

Modelagem da incerteza pela Inferência Bayesiana em um Estudo de Caso de Doenças Lombares

Edroaldo Lummertz da Rocha¹, Priscyla Waleska Targino de Azevedo Simões¹,
Merisandra Côrtes de Mattos¹, Cristian Cechinel²

¹Unidade Acadêmica de Ciências, Engenharias e Tecnologias – Curso de Ciência da Computação – Grupo de Pesquisa em Inteligência Computacional Aplicada
Universidade do Extremo Sul Catarinense (UNESC) – Av. Universitária 1105
Criciúma – Santa Catarina – Brasil

²Curso de Engenharia de Computação – Universidade Federal do Pampa (Unipampa)
Campus de Bagé – Rua Carlos Barbosa s/n – Bagé – Rio Grande do Sul – Brasil

edroaldo@gmail.com, pri@unesc.net, mem@unesc.net,
contato@crisiancechinel.pro.br

Abstract. *There are different tools for uncertainty modeling, which use only a knowledge representation mechanism. The objective of this research is the development of a tool, called shell Pegasus Uncertainty Modeling that provides a unified interface different methodologies for uncertainty modeling, as certain factors, fuzzy logic, Dempster-shafer theory and bayesian networks. This paper deals specifically about how bayesian inference is accomplished on it, being the low back pain diagnostic used as problem from which the results are got and analyzed.*

Keywords: *Bayesian networks, Pearl's message passing algorithm, artificial intelligence*

Resumo. *Existem diferentes ferramentas para modelagem da incerteza, as quais utilizam somente um mecanismo de representação de conhecimento. O objetivo desta pesquisa é o desenvolvimento de uma ferramenta, intitulada shell Pegasus, que propicie em uma interface unificada diferentes metodologias para modelagem da incerteza, como fatores de certeza, lógica fuzzy, teoria de Dempster-Shafer e redes bayesianas. Este artigo trata especificamente sobre como a inferência bayesiana é realizada na mesma, sendo o diagnóstico de lombalgia utilizado como problema a partir do qual os resultados são obtidos e analisados.*

Palavras-chave: *Redes bayesianas, algoritmo de passagem de mensagens de Pearl, inteligência artificial*

1. Introdução

Na área de inteligência artificial existem diferentes ferramentas para modelagem da incerteza, dentre as quais estão a shell Netica, para redes bayesianas, a shell Expert Sinta, para fatores de certeza, o toolbox fuzzy do Matlab e a Dempster-shafer engine para a teoria de Dempster-Shafer. Estas teorias abordam variações do conceito de

incerteza e estas ferramentas automatizam o desenvolvimento de sistemas inteligentes, fornecendo uma interface amigável para utilização destas abordagens para modelá-la.

No entanto, estas ferramentas não abordam a disponibilização destas teorias em uma única ferramenta e neste sentido, o Grupo de Pesquisa em Inteligência Computacional Aplicada da Universidade do Extremo Sul Catarinense propôs o desenvolvimento de uma ferramenta, denominada shell Pegasus Uncertainty Modeling, cujo objetivo é fornecer um ambiente integrado de desenvolvimento e avaliação dos modelos criados, baseada inicialmente, nas quatro teorias acima citadas.

Os objetivos a longo prazo dividem-se em duas categorias: globais e locais. Os objetivos globais caracterizam a integração da teoria de redes bayesianas com as teorias de lógica fuzzy e redes neurais artificiais, proporcionando um mecanismo para criação de abordagens híbridas para modelagem de sistemas inteligentes. Os objetivos locais definem o aprofundamento tanto matemático quanto algorítmico dos aspectos relacionados às respectivas teorias. Por exemplo, tratando-se da teoria de redes bayesianas, abordar o desenvolvimento de algoritmos de inferência exata, aproximada e simbólica bem como os de aprendizado, subdivididos nos métodos de independência condicional e busca e pontuação. Atualmente, esta ferramenta disponibiliza mecanismos de inferência para fatores de certeza, Dempster-Shafer e redes bayesianas, os quais encontram-se em funcionamento.

