

INTELIGÊNCIA ARTIFICIAL E ANÁLISE DE PADRÕES GRADIENTES PARA A CLASSIFICAÇÃO DE BATIMENTOS CARDÍACOS

Juliana M. Guerra, José Demísio S. Simões, Reinaldo Roberto Rosa

Laboratório Associado de Computação e Matemática Aplicada - Instituto Nacional de Pesquisas Espaciais (INPE)
12227-010-São José dos Campos - SP
jumats_guerra@yahoo.com.br, {demisio,reinaldo}@lac.inpe.br.

Resumo. O propósito deste trabalho é estudar alguns métodos para a classificação de batimentos cardíacos de pacientes normais e com patologias cardíacas com o auxílio de uma técnica fina de análise de séries temporais (GPA) e fazer a comparação desses métodos considerando porcentagem de erro e tempo de execução.

Palavras-chave: ECG, patologias cardíacas, inteligência artificial, análise de padrões gradientes.

Área do Conhecimento: Engenharia Biomédica

Introdução

Uma das principais causas de óbitos nos dias atuais em países desenvolvidos e em desenvolvimento são as doenças cardiovasculares. A maior parte destes óbitos poderia ser evitada se houvesse um pré-monitoramento e um diagnóstico prévio das arritmias cardíacas e isquemias miocárdicas, a partir do eletrocardiograma (ECG). O eletrocardiograma mede os potenciais elétricos na superfície do corpo humano através de eletrodos; é uma das ferramentas mais rápidas e confiáveis para o diagnóstico cardíaco. Contudo, quando um paciente é monitorado continuamente por tempos prolongados, pode-se obter uma quantidade expressiva de dados a serem analisados pelo médico. Além disso, os sinais cardíacos considerando uma diversidade de patologias cardíacas, muitas vezes não são fáceis de caracterizar e a análise feita pelo médico pode ser bastante subjetiva, podendo variar de médico para médico devido à variabilidade intrínseca do sinal. Desta forma, o monitoramento e o pré-diagnóstico automático visam auxiliar o médico em uma detecção mais rápida e precisa das doenças cardíacas (Lettnin, 2005).

Tecnologias de inteligência artificial e aprendizado de máquina têm sido cada vez mais empregados para auxílio ao diagnóstico médico, graças a sua capacidade de prever, com boa taxa de acerto, a ocorrência ou não de doenças.

O aprendizado de máquina é uma área de pesquisa cujo objetivo é o desenvolvimento de sistemas computacionais capazes de aprenderem, e adquirirem conhecimento de forma automática. Um algoritmo de aprendizado é um programa computacional capaz de tomar decisões baseadas em soluções de problemas anteriores. Os sistemas de aprendizado possuem características

que permitem sua classificação de acordo com a linguagem de descrição, modo, paradigma e forma de aprendizado. Redes Neurais, Árvores de Decisão (ADs) e etc. são alguns exemplos das técnicas de aprendizado de máquina existentes. (Sousa, 2004).

Nesse trabalho aliou-se as técnicas de inteligência artificial aos resultados obtidos através de uma técnica de caracterização fina de séries temporais, a Análise de Padrões Gradientes (GPA), utilizando os valores de g_{1a} e os quatro momentos gradientes (Rosa, 2003) como atributos de classificação. O objetivo é obter um método eficiente na correta previsão de cardiopatias, com custo reduzido e menores implicações para o paciente (Ó, 2003).

Metodologia

O presente trabalho pretende comparar três classificadores distintos disponíveis numa plataforma de software de disponibilização gratuita (WEKA 3.5.6 - Waikato Environment for Knowledge Analysis), uma ferramenta de KDD que contempla uma série de algoritmos de preparação de dados, de aprendizagem de máquina (mineração) e de validação de resultados. Os classificadores utilizados foram os algoritmos de Árvore de decisão J.48, LMT e o algoritmo de Rede Neural MLP.

