, J. Appl. Physiol, 76(2) 965-973, 1994.

Zbilut, J.P., Webber Jr., C.L., “Embeddings and delays as derived from quantification of recurrence plots”, Phys. Lett. A 171 (3-4) 199-203, 1992.

Eckmann, J.-P., Kamphorst, S.O., Ruelle, D.,“Recurrence plots of dynamical system”, Europhys. Lett. 5 973-977, 1987.