Neste sentido, este artigo apresenta uma descrição da shell Pegasus bem como a implementação do módulo correspondente a teoria de redes bayesianas, especificamente o algoritmo de passagem de mensagens [PEARL, 1988] em grafos com estrutura de políárvore.

1.1. Redes Bayesianas

Redes bayesianas são grafos acíclicos dirigidos constituídos por dois componentes fundamentais: a) um componente estrutural, S , que define um relacionamento qualitativo causal entre os nós de um grafo, e b) parâmetros numéricos, θ , que quantificam a relação probabilística causal existente entre os nós de S [LUNA, 2004] [WILLIANSO, 2005].

Considerando que em um relacionamento causal a causa precede o efeito, há a necessidade de um mecanismo unidirecional para modelagem da causalidade, sendo o conceito de probabilidade condicional indicativo desses relacionamentos sem conexão direta [NASSAR, 2003].

Neste sentido, as redes bayesianas fornecem um modelo matemático que expressa causalidade explorando as relações de independência entre as variáveis no domínio sendo modelado e possibilitando a fatorização da distribuição de probabilidade conjunta. Esta distribuição permite responder a diversas questões sobre um domínio de dados. No entanto, sua dificuldade de representação aumenta em função do número de variáveis.

Na aplicação do teorema de Bayes, a exploração de independências condicionais entre variáveis aleatórias possibilita simplificar os cálculos e reduzir o número de probabilidades condicionais que precisam ser especificadas. Sob este aspecto, as redes bayesianas, utilizando o teorema de Bayes como mecanismo de inferência, representam as dependências entre as variáveis aleatórias existentes bem como fornecem uma

representação compacta da distribuição de probabilidade conjunta, caracterizando uma estrutura eficiente para a realização do procedimento de inferência [PEARL, 1988].

1.2. Inferência

A inferência bayesiana possibilita estimar a probabilidade das variáveis aleatórias pertencentes a um domínio de aplicação modelado a partir da ocorrência de um conjunto de evidências E [CASTILHO; GUTIÉRREZ; HADI, 1998]. Sua importância está relacionada não somente a obtenção de distribuições de probabilidade condicionais como também para aprendizagem automática de redes bayesianas.

Em contextos médicos, por exemplo, o diagnóstico para determinada doença é obtido analisando-se os sintomas (evidências) apresentados pelo paciente. Este mecanismo é denominado propagação de evidências (inferência) e consiste em atualizar as probabilidades das variáveis quando novas informações são fornecidas.

Existem diferentes algoritmos de inferência, os quais podem ser classificados em três categorias fundamentais [NEOPOLITAN, 2004]: algoritmos exatos, aproximados e simbólicos. Os algoritmos exatos calculam as probabilidades das variáveis sem outro erro senão aquele produzido pelas limitações de representação numérica do processador [CASTILHO; GUTIÉRREZ; HADI, 1998].

No entanto, em situações onde os métodos exatos não são aplicáveis, utilizam-se algoritmos aproximados, os quais aplicam diferentes técnicas de simulação para obter probabilidades aproximadas. Os algoritmos simbólicos podem ser utilizados tanto com parâmetros numéricos quanto simbólicos, obtendo probabilidades na forma simbólica em função dos parâmetros [LUNA, 2004].

A efetivação de inferência bayesiana na shell Pegasus é realizada com o algoritmo de passagem de mensagens apresentado em [PEARL, 1988], em sua versão para poliárvores. Em uma poliárvore, dois nós estão conectados por apenas um caminho, fazendo com que cada nó subdivida esta estrutura em duas poliárvores desconexas, uma contendo os pais e outra os filhos do respectivo nó, além dos subgrafos associados a cada pai e filho do nó em questão [CASTILHO; GUTIÉRREZ; HADI, 1998], conforme ilustra a Figura 1.




Figura 1. O nó D divide a poliárvore em duas poliárvores desconexas
Fonte: [CASTILHO, E.; GUTIÉRREZ, J.; HADI, A. , 1998].