Os dados estudados foram obtidos junto ao banco de dados da Physionet (MIT - Physiobank), sendo 23 de pacientes normais (Normal Sinus Rhythm Database), 22 de pacientes com arritmias ventriculares malignas (Malignant Ventricular Arrhythmia Database), nas quais estão incluídas taquiarritmia ventricular, fibrilação ventricular e flutter, e 18 de pacientes com ataque cardíaco (Sudden Cardiac Death Holter Database). Foram considerados apenas os primeiros 4096

pontos de cada um desses sinais. Estes dados foram separados em 2 grupos para treinamento e validação do classificador.

Para utilização do Weka é necessário montar um arquivo “.arff” que contenha os atributos considerados para separar cada grupo de séries.

Primeiramente, foram considerados os 100 primeiros valores da série como atributos e as respectivas medidas estatísticas. Porém, somente com esses atributos a classificação foi insatisfatória. Considerou-se, então, as medidas utilizadas na análise de padrões gradientes como os atributos para a classificação entre esses 3 grupos de sinais. A análise de padrões gradientes é uma técnica de análise fina de séries temporais que consegue captar as pequenas flutuações dos sinais. Foram utilizados os valores da média de $g1$ e os quatro momentos gradientes ($g1$, $g2$, $g3$ e $g4$) de cada um dos 3 diferentes sinais de batimento cardíaco (veja o Anexo A).

O algoritmo J48 foi utilizado considerando fator de confiança 0.25 e os parâmetros *binary split*, *subtreeraising* e *unpruned* ativos (true). Para esse algoritmo considerou-se apenas 1 instância por folha. Para o algoritmo LMT considerou-se ativos (true) os parâmetros *convert nominal*, *error on probabilities*, *fast regression* e *split on residual*.

No caso da rede neural, a topologia de rede adequada para a classificação foi diferente para 2 (normal e ataque, normal e fibrilação, ataque e fibrilação) ou 3 grupos de sinais (ataque, normal e fibrilação). Para a classificação entre 2 sinais apenas, considerou-se uma rede com apenas 1 camada escondida com 2 neurônios. Já para a classificação entre os 3 sinais foi necessário uma rede maior, com 2 camadas escondidas com 10 neurônios em cada. Os parâmetros variáveis da rede que melhor se ajustaram a esses sinais foram: taxa de aprendizado 0.3 e momento 0.4. Foram consideradas 1000 épocas para treinamento.

Resultados

Os três classificadores utilizados obtiveram resultados eficientes na classificação dos sinais quando a técnica de análise de padrões gradientes foi incorporada na classificação.

A tabela 1 mostra a porcentagem de acerto na classificação durante a validação dos modelos. No treinamento a taxa de acerto foi quase de 100% para todos os modelos utilizados.

Tabela 1: Porcentagem de acerto na validação

Sinais	J48	LMT	MLP
Normal - Ataque - Fibrilação	82,35%	88,23%	100%
Normal - Ataque	81,81%	100%	100%
Normal - Fibrilação	90,90%	90,90%	81,81%
Ataque - Fibrilação	75%	83,33%	91,66%

A classificação dos sinais dois a dois obteve uma maior taxa de acerto do que a classificação dos 3 grupos simultâneos, de forma que essa abordagem pode ser adaptada dependendo do interesse da aplicação.

Os sinais de pacientes normais foram mais bem separados dos sinais de pacientes com ataque cardíaco do que dos pacientes com arritmias ventriculares malignas, o que é coerente uma vez que a complexidade dos sinais com ataque cardíaco é bem maior que a dos outros sinais. Na classificação entre os sinais de ataque cardíaco e de fibrilação ventricular a taxa de acerto cai consideravelmente, fato que pode ser associado à similaridade inerente desses sinais, uma vez que a fibrilação ventricular pode ser um estágio antecedente do ataque cardíaco.

Pode-se observar que o algoritmo LMT conseguiu um resultado melhor que o J48, uma vez que utiliza o modelo logístico, além da estrutura de árvore de decisão. Entretanto, o modelo com redes neurais foi o que obteve o melhor resultado na classificação dos sinais.

As figuras 2 e 3 mostram, respectivamente, a rede neural (MLP) e a árvore de decisão utilizadas na classificação. Na figura 2 podemos ver que a rede tem como entrada os atributos determinados no arquivo (.arff): média de $g1$, os quatro momentos gradientes, a média e as informações do paciente (idade, sexo e se apresenta algum tipo de arritmia no seu ECG). Note na figura 3 que os atributos escolhidos para este caso de classificação foram o terceiro e o quarto momento gradiente, momento gradiente de desordem e fase do momento gradiente de medida global, respectivamente.

