

Inteligência Computacional para Detecção de Arritmias e Anomalias Morfológicas Cardíacas em Sinais de Eletrocardiograma

Danilo A. Caldeira Silva¹, Vinicius T. Lino², Antonio L.P. Ribeiro³,
Alessandro Beda, Antônio de P. Braga⁴

¹Graduação em Engenharia Elétrica – Universidade Federal de Minas Gerais
Caixa Postal 15.064 – 91.501-970 – Belo Horizonte – MG – Brazil

²Graduação em Engenharia de Controle e Automação
Universidade Federal de Minas Gerais
Caixa Postal 15.064 – 91.501-970 – Belo Horizonte – MG – Brazil

³Hospital das Clínicas – UFMG
Av. Professor Alfredo Balena, 110 - 1º Andar - Ala Sul - Sala 107
30130-100 - Belo Horizonte - MG – Brazil

⁴Departamento de Engenharia Eletrônica – UFMG
Caixa Postal 15.064 – 91.501-970 – Belo Horizonte – MG – Brazil

daniilo.caldeira@yahoo.com, tom@hc.ufmg.br, {beda, apbraga}@ufmg.br

Abstract. *The Centro de Telessaúde's chief service is the provision of Electrocardiograms (ECG) to remote regions of the state of Minas Gerais. The high daily volume of exams performed by the Centro demands the development of an automated ECG analysis system. This work focuses on selecting features among those extracted from the time-series associated with each ECG record in order to construct classifiers, whose outputs indicate the presence or absence of a given heart pathology in the patient under analysis. We use correlation rankings to select variables, and validate those choices by evaluating the performances of a number of Support Vector Machines constructed with those variables.*

Resumo. *O principal serviço ofertado pelo Centro de Telessaúde de Minas Gerais é o Eletrocardiograma (ECG) em regiões remotas do estado. O volume diário de exames realizados pelo Centro demanda o desenvolvimento de um sistema automatizado de análise de ECGs. Este trabalho se concentra em selecionar variáveis, entre aquelas extraídas das séries temporais correspondentes a cada traçado de ECG, para a construção de classificadores cujas respostas indiquem a presença ou ausência de determinadas patologias no paciente em análise. Utilizamos rankings de correlação para selecionar variáveis, e validamos estas escolhas avaliando o desempenho de um número de Máquinas de Vetor Suporte construídos com estas variáveis.*

1. Introdução

O propósito do ECG, carro chefe do Centro de Telessaúde do Hospital das Clínicas da Universidade Federal de Minas Gerais, é detectar patologias cardíacas – arritmias, defeitos de condução e anomalias morfológicas – analisando-se formas de ondas de tensão elétrica associadas aos ciclos de polarização e despolarização das células

cardíacas [et. al. 2010]. A interpretação destes exames demanda, portanto, alto grau de conhecimento técnico.

O grande volume de ECGs diários recebidos pelo Centro, entretanto, inviabiliza a interpretação de cada exame por um humano, primeiro por uma questão de tempo hábil, e também devido aos riscos e custos associados à sobrecarga dos profissionais envolvidos.

Este volume grande de exames pede, então, por um sistema automatizado de análise de ECG, que seja capaz de rápida e confiavelmente emitir laudos preliminares dos exames. Com o advento das técnicas de *Inteligência Computacional*, tornou-se possível o projeto deste tipo de sistema.

O objetivo do projeto do qual este trabalho faz parte é, portanto, construir um sistema automático de análise e interpretação de sinais de ECGs, utilizando técnicas de Inteligência Computacional, que será utilizado pelo Centro de Telessaúde do Hospital das Clínicas da Universidade Federal de Minas Gerais. Em específico, neste trabalho selecionamos, dentre as variáveis extraídas dos sinais de ECG, quais serão utilizadas para prever a presença de cada patologia cardíaca.

2. Metodologia

Compôs-se, para este trabalho, um dataset de 11.947 amostras de exames reais. Estas foram rotuladas de acordo com a presença de determinadas patologias-alvo, e são acompanhadas da indicação de caráter pediátrico ou adulto do paciente. Usamos as variáveis extraídas segundo a metodologia descrita em [Lino 2017], além de variáveis extraídas pelo sistema de Glasgow [et. al. 1990], incluído a frequência cardíaca, o eixo cardíaco e a duração de certos segmentos da onda do ECG, totalizando 36 variáveis.