Por exemplo, na Figura 1, o nó D divide a poliárvore em duas poliárvores não conexas. A primeira, constituída pelos nós {A, B, C}, inclui seus pais e os nós

acessíveis desde D por meio destes. A segunda, formada pelos nós {E, F, G}, inclui seus filhos e os nós acessíveis desde D por meio de seus filhos. Conforme ilustrado, o nó D separa estes dois conjuntos e, portanto, a relação de independência condicional $I(\{A, B, C\} \{E, F, G\} | D)$ é graficamente constatada.

Neste tipo de grafo, a inferência bayesiana pode ser eficientemente realizada utilizando passagens de mensagens¹ entre os distintos subgrafos da poliárvore, por meio de computações locais² [NEOPOLITAN, 2004]. Portanto, o algoritmo de passagens de mensagens [PEARL, 1988] pode ser utilizado para propagar as probabilidades pela rede quando um conjunto de evidências E é fornecido. A seguir é descrito um resumo deste algoritmo.

O resumo abaixo descrito é baseado em [KORB; NICHOLSON, 2004]. Considerando uma variável X, com m filhos e n pais. A distribuição de probabilidades da variável X pode ser calculada se três tipos de parâmetros estão disponíveis:

A força atual do suporte causal, π , formado pela contribuição de cada arco de chegada $U_i \rightarrow X$:

$$\pi_X(x_i) = P(u_i | e_{\bar{U}_i}^+)$$

A força atual do suporte diagnóstico, λ , formado pela contribuição de arco de saída $X \rightarrow Y_j$:

$$\lambda_{Y_j}(x) = P(e_{\bar{X}Y_j}^- | x)$$

A matriz de probabilidade condicional fixa $P(x | u_1, \dots, u_n)$ que relaciona a variável X a seus pais imediatos.

Utilizando estes parâmetros, a atualização de crença local pode ser executada em três passos:

Passo 1- Atualização de crença: quando um nó X é ativado (recebe uma evidência), ele simultaneamente inspeciona as mensagens $\pi_X(x_i)$ enviadas pelos seus pais e as mensagens $\lambda_{Y_j}(x)$ enviadas pelos seus filhos. Utilizando esta entrada, o nó atualiza sua medida de crença para:

$$BEL(x) = \alpha \lambda(x) \pi(x)$$

Onde:

$$\lambda(x) = \prod_{j=1}^m \lambda_{Y_j}(x)$$

$$\pi(x) = \sum_{\mathbf{u}} [P(x | \mathbf{u})] \prod_{i=1}^n \pi_X(u_i)$$

¹ Mecanismo pelo qual as probabilidades são distribuídas pela rede bayesiana [NEOPOLITAN, 2004].

² Cada nó que compõe a rede faz cálculos localmente, baseados em sua informação e na informação proveniente de outros nós, que uma vez calculada é transmitida para outros nós, por meio de uma mensagem [KORB; NICHOLSON, 2004].

Passo 2- Propagação ascendente: Utilizando as mensagens recebidas, o nó X calcula novas mensagens λ para serem enviadas aos seus pais. Por exemplo, a nova mensagem $\lambda_X(u_i)$ que X envia a seus pais U_i é calculada por:

$$\lambda_X(u_i) = \beta \sum_x \lambda(x) \sum_{u_{k:i} \neq u_i} P(x|u) \prod_{k \neq i} \pi_X(u_k)$$

Passo 3- Propagação descendente: Cada nó calcula novas mensagens π para serem enviadas aos seus filhos. Por exemplo, a nova mensagem $\pi_{Y_j}(x)$ que X envia aos seus filhos Y_j é calculada por:

$$\pi_{Y_j}(x) = \alpha \left[\prod_{k \neq j} \lambda_{Y_k}(x) \right] \sum_u [P(x|\square)] u \prod_{i=1}^n \pi_X(u_i)$$

$$\pi_{Y_j}(x) = \alpha \frac{BEL(x)}{\lambda_{Y_j}(x)}$$

2. Shell Pegasus

A shell Pegasus é uma ferramenta para modelagem da incerteza constituída por quatro módulos principais: teoria dos fatores de certeza, lógica fuzzy, teoria de Dempster-shafer e redes bayesianas. O objetivo de seu desenvolvimento é prover um ambiente unificado para análise de abordagens de construção de sistemas inteligentes e metodologias híbridas para modelagem de problemas baseados em conhecimento incerto.