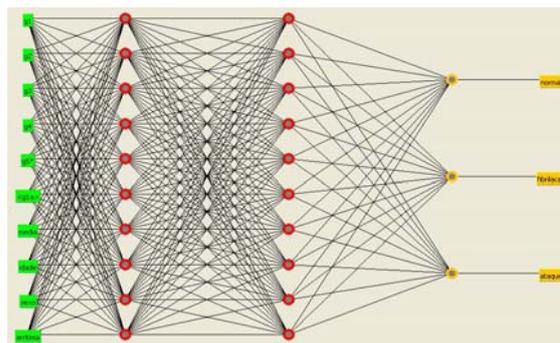


Figura 2: Topologia de rede utilizada para a classificação dos sinais (a) Normal, Fibrilação e Ataque.

A árvore de decisão escolhe os atributos que geram a maior separabilidade entre as séries, e a partir desses atributos geram as regras de classificação dos diferentes sinais. Em alguns casos apenas um atributo é suficiente para a

classificação, em outros são necessários muitos atributos.

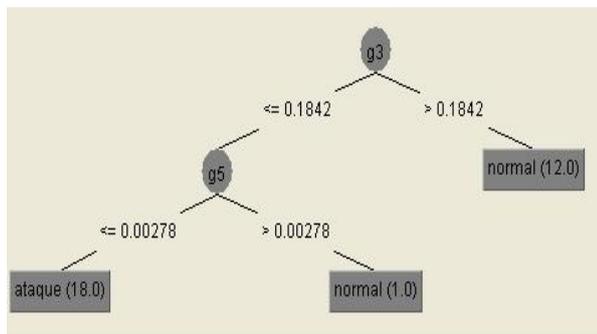


Figura 3: Árvore de decisão do algoritmo J48 para a classificação dos sinais Normal e Ataque.

Discussão

A classificação dos três grupos de sinais considerando apenas os valores da série e medidas estatísticas foi considerada insatisfatória, uma vez que as taxas de acerto obtidas para a validação estiveram em torno de 50%. Enquanto, a classificação desses mesmos grupos, considerando a análise fina que a análise de padrões gradiente provê, obteve resultados muito bons, com taxas de acerto em torno de 90%. Dessa forma, foi verificado que a análise de padrões gradientes, utilizando o valor médio de g_1 e os 4 momentos estatísticos, pode ser considerada como um bom classificador desse tipo de série temporal.

Quanto ao tempo de execução, os três algoritmos gastaram um tempo relativamente baixo, tanto para o treinamento quanto para a validação. Entretanto, notou-se que a porcentagem de erro foi inversamente proporcional ao desempenho do algoritmo, considerando porcentagem de acertos, ou seja, o algoritmo J48 foi o que obteve menor tempo para as classificações, por volta de 0.02s. O algoritmo LMT levou cerca de 1s. Já o MLP, que obteve os melhores resultados gastou aproximadamente 20s para finalizar a classificação.

A rede neural Multilayer perceptron, mesmo utilizada em uma plataforma de simulação, como o Weka, apresentou um resultado satisfatório e superior aos outros algoritmos testados.

Conclusão

A análise de padrões gradientes, aliada a inteligência artificial, pode ser considerada como um bom classificador de diferentes sinais de batimentos cardíacos. Essa abordagem é importante, uma vez que o diagnóstico cardíaco correto e prévio pode ser crucial para um

tratamento adequado das patologias cardíacas e evitar mortes por ataques cardíacos.

