



Exacta

ISSN: 1678-5428

exacta@uninove.br

Universidade Nove de Julho
Brasil

Zerbinatti, Leandro; de Assis Moura, Lincoln
Fuzzy e Bayes no apoio à decisão médica
Exacta, vol. 4, núm. 2, 2006, pp. 309-315
Universidade Nove de Julho
São Paulo, Brasil

Disponível em: <http://www.redalyc.org/articulo.oa?id=81040210>

- Como citar este artigo
- Número completo
- Mais artigos
- Home da revista no Redalyc

redalyc.org

Sistema de Informação Científica
Rede de Revistas Científicas da América Latina, Caribe, Espanha e Portugal
Projeto acadêmico sem fins lucrativos desenvolvido no âmbito da iniciativa Acesso Aberto

Fuzzy e Bayes no apoio à decisão médica

Leandro Zerbinatti

Doutorando em Engenharia Elétrica – Poli/USP;
Professor do departamento de Ciências Exatas – Uninove.
São Paulo – SP [Brasil]
zerbinatti@poli.usp.br

Lincoln de Assis Moura Júnior

Professor credenciado – USP;
Engenheiro especialista – Atech.
São Paulo – SP [Brasil]
atech@atech.br

Neste trabalho, apresenta-se um estudo comparativo entre as técnicas Fuzzy e bayesiana no apoio à avaliação médica, utilizando como experimento os diagnósticos de fratura na costela (CID-10-S22.3), pneumonia viral não-especificada (CID-10-J12.3) e angina instável (CID-10-I20.0).

Palavras-chave: Bayes. Fuzzy. Técnicas de apoio à decisão.



1 Introdução

Neste trabalho, comparam-se os resultados obtidos entre a modelagem por meio da Lógica Fuzzy e o modelo de múltiplas hipóteses para evidências de Bayes. Os resultados apresentados são prévios e buscam provas dos conceitos para posterior aprofundamento na construção de um sistema de apoio à decisão médica.

2 Metodologia

Temos a intenção de transformar o sistema de apoio à decisão médica proposto numa ferramenta a ser utilizada no processo de triagem do atendimento ao paciente, com o intuito de diminuir os problemas de diagnose resultantes de falhas humanas. Para a formulação de uma ferramenta eficaz, é necessário identificar as formas de raciocínio do profissional de saúde e os conhecimentos necessários à tomada de decisão médica.

O conhecimento médico está ligado a aspectos da experiência humana e baseia-se em evidências disponíveis no cerne do conhecimento médico universal e formal (MASSAD; ROCHA, 2003).

O conhecimento experiencial pode ser sistematizado por meio de informações constantes em bases de dados de pacientes, envolvendo processos, nos quais o médico reconhece determinado padrão clínico de experiências anteriores. O conhecimento com base em evidências, por sua vez, é dado pelas confirmações acumuladas ao longo do tempo e sumarizadas por processos estatísticos adequados. O conhecimento formal tem como fonte a literatura médica, disponibilizada em periódicos, livros e em outras formas de armazenamento, incluindo, ainda, processos de dedução (MASSAD; ROCHA, 2003).

Tomando como premissa a existência de um Prontuário Eletrônico de Pacientes (PEP), contendo informações estruturadas e não-estruturadas, é possível conhecer, pela utilização de técnicas estatísticas, as doenças de maior incidência com base em vocabulários como o Código Internacional de Doenças (CID)-10.

A prevalência de doenças mais frequentes pode ser modelada por meio de regras de produção e submetida à inferência Fuzzy. As doenças que não estiverem no *ranking* de maior incidência podem ser tratadas por intermédio de técnicas que permitem acesso ao conhecimento em base de dados (*knowledge discovery in database* [KDD]), tendo como fonte os modelos de Bayes. Dessa maneira, associam-se duas importantes técnicas de inteligência artificial para apoio à tomada de decisão.

A Lógica Fuzzy, também conhecida como lógica nebulosa, tem o objetivo de modelar o raciocínio humano de forma aproximada, a fim de desenvolver sistemas computacionais para a tomada de decisão racional em ambientes de incertezas (ZADEH, 1965). Nela, são modelados os conjuntos Fuzzy, que são funções que mapeiam um valor escalar entre 0 e 1, indicando o grau de pertinência nesse conjunto. São também estabelecidas as regras, que normalmente são extraídas de especialistas humanos ou valores numéricos. A partir de queixas, sinais e sintomas apresentados pelo paciente, o processo de inferência determina como as regras serão ativadas e combinadas. O chamado processo de defuzzyficação transforma o conjunto nebuloso de saída em uma saída precisa.