Ela está sendo desenvolvida com a tecnologia Java e o ambiente de Netbeans 6.1, sendo sua modelagem realizada com um plugin UML integrado ao próprio ambiente de desenvolvimento. A Figura 2 ilustra a interface da shell Pegasus com o módulo de redes bayesianas inicializado.

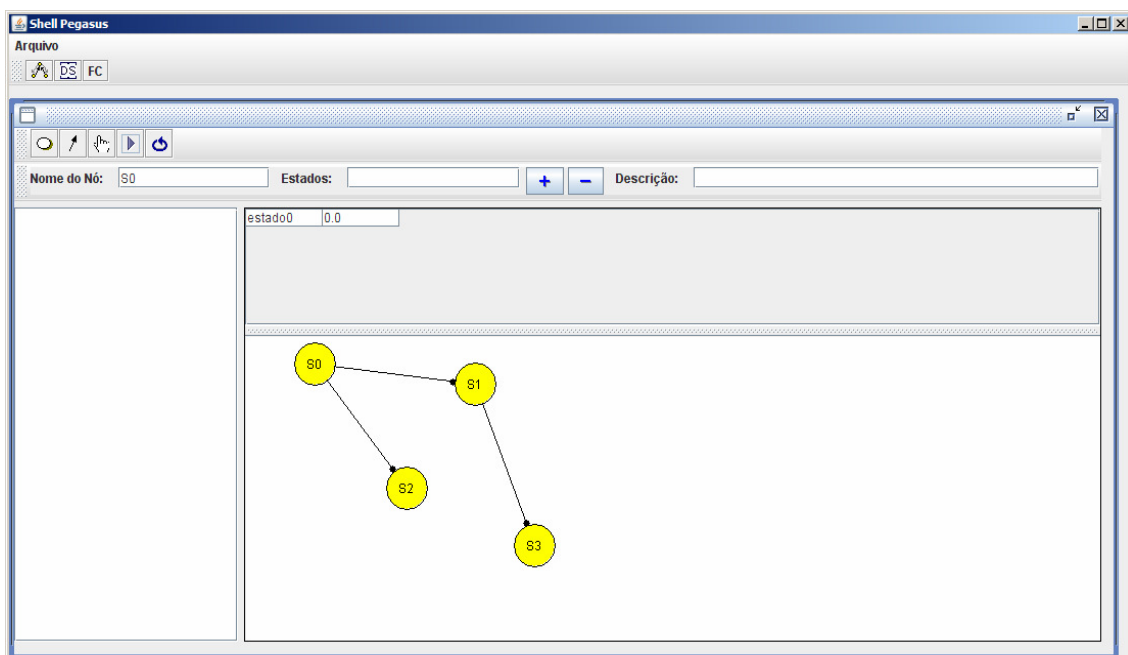


Figura 2. Interface da *shell* Pegasus com o módulo bayesiano ativado.

A metodologia abordada neste artigo consiste na apresentação do módulo de redes bayesianas, da base de conhecimento e dos testes realizados no módulo de redes bayesianas.

3. Metodologia

Primeiramente, foi criada uma base de conhecimento na shell Pegasus, com o módulo de redes bayesianas, utilizando a base desenvolvida em Scussel (2001) para obter os relacionamentos e distribuições de probabilidade associadas ao diagnóstico de lombalgia, a partir da qual foram realizados testes e obtidos os resultados.