Referências

- LETTNIN, D. V., Vargas, F., Macarthy, M. (2002) "Estudo de um sistema para classificação de batimentos cardíacos utilizando Redes Neurais", Rio Grande do Sul.
- ROSA, R. R., Campos, M.R., Ramos, F. M. et al. (2003) "Gradient pattern analysis of structural dynamics: application to molecular system relaxation", In: **Int. Journal of Modern Physics C**, v.33 (3), p. 605-610, São José dos Campos.
- Ó, V. T., Tinos, R., Martinez, E. Z. (2003) "Comparação entre Métodos de Auxílio ao Diagnóstico em Cardiopatia Isquêmica", Ribeirão Preto.
- SOUSA, T.H.S., Policastro, C. A., Delbem, A.C.B., Garratt, R. C. (2004) "Computação inteligente no estudo de variantes de hemoglobina", São Carlos.
- PREVIERO, C.A. (2004) "Uma Ferramenta para Extração de Padrões", Palmas.
- LANDWEHR, N., Hall, M., Frank, E. (2005) "Logistic Model Trees", In: **Machine Learning**, v.59, p.161–205, Alemanha.
- NUNES, V. B., Nunes, A., Bação, F., Caetano, M.. (2007) "Comparação dos algoritmos Naive Bayes e Multilayer Perceptron para classificação de imagens IKONOS, Portugal.
- ASSIREU, A.T. et al. (2004) "Aplicação do Operador de Fragmentação Assimétrica (FA) na caracterização de controles geomorfológicos em reservatórios hidroelétricos", In: **Revista Brasileira de Geociências**, v.34, n.4, p. 501-508, São José dos Campos.

Anexo A

Análise de Padrões Gradientes (GPA)

A análise de padrões gradientes possibilita a caracterização de regimes complexos, como intermitência e turbulência, durante a formação e evolução de padrões espaço-temporais em sistemas não-lineares (Rosa, 2003).

Dentro do formalismo GPA, um campo vetorial gradiente pode ser descrito pela composição de quatro momentos gradientes: o momento gradiente de primeira ordem, g_1 , uma medida global da distribuição de todos os vetores, isto é, de todas as normas e suas respectivas fases localizadas no campo gradiente, o momento gradiente de segunda ordem, g_2 , que calcula a desordem existente no módulo dos vetores, o momento gradiente de terceira ordem, g_3 , que calcula a desordem existente na fase dos vetores e o quarto momento, g_4 , que é a medida global da norma dos vetores e da fase dos vetores.

Esta técnica baseia-se na aplicação de operadores computacionais que quantificam quebras de simetria e desordem de fase em escalas locais e globais de um dado padrão espaço-temporal. As propriedades do padrão de falta de simetria e grau de fragmentação podem ser resumidas no Operador de Fragmentação Assimétrica (g_{1a}).

A análise baseada em g_{1a} consiste em gerar campos vetoriais, a partir de matrizes numéricas. Por conveniência metodológica aplicada às estruturas complexas, os vetores simétricos (V) são removidos e, portanto apenas os vetores assimétricos (L) são mantidos. Uma segunda operação é realizada para garantir a separabilidade entre os campos gradientes.

A triangulação de Delaunay consiste em unir os vetores através de linhas, sem que estas linhas se cruzem. É possível distinguir as matrizes, mesmo estas tendo iguais valores de V e L . O número de linhas (I) utilizado para unir os centros de cada vetor é diferente. Portanto, com a quantidade I é possível distinguir diferentes matrizes quanto à sua correspondência em termos de complexidade, já que I é diretamente proporcional ao nível de desordem espacial (complexidade) do campo gradiente.

$$g_{1a} = \frac{I-L}{L} \quad (I \geq L > 0)$$

Com o intuito de estender as aplicações do método para séries unidimensionais, cada nove pontos da série são convertidos em uma matriz 3x3 (figura 1) e o método é, desta forma, aplicado ao longo da série (Assireu, 2004).

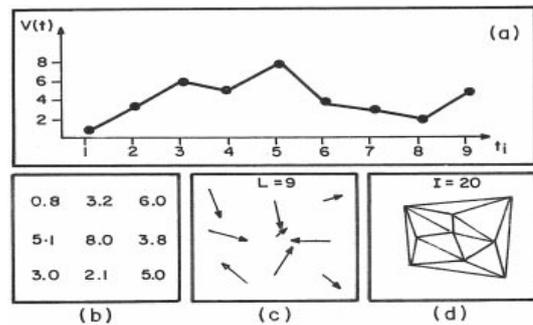


Figura 1: (a) Típico Padrão de Variabilidade, (b) Matriz Correspondente, (c) Campo Gradiente Correspondente, (d) Campo de Triangulação.