Modelaram-se, por meio da técnica Fuzzy, os conjuntos para identificar as hipóteses diagnósticas de fratura na costela (CID-10-S22.3), pneumonia viral não-especificada (CID-10-J12.3) e angina instável (CID-10-I20.0) (Figura 1).




Figura 1: Conjuntos Fuzzy de saída ou processo de defuzzificação

Fonte: Os autores.

Também foram modelados os conjuntos para identificar as evidências. Utilizam-se as seguintes variáveis linguísticas: dor torácica, respiração, temperatura, colesterol e acidente.

Para cada variável linguística foram estabelecidos os valores linguísticos associados. Para dor torácica, discreto e contínuo; para respiração, tosse e dificuldade; para temperatura, normal e febre; para colesterol, ideal, suspeito e alto risco (Figura 2); para acidente, positivo e negativo.




Figura 2: Valores linguísticos para o conjunto da variável linguística colesterol

Fonte: Os autores.

Concluindo a modelagem Fuzzy, foram estabelecidas dez regras que compõem o conhecimento do especialista médico para a conclusão diagnóstica. Essas normas não são conclusivas e foram concebidas tendo como base o conhecimento extraído da literatura; além disso, ressaltamos a possibilidade de não estarem completas, o que pode causar diagnósticos incorretos. No entanto, para fins de experiência, elas foram utilizadas da seguinte forma:

Regra 1: se o colesterol é ideal, e a dor torácica, contínua; se a respiração é tosse, a temperatura, febre, e o acidente, negativo, então, o diagnóstico será pneumonia;

Regra 2: se o colesterol é ideal, e a dor torácica, contínua; se a respiração é difícil; a temperatura, normal e o acidente, positivo, então, o diagnóstico será fratura;

Regra 3: se o colesterol é de alto risco, e a dor torácica, discreta; se a respiração é difícil, a temperatura, normal e o acidente, negativo, então, o diagnóstico será angina;

Regra 4: se o colesterol é suspeito e a dor torácica contínua; se a respiração indica tosse, a temperatura, febre e o acidente, negativo, então, o diagnóstico será pneumonia;

Regra 5: se o colesterol é suspeito e a dor torácica contínua; se a respiração é difícil, e a temperatura, normal, então, o diagnóstico será fratura;

Regra 6: se o colesterol é suspeito, e a dor torácica, discreta; se a respiração é difícil e a temperatura, normal, então, o diagnóstico será angina;

Regra 7: se o colesterol é de alto risco, e a dor torácica, discreta, então, o diagnóstico será angina;

Regra 8: se a respiração é tosse, e a temperatura, febre, então, o diagnóstico será pneumonia;

Regra 9: se a respiração é difícil, e a dor torácica, contínua, então, o diagnóstico será fratura;

Regra 10: se o acidente é positivo, e a dor torácica, contínua, então, o diagnóstico será fratura.

Outro método empregado foi a Teoria de Bayes. Uma das técnicas de Bayes mais conhecidas são as chamadas redes bayesianas. Trata-se de uma rede que consiste em um grafo acíclico orientado, no qual os nós representam variáveis aleatórias,



e o arco unindo dois nós a dependência probabilística entre as variáveis associadas. A representação gráfica explicita as relações de dependência e constitui uma ferramenta poderosa na aquisição de conhecimentos e no processo de verificação (FLORES et al., 2000). Quando uma rede bayesiana está ligada a uma base de dados, ela pode ser construída de forma que se torne adaptativa e se atualize, conforme as probabilidades estimadas a partir dos dados armazenados, sendo chamadas de redes bayesianas adaptativas. Essa capacidade oferece a possibilidade de implementar técnicas de KDD (LEE; ABBOTT, 2003).

Com esses recursos adaptativos em mente, foi utilizada, neste estudo, a Teoria de Bayes no tratamento de múltiplas hipóteses e evidências. Essa teoria pertence ao conceito probabilístico de independência entre dois eventos, em que certa informação sobre um evento não traz dado adicional a respeito de outro, ou seja, o evento 1 (e1) ocorre, e não traz informação para o evento 2 (e2), e vice-versa.

A seguir, demonstrar-se-á formalmente esse conceito.