Num problema de classificação, o qual corresponde a determinar a presença ou ausência de uma patologia-alvo, calculamos a correlação de Pearson, dada pela equação 1, de cada variável com o rótulo correspondente. Uma vez que não estamos interessados na direção da correlação, ordenamos as variáveis de acordo com a magnitude desta métrica, inicialmente selecionando aquelas 5 variáveis que dela apresentarem os maiores valores, em seguida subtraindo ou adicionando variáveis iterativamente.

$$\rho(X, C) = \mathbb{E} \left[\frac{X - \mu_X}{\sigma_x} \times \frac{C - \mu_C}{\sigma_C} \right] \quad (1)$$

Para cada seleção dentro de um problema, treinamos 100 Máquinas de Vetor Suporte (Support Vector Machine – SVM) [Vapnik and Cortes 1995], utilizando o pacote *caret* [Kuhn 2017] da linguagem R. Para cada treinamento, dividimos os dados aleatoriamente entre 70% para treinamento e 30% para teste, esperando que a divisão aleatória gere um conjunto de modelos diferentes cujo comportamento estatístico informe sobre o valor preditivo das variáveis. Configuramos a função de treinamento do *caret* para durante o treinamento de cada SVM, realizar validação cruzada com $K = 5$. Medimos o desempenho de cada SVM utilizando a área sob a curva ROC (AUC) computada pelo algoritmo de treinamento sobre o conjunto de validação cruzada, assim como as métricas de sensibilidade e especificidade computadas sob o conjunto de teste. Ao fim dos 100 treinamentos, utilizamos o resumo estatístico das métricas para julgar a escolha de variáveis como aceitável ou não.

Devido ao desbalanço de classe observado em alguns dos problemas, foi necessário utilizar *oversampling* via SMOTE [Chawla et al. 2002], sem *undersampling* da classe majoritária. Devido ao desbalanceamento, prestamos maior atenção à AUC durante a avaliação de desempenho.

3. Resultados

Seguindo a metodologia descrita fomos capazes de selecionar conjuntos aceitáveis de variáveis para 13 problemas de classificação. A lista desses problemas, das variáveis escolhidas, assim como os valores das métricas obtidas nos classificadores preliminares, está mostrada na tabela 1. Em todos os problemas levamos em conta o discriminante entre paciente pediátrico *versus* adulto. Também nesta tabela indicamos se foi ou não necessário utilizar o SMOTE. A tabela 2 mostra resultados preliminares para outros 3 problemas, nos quais fomos capazes de selecionar um conjunto razoavelmente aceitável de variáveis, mas cujos classificadores têm potencial de melhora de desempenho caso incluamos variáveis ainda não extraídas da série temporal.

Há, ainda, problemas para os quais não conseguimos selecionar variáveis dentre o conjunto de dados disponíveis, seja por falta de amostras ou por falta de preditores adequados entre os 36 disponíveis. Omitimos estes problemas por brevidade.

Table 1. Problemas de classificação resolvidos, suas respectivas variáveis representativas, e métricas de desempenho calculadas.

Problema	Lista de Variáveis	Sensib. / Espec.	AUC	SMOTE
Inversão de Eletrodos	Eixo P; Eixo QRS; Onda P	98,5 ± 0,6 % / 98,5 ± 0,6 %	N/C	Não
Hipertrofia Ventricular Esquerda	Escore LVH; Eixo QRS; Duração do complexo QRS	98,5 ± 0,6 % / 98,5 ± 0,6 %	N/C	Não
Hipertrofia Biventricular	Escore LVH; Duração Geral QRS; Eixo P; Dispersão do Segmento QT; Eixo QRS	75,27 ± 10,3% / 93,76 ± 0,82 %	0,97	Sim
Taquicardia	Freq. Vent.; Freq. Cardíaca; Freq. Sinusal; Duração RR Ventricular Média; Duração RR Sinusal Média	99,37 ± 2,26 % / 97,47 ± 0,46 %	0,99	Sim
Infarto Anteroseptal	Onda P; Variabilidade da Freq. Card.; Dev. Pad. Intervalo RR; Dispersão QT; Intervalo PR Geral	79,7 ± 10,14 % / 92,44 ± 0,82 %	0,98	Sim
Desvio para a esquerda do eixo cardíaco	Eixo QRS; Escore LVH; Duraç. Geral QRS; Dispersão QT; Terminação Geral QRS	72,87 ± 3,88 % / 97,81 ± 0,6 %	0,96	Não
Desvio para a direita do eixo cardíaco	Eixo QRS; Ondas P; Duração Geral QRS; Eixo T; Duração Geral ST	98,53 ± 3,38 % / 99,67 ± 0,16 %	1	Sim
Eixo cardíaco tende à esquerda	Escore LVH; Eixo QRS; Duração Geral QRS; Tensão Ventricular Esquerda; Duração Geral da Onda P	66,23 ± 5,52 % / 97,49 ± 0,54 %	0,97	Não
Eixo cardíaco tende à direita	Eixo QRS; Freq. Vent.; Freq. Card.; Freq. Sinusal; Eixo ST	96,69 ± 3,96 % / 98,68 ± 0,36 %	0,99	Sim
Eixo QRS tende à esquerda <i>para a idade</i>	Escore LVH; Eixo QRS; Duraç. Geral QRS; Tensão V.E.; Duraç. Geral P	71,18 ± 5,24 % / 97,58 ± 0,56 %	0,97	Não
Bloqueio no ramo esquerdo do feixe de His	Ondas P; Variab. Freq. Card.; Duraç. Geral QRS; Escore LVH; Intervalo Geral PR	64,83 ± 23,52 % / 92,96 ± 2,67 %	0,97	Não
Fibrilação Atrial	Ondas P; Variab. Freq. Card.; Dev. Pad. Interv. RR; Eixo Card. Indeterminado; Duraç. Geral QRS	61,41 ± 12,82 % / 99,56 ± 0,26 %	0,97	Sim