3.1. Módulo de Redes Bayesianas

As características relacionadas a redes bayesianas são definidas neste módulo, o qual é responsável por agrupar desenvolvimentos futuros como novos algoritmos de inferência e aprendizado. Em seu estágio inicial, este módulo é constituído por um mecanismo de inferência baseado em troca de mensagens [NEOPOLITAN, 2004] entre os nós que constituem uma rede bayesiana, apresentado em Pearl (1988) e descrito na seção 2.1.

Utilizando este algoritmo, foram realizados testes aplicando-o ao problema do diagnóstico etiológico de lombalgia, com uma base de conhecimento desenvolvida em Scussel (2001), a qual foi escolhida objetivando a comparação dos resultados obtidos pela shell Netica, ferramenta na qual a base de [SCUSSEL, 2001] foi desenvolvida, e aqueles obtidos pelo módulo de redes bayesianas da shell Pegasus.

3.2. Base de Conhecimento

A base de conhecimento utilizada nesta pesquisa foi desenvolvida em 2001 como um trabalho de conclusão de curso na UNESC e uma descrição detalhada da mesma encontra-se em [SCUSSEL, 2001].

Esta base de conhecimento, ilustrada na Figura 3, foi criada utilizando a shell Netica sob orientação de um médico especialista em traumatologia, do curso de medicina da UNESC. Ela é composta por 23 nós, sendo as hipóteses diagnósticas especificadas no nó Lombalgia e os demais nós são denominados nós evidenciais.

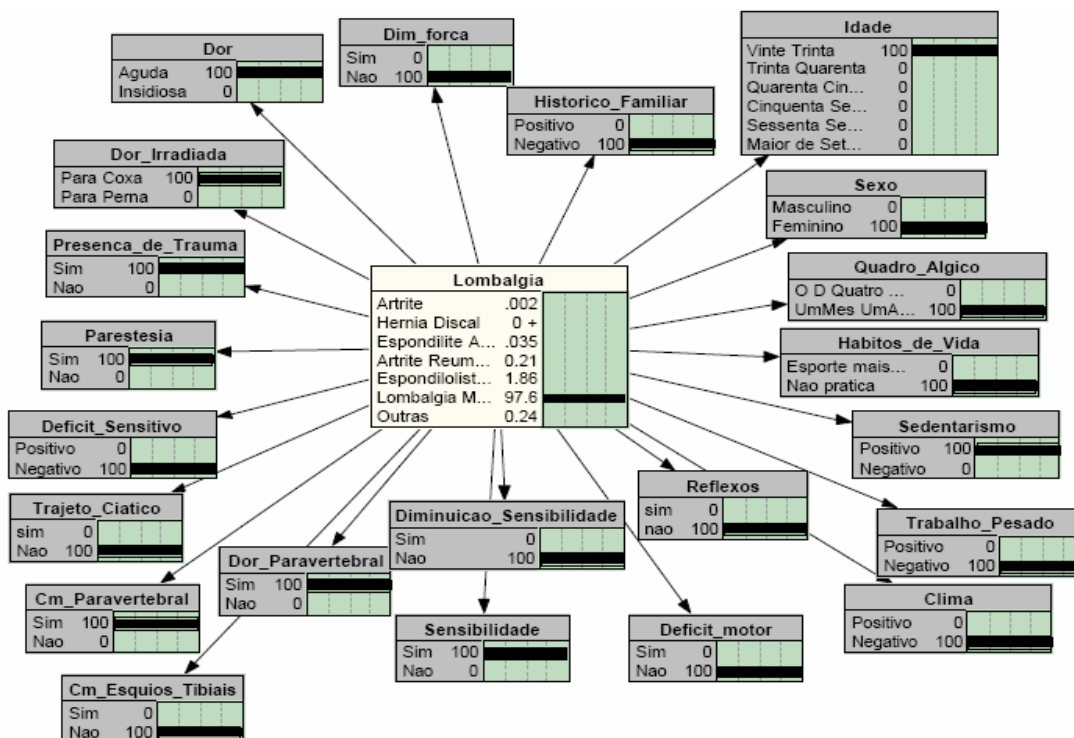


Figura 3. Base de conhecimento para diagnóstico de lombalgia.
Fonte: [SCUSSEL, 2001]

A partir das tabelas de probabilidade condicionais e a priori e dos relacionamentos existentes entre os nós que constituem esta base de conhecimento, uma base quantitativa e qualitativamente equivalente foi criada na shell Pegasus.