Considerando que se tenham n evidências (e1, e2,..., en), logo a probabilidade da hipótese diagnóstica H_i é dada por:

$$P(H_i|e_1e_2e_3...e_n) = \frac{P(H_i|e_1e_2e_3...e_n|H_i) \cdot P(H_i)}{P(e_1,e_2,e_3,...,e_k,...,e_n)} \quad (1)$$

Supondo que as evidências sejam independentes sob a hipótese H_i , então:

$$P(H_i|e_1e_2e_3...e_n) = \frac{P(e_1|H_i) \cdot P(e_2|H_i) \cdot P(e_n|H_i) \cdot P(H_i)}{P(e_1,e_2,e_3,...,e_k,...,e_n)} \quad (2)$$

Resultando em:

$$P(H_i|e_1e_2e_3...e_n) = \frac{P(H_i) \cdot \prod_{k=1}^n P(e_k|H_i)}{P(e_1,e_2,e_3,...,e_n)} \quad (3)$$

Utilizando esses conceitos, modelou-se o conhecimento médico, com base na teoria das múltiplas evidências e hipóteses.

Considerando-se como hipóteses, H_1 , fratura na costela; H_2 , pneumonia, e H_3 , angina, as evidências associadas são:

E1 = dor torácica;
E11= discreta;
E12 = contínua;
E2 = respiração;
E21 = tosse;
E22 = dificuldade;
E3 = temperatura;
E31 = normal;
E32 = febre;
E4 = colesterol;
E41 = ideal;
E42 = suspeito;
E43 = alto risco;
E5 = acidente;
E51 = positivo;
E52 = negativo.

	E1		E2		E3			E4		E5	
	E11	E12	E21	E22	E31	E32	E41	E42	E43	E51	E52
H1	0,3	0,7	0,1	0,9	0,9	0,1	0,4	0,3	0,3	0,9	0,1
H2	0,3	0,7	0,6	0,4	0,2	0,8	0,4	0,3	0,3	0,1	0,9
H3	0,8	0,2	0,2	0,8	0,9	0,1	0,1	0,3	0,6	0,1	0,9

Quadro 1: Distribuição de probabilidades da hipótese H_x , dada a evidência E_y

Fonte: Os autores.

No Quadro 1 verifica-se a distribuição das probabilidades da ocorrência de uma hipótese, dada à ocorrência de uma evidência. Por exemplo, na coluna identificada com evidência E32 – febre – identifica-se uma distribuição de 10% de probabilidade de o diagnóstico ser fratura na costela; 80%, de ser pneumonia, e 10%, de ser angina.

Já no Quadro 2, identifica-se a probabilidade, *a priori*, de ocorrer aquela hipótese. Exempli-

Hipóteses	Probabilidade <i>a priori</i>
H1	0,15
H2	0,6
H3	0,25

Quadro 2: Distribuição de probabilidades *a priori*

Fonte: Os autores.

ficando: se um paciente não apresentar problemas de saúde, há 15% de probabilidade de ele ser diagnosticado como portador de fratura na costela, 60%, de ter pneumonia, e 25%, de angina.

Vale lembrar que essas informações são suposições e não têm credibilidade de dados reais. No entanto, para um estudo real, esses dados devem ser capturados de dados históricos de diversos pacientes, em que um programa de educação postural (PEP) pode ter função primordial nessa ação.

3 Resultados

Esses dois modelos foram submetidos às mesmas evidências, constatando-se os seus resultados. Logicamente os modelos têm formas de lidar com o conhecimento de maneira distinta, porém os resultados foram, de certa forma, bastante aproximados.

Demonstramos, a seguir, situações que supõem evidências e seus respectivos resultados.

No Quadro 3, são descritos os valores lingüísticos apresentados como evidência e, após o processo de inferência Fuzzy, tem-se o resultado de 1,55 – fratura.

No Quadro 4, apresentam-se as evidências para cálculo, por meio do método das múltiplas hipóteses e evidências. Essas evidências seguem a mesma sequência de apresentação do experimento Fuzzy, e o resultado obtido é 94,73% de probabilidade de ser fratura.

Variável lingüística	Índice	Valor lingüístico
Respiração	4	Dificuldade
Dor torácica	4	Contínua
Temperatura	37	Normal
Colesterol	190	Ideal
Acidente	3	Positivo
Resultado (diagnóstico)	1,55	Fratura

Quadro 3: Série de evidências e seu diagnóstico


Fonte: Os autores.

Hipóteses	Evidências					Evidências
H1 – fratura						0,9473
H2 – pneumonia	E22	E12	E31	E41	E51	0,0416
H3 – angina						0,0111

Quadro 4: Resultado obtido pela exposição das mesmas evidências do Quadro 3

Fonte: Os autores.

Na Figura 3, é representada a evolução das probabilidades das hipóteses na apresentação das evidências.