4. Conclusões e passos futuros

Fomos capazes de selecionar as variáveis mais relevantes para 13 dos problemas de classificação. Os próximos passos envolverão, então, comparar as soluções baseadas em

Table 2. Problemas de classificação parcialmente resolvidos, suas respectivas variáveis representativas, e métricas de desempenho calculadas.

Problema	Lista de Variáveis	Sensib. / Espec.	AUC	SMOTE
Defeito de Condução Intraventricular	Duraç. Geral QRS; Escore LVH; Eixo QRS; Tensão Vent. Esq.; Term. Geral QRS	56.87±4.6% / 97.08±0.62%	0.91	Não
Padrão rSr' – Provável variante normal	Eixo QRS; Escore LVH; Força Terminal em V1; Freq. Card.; Freq. Sinusal	67.81±14.68% / 89.81±0.88%	0.94	Sim
Bloqueio no ramo direito do feixe de His com bloqueio fascicular esquerdo	Ondas P; Variab. Freq. Card.; Dev. Pad. Interv. RR; Eixo Card. Indeterminado; Duraç. Geral QRS	49.39±8.92% / 98.94±0.38%	0.91	Sim

SVM com soluções baseadas em outros modelos, e.g. redes neurais.

Para 3 dos problemas restantes fomos capazes de selecionar variáveis representativas dentro do conjunto disponível, mas não pudemos declarar o desempenho dos classificadores como perfeitamente aceitáveis. Os próximos passos são, então, extrair mais variáveis definidas pela literatura médica [Party 1990].

Houve pouca quantidade de amostras representativas de cada classe. Além disso, o desbalanceamento entre amostras positivas e negativas, devido às baixas taxas de incidência de cada patologia, afetaram o desempenho dos classificadores.

Passos futuros incluem adquirir mais amostras rotuladas e encontrar modelos que lidem melhor com o desbalanço entre classes.

Por fim, outros passos incluem implementar algoritmos rápidos e confiáveis de extração de variáveis, e integrá-los ao estágio de classificação de patologias, numa constelação de *softwares* que venham a compor o sistema completo de análise de ECGs.

References

- Chawla, N. V., Bowyer, K. W., Hall, L. O., and Kegelmeyer, W. P. (2002). SMOTE: Synthetic Minority Over-sampling Technique. *Journal of Artificial Intelligence Research*, 16(.).
- et. al., P. W. M. (1990). Methodology of ECG interpretation in the Glasgow program. *Methods of Information in Medicine*, 29(1):354–371.
- et. al., P. W. M. (2010). *Comprehensive Electrocardiography*. Springer-Verlag London, 2nd edition.
- Kuhn, M. (2017). The caret package.
- Lino, V. (2017). *Técnica de Extração de Parâmetros em Eletrocardiograma Para Classificação de Patologia*. UFMG, - edition.
- Party, C. W. (1990). Recommendations for measurement standards in quantitative electrocardiography. *European Heart Journal*, 6(10):815–825.
- Vapnik, V. and Cortes, C. (1995). Support Vector Machines. *Machine Learning*, 20(3):273–297.