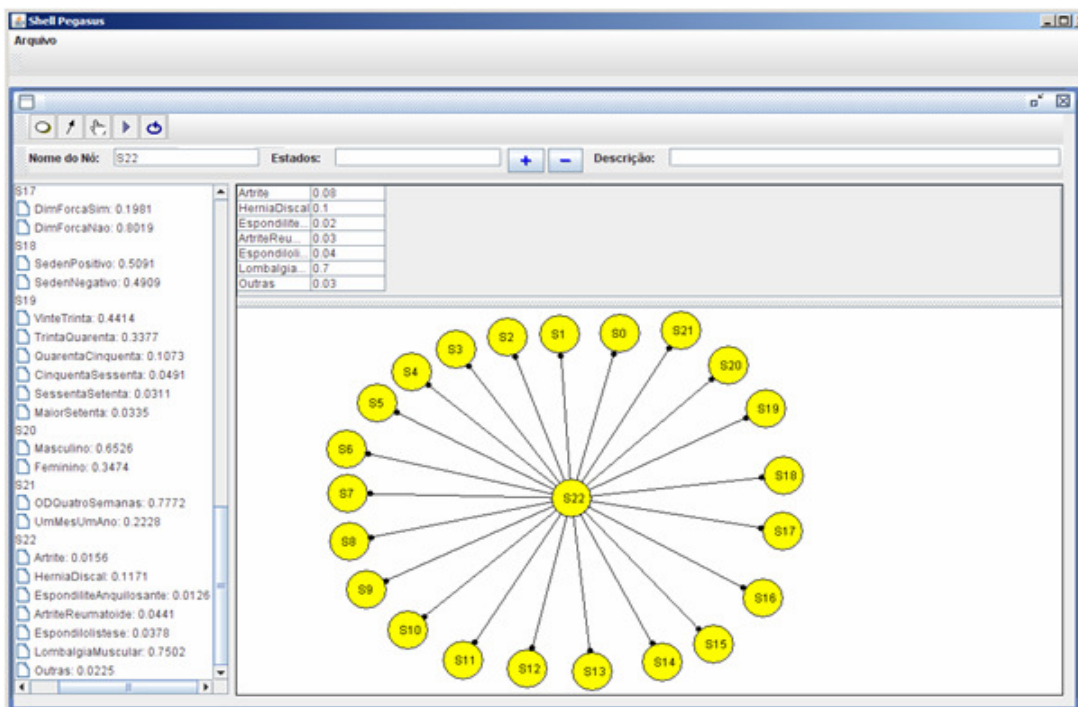


Figura 4. Interface da shell Pegasus com o módulo bayesiano ativado.

O nó S22 corresponde ao nó de hipóteses diagnósticas (Lombalgia) e os demais são os nós evidenciais. A partir da construção deste modelo, foram realizadas inferências com diferentes tipos de entradas, sendo os mesmos procedimentos empregados na base de conhecimento desenvolvida na shell Netica.

4. Resultados

A partir da metodologia apresentada na seção 5, os resultados numéricos provenientes da shell Pegasus mostraram-se condizentes com os obtidos pela shell Netica, demonstrando um comportamento estável do algoritmo de inferência desenvolvido. É importante ressaltar que este algoritmo funciona corretamente somente com redes bayesianas que apresentam estrutura de poliárvore, uma vez que o mesmo não é projetado para redes bayesianas multiconectadas.

Os valores de probabilidade do nó Lombalgia (S22), quando nenhuma evidência é fornecida são ilustrados na Figura 5.