**Figura 3: Evolução das probabilidades na apresentação das evidências**

Fonte: Os autores.



Modelaram-se, assim, por intermédio de Fuzzy e Bayes, as evidências para as hipóteses diagnósticas de fratura na costela (CID-10-S22.3), pneumonia viral não-especificada (CID-10-J12.3) e angina instável (CID-10-I20.0).

Dado um conjunto de evidências, o modelo Fuzzy resultou no valor de 1,55 (fratura), enquanto o modelo Bayes demonstrou que a probabilidade de o diagnóstico indicar fratura ficou em torno de 94%. Alterando-se as evidências, por meio do modelo Fuzzy obteve-se 5 (pneumonia), e pelo método Bayes, 95,2%. Em uma terceira situação, 8,33 (angina) e 93,98% de probabilidade desse mesmo diagnóstico. Nessas três situações, houve confirmação de diagnóstico entre os modelos.

Dado outro conjunto de evidências, o modelo Fuzzy, conforme demonstrado na situação 4, resultou em 7,07 (entre os diagnósticos pneumonia e angina), e o modelo Bayes, em 76,56% de probabilidade de o diagnóstico ser angina. Em outro conjunto de evidências, Fuzzy indicou 2,92 (entre pneumonia e fratura), e Bayes, 61,76% de probabilidade de fratura. Nessas duas situações, houve confirmação parcial do diagnóstico, visto que, no modelo Fuzzy, o resultado ficou entre dois diagnósticos e, no Bayes, confirmou-se um deles, com probabilidade menor que a dos padrões apresentados anteriormente.

Essas situações estão representadas no Quadro 5.

Situação	Resultado Fuzzy	Resultado Bayes
1	1,55 (fratura)	0,9473 = 94,73% (fratura)
2	5 (pneumonia)	0,952 = 95,2% (pneumonia)
3	8,33 (angina)	0,9398 = 93,98% (angina)
4	7,07 (angina; pneumonia)	0,7656 = 76,56% (angina)
5	2,92 (fratura; pneumonia)	0,6176 = 61,76% (fratura)

Quadro 5: Resultados obtidos dos experimentos

Fonte: Os autores.

4 Discussão e conclusões

Os resultados, apesar de preliminares, remetem a uma corroboração de diagnósticos realizados com as técnicas apresentadas por Zadeh (1965), mediante a Lógica Fuzzy, e por Bayes, por meio da técnica de múltiplas hipóteses e evidências.

Algumas divergências ocorreram nos diagnósticos, provavelmente causadas pela falta de refinamento dos modelos para reproduzir a mesma realidade.

Caso se considere um modelo no qual grande parte das doenças (descritas na CID-10) esteja acertadamente representada, um sistema de apoio à decisão médica baseado em Fuzzy e em Bayes consistirá numa eficiente ferramenta para o processo de triagem do atendimento médico.

Fuzzy and Bayes in medical decision making support

In this article, it is presented a study comparing Fuzzy and Bayes for the medical diagnostic decision support using Rib Fracture (CID-10-S22.3), Viral Pneumonia (CID-10-J12.3) and Unstable Angina (CID-10-I20.0) diagnoses as a test field.

Key words: Bayes. Decision making techniques. Fuzzy.

Referências

FLORES, C. D. et al. Uma experiência do uso de redes probabilísticas no diagnóstico médico. In: ARGENTINE SYMPOSIUM ON HEALTHCARE INFORMATICS, 3., 2000, Tandil. *Anais...* Tandil: Fuesmen, 2000. v. 1. p. 126-133.

LEE, S. M.; ABBOTT, P. A. Bayesian networks for knowledge discovery in large datasets: basics for nurse researchers. *Journal of Biomedical Informatics*, San Diego, v. 36, n. 4, p. 389-399, 2003.

MASSAD, E.; ROCHA, A. F. A construção do conhecimento médico. In: MASSAD, E.; MARIN, H. F.; AZEVEDO NETO, R. S. (Org.). *O prontuário eletrônico do paciente na assistência, informação e conhecimento médico*. 1. ed. São Paulo: Organização Pan-americana da Saúde/USP, 2003. p. 21-23.

ZADEH, L. A. Fuzzy Sets. *Information and Control*, Nova York, v. 8, n. 3, p. 338-353, 1965.

Recebido em 18 set. 2006 / aprovado em 21 out. 2006

Para referenciar este texto

ZERBINATTI, L.; MOURA JÚNIOR, L. de A. Fuzzy e Bayes no apoio à decisão médica. *Exacta*, São Paulo, v. 4, n. 2, p. 309-315, jul./dez. 2006.