

DoToR - um sistema especialista para apoio ao diagnóstico diferencial de dor torácica

Heitor S. Lopes¹, Mario S. Coutinho², Jorge M. Barreto², Walter C. de Lima³

¹CEFET-PR/NEHOS - A. 7 de setembro, 3165 - 80230-901 - Curitiba - hslopes@cpgei.cefetpr.br

²UFSC/GPEB - Florianópolis, ³ UDESC - Florianópolis

Resumo: Este trabalho descreve a implementação do sistema DoToR para o apoio ao diagnóstico de dor torácica aguda de origem não-traumática. O paradigma central utilizado é o raciocínio por analogia com protótipos de doenças, onde uma inferência é realizada computando-se o grau de similaridade entre um protótipo e um caso real. O sistema desenvolvido é capaz de diagnosticar 12 diferentes patologias. Um sistema de aprendizado é utilizado para aumentar o desempenho do sistema simulando o aprendizado qualitativo.

Abstract: The implementation of a knowledge-based system to aid clinicians in non-traumatic acute chest pain diagnosis is described. The central paradigm developed here is the analogy with diseases prototypes, where inferences are achieved by computing the similarity level between the prototype and a real case. This system, named DoToR, is able to diagnose 12 different pathologies common to chest pain. A machine learning system is employed in order to make DoToR to increase its diagnostic performance, by simulating a qualitative learning.

Introdução

A dor torácica é um sintoma bastante comum relacionado a doenças de origem esofágica, pulmonar, musculoesquelética, psicogênica ou cardiovascular. Segundo dados recentes da Organização Mundial da Saúde, somente as doenças de origem cardio-vascular causam cerca de 1/4 das mortes registradas no mundo, e a observação destas cifras de anos anteriores tem revelado uma emergente epidemia de doenças cardio-vasculares nos países em desenvolvimento, como é o caso do Brasil.

A avaliação da dor torácica de origem desconhecida é um problema bastante freqüente e consideravelmente crítico enfrentado por um médico. Um grande número de pacientes que apresentam a dor torácica como queixa principal fazem parte da rotina de um hospital, especialmente das unidades de emergência, local onde é freqüentemente impossível ser realizado um diagnóstico detalhado

Mesmo reconhecendo-se que a experiência do médico e o seu julgamento holístico terão sempre o papel fundamental no diagnóstico, a utilização de sistemas

computacionais para análise destas informações pode ser de grande utilidade¹.

Metodologia

Ridderikhoff², a partir de trabalhos de outros autores, identificou duas estratégias de resolução de problemas que podem ser aplicadas à área médica: o raciocínio produtivo e o raciocínio reprodutivo. O primeiro representa um meio através do qual a solução de um problema deve ser construída passo-a-passo. No raciocínio reprodutivo, a resolução de um determinado problema é feita por analogia, reutilizando-se soluções satisfatórias de casos similares do passado. A partir da instanciação dos atributos de casos passados, indutivamente chega-se à similaridade com o caso presente. O modelo de raciocínio produtivo é a base da metodologia de diagnóstico por analogia com protótipos descrita por Lopes et al³ e empregada neste trabalho.

A utilização do raciocínio por analogia em problemas de diagnóstico clínico é baseada em medidas de similaridade. As informações de um determinado paciente são tabuladas e constituem o alvo. É utilizado um conjunto de protótipos de doenças, previamente

constituído, para confrontação com o alvo. Estes protótipos, denominados de fontes, são obtidos a partir da aquisição de conhecimento do especialista do domínio, e representam o universo das patologias diagnosticáveis. Quanto maior ao grau de similaridade entre o protótipo e o caso do paciente, maior será a possibilidade de que o paciente em questão tenha a doença cuja abstração é representada pelo protótipo. A dissimilaridade entre o alvo e o m -ésimo protótipo é dada pela equação a seguir:

$$d(A, F_m) = a \cdot \left[\sum_{i \in \{A - F_m\}} (p_m)_i \right] + b \cdot \left[\sum_{i \in \{F_m - A\}} (p_m)_i \right] + g \cdot \left[\sum_{i \in \{A \cap F_m\}} (p_m)_i \right]$$

A partir do valor da dissimilaridade entre o alvo (caso do paciente) e os protótipos de doenças, a similaridade entre eles é calculada como uma função inversa:

$$s(A, F_m) = 1 - \text{sen}^2 \left(\frac{p d(A, F_m)}{2} \right)$$

Resultados

O sistema desenvolvido, denominado DoToR, utiliza 161 variáveis obtidas da anamnese do paciente e de exames suplementares, e é capaz de diagnosticar as seguintes patologias: angina estável, angina instável, infarto agudo do miocárdio, dissecação de aorta, tamponamento cardíaco, tromboembolismo pulmonar, pneumotórax, pericardite, úlcera péptica, espasmo/refluxo esofágico, doença de origem músculo-esquelética, doença de origem psicogênica.

Com o objetivo de melhorar o desempenho do sistema, foi utilizada a metodologia de aprendizado de máquina⁴, baseada em Algoritmos Genéticos. Para tanto foi utilizado uma base de 138 casos clínicos simulados por um grupo de 21 médicos experientes e de diferentes locais e formações. Destes casos, 90 foram utilizados para treinamento (BCTR) e 48 para teste (BCTE).

Vários modelos de cálculo de similaridade entre protótipos foram testados, bem como inúmeros parâmetros do sistema de treinamento foram ajustados para o melhor desempenho. Sem

treinamento, o sistema atingiu sensibilidade e especificidade médias (para todas as 12 doenças) de 0,79 e 0,92, respectivamente, enquanto que, após treinado com o BCTR, atingiu 1,00 e 0,89, respectivamente. Com o sistema treinado, a avaliação do BCTE resultou em médias de 0,94 para a sensibilidade e 0,91 para a especificidade.

Discussão e Conclusão

A analogia intradomínio, baseada em similaridade semântica, utilizada como paradigma central deste trabalho, foi adequada à tarefa de diagnóstico clínico. A implementação prática desta metodologia, o sistema DoToR (Dor ToRácica), mesmo em fase de protótipo, apresenta excelentes características de desempenho com casos simulados e uma interface gráfica eficiente e de fácil utilização. O sistema ainda se encontra em desenvolvimento, sendo previsto oportunamente uma fase de testes com casos clínicos reais, e a sua utilização em ambiente de salas de emergência ou consultórios médicos, como uma ferramenta de apoio à decisão.

Referências

- ¹ KENNEDY, R.L. et al, Do we need computer-based decision support for the diagnosis of acute chest pain? *J. Roy. Soc. Med.*, v. 86, p. 31-34, 1993.
- ² RIDDERIKHOFF, J., Medical problem-solving: an exploration of strategies. *Med. Educ.*, v. 25, p. 196-207, 1991.
- ³ LOPES, H.S., et al, A model of similarity-triggered analogical reasoning for diagnosis in medicine. in: Proc. 8th Int. Symp. Syst. Mod. Contr., Zakopane, 1995, p. 13-17.
- ⁴ LOPES, H.S., et al, An evolutionary approach to simulate cognitive feedback learning in medical domain. in: SANCHEZ, E., et al (eds.), *Genetic Algorithms and Fuzzy Logic Systems*. Singapore: World Publ., 1996 [a ser publicado].