Figura 5. (a) Resultados obtidos na *shell* Pegasus (b) Resultados obtidos na *shell* Netica

Uma evidência é fornecida clicando duas vezes no estado da respectiva variável. Automaticamente, o estado selecionado assume o valor 1 enquanto os demais são configurados para zero e a distribuição de probabilidades do modelo é atualizada refletindo a ocorrência da evidência. A Figura 6 apresenta as probabilidades do nó Lombalgia (S22) quando a evidência Histórico Familiar (S1) assume o estado Positivo.



Figura 6. (a) Resultados obtidos na *shell* Pegasus (b) Resultados obtidos na *shell* Netica

Conforme ilustra a Figura 6, a ocorrência da evidência Histórico Familiar positivo aumenta a probabilidade da ocorrência de Lombalgia Muscular. Esta informação, em um processo decisório, poderia auxiliar o médico na realização de procedimentos específicos relacionados a este estado ao invés dos demais estados.

Em seguida, fornecendo a evidência Dor no estado Aguda, as probabilidades da rede bayesiana são atualizadas, tanto para a evidência Histórico Familiar assumindo o estado Positivo, quanto para Dor em seu estado Aguda, as quais são ilustradas na Figura 7.

		Lombalgia	
Artrite	0.0156	Artrite	1.56
Hernia Discal	0.1171	Hernia Discal	11.7
Espondilite...	0.0126	Espondilite Anquilosante	1.26
Artrite Reu...	0.0441	Artrite Reumatoide	4.41
Espondiloli...	0.0378	Espondilolistese	3.78
Lombalgia ...	0.7502	Lombalgia Muscular	75.0
Outras	0.0225	Outras	2.25

Figura 7. (a) Resultados obtidos na *shell* Pegasus (b) Resultados obtidos na *shell* Netica

Conforme ilustra a Figura 7, a ocorrência da evidências Histórico Familiar positivo e Dor Aguda aumentam ainda mais a probabilidade da ocorrência de Lombalgia Muscular.

5. Considerações finais

O modelo bayesiano desenvolvido utilizando a *shell* Pegasus apresenta resultados condizentes com aqueles apresentados pela *shell* Netica, portanto, se constata o adequado funcionamento do algoritmo de inferência quando a rede bayesiana apresenta uma estrutura de poliárvore.

Considerando os relacionamentos existentes entre as variáveis e a atualização da distribuição de probabilidades como um reflexo do fornecimento de evidências constata-se que as redes bayesianas são uma mecanismo intuitivo para auxílio a tomada de decisão, especialmente em contextos médicos, onde o raciocínio realizado em processos diagnósticos pode ser adequadamente representado por estes modelos.

Referências

- CASTILHO, E.; GUTIÉRREZ, J. M.I; HADI, A. S. (1998), **Sistemas Expertos y Modelos de Redes Probabilísticas**. Madrid: Academia Española de Ingeniería
- LUNA, J. E. O. (2004), **Algoritmos EM para Aprendizagem de Redes Bayesianas a partir de Dados Incompletos**. http://www.dct.ufms.br/mestrado/dissertacoes/jose_eduardo.pdf, Agosto.
- KORB, K.; NICHOLSON, A. (2004), **Bayesian artificial intelligence**. Florida: Chapman & Hall.
- NASSAR, S. M.(2003), **Tratamento de Incerteza: Sistemas Especialistas Probabilísticos**. <http://www.inf.ufsc.br/~silvia/disciplinas/sep/MaterialDidatico.pdf>, Agosto.
- NEOPOLITAN, R. E. (2004), **Learning in bayesian networks**. New Jersey: Prentice Hall.
- PEARL, J. (1988), **Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference**. San Francisco: Morgan Kaufmann.
- SCUSSEL, T. (2001), **Base de Conhecimento para um Sistema Especialista de Apoio ao Diagnóstico Etiológico de Lombalgia**. Criciúma, SC: UNESC, 2001. 59 p. Trabalho de Conclusão de Curso (Graduação em Ciência da Computação) - Universidade do Extremo Sul Catarinense.
- WILLIAMSON, J. (2005), **Bayesian nets and causality: philosophical and computational foundations**. New York: Oxford University Press.