

Tratamento Eficiente da Incerteza em Sistemas de Apoio à Decisão

Marcelo Ladeira

Departamento de Ciência da Computação - UnB

Cecília Dias Flores e Charles Höher

ARQ Systems – Arquitetura de Sistemas (Micro Empresa)

Rosa Maria Vicari

Instituto de Informática - UFRGS

Resumo

Esse artigo apresenta o framework SEAMED para modelagem de domínios em ambiente reais com representação da incerteza por meio de probabilidades. O domínio é modelado com um conjunto de variáveis aleatórias. Os relacionamentos de possibilidade, condicionamento, relevância e causalidade entre elas são representados por arcos orientados entre variáveis com relacionamento direto. A intensidade do relacionamento da variável X com seus pais é representada pela função de distribuição de probabilidades de X condicionada aos valores que seus pais podem assumir. O SEAMED apresenta uma interface gráfica voltada para o desenvolvimento de aplicações de apoio à tomada de decisão na área médica. Para a análise de um caso específico, o usuário da aplicação entra com a evidência total (informação) disponível. A aplicação a propaga no domínio e atualiza as probabilidades das demais variáveis, face a essa evidência. Em geral, o raciocínio médico é do tipo diagnóstico, isto é, procura-se as patologias mais prováveis a partir da observação de sintomas e de resultados de exames. A entrada de evidências no SEAMED segue a metáfora do raciocínio médico, sendo baseada na anamnese (história clínica, queixa principal e exames físicos), realização de exames complementares, obtenção de laudos e realização de diagnóstico diferencial.

Abstract

This paper presents the SEAMED framework. Real domains into environment with uncertainty can be model with this framework, as follows. The theory of probabilities is used to model and to treat the inherent uncertainty of the domain. The domain is modeled with a set of random variables. A directed link from a random variable to another one represents the direct relationship of likelihood, conditioning, relevance or causality among these random variables. The probability distribution function of a random variable, giving its parents, represents the strengths of the relationship among the variable and its parents. The SEAMED presents a graphical interface designed to ease the construction of decision-making support applications into some medical fields. In order to analyze a specific case, the user of the application should enter the total evidence (information) available. Then, the application propagates this evidence through the other random variables and updates their probabilities giving the evidence available into the system. Generally, the medical reasoning is of the diagnostic kind, that is, the physician observes the effects caused by diseases in a patient and the results of exams in order to find out the most provable cause pathologies. The SEAMED evidence entrance follows the medical reasoning metaphor, that is, it is based on the anamnesis (patient's clinical history, patient's major complain and realization of physic exams), the carry out of complementary exams, and the performance of differential diagnoses.

1. Introdução

As pessoas fazem simplificações para resolver problemas e tomar decisões em ambientes reais onde a informação é parcial (não completa) ou aproximada (não exata). Para esse tipo de problema pode-se obter apenas soluções com incerteza. Um médico pode diagnosticar uma certa

doença, com base em alguns sintomas, mas esse diagnóstico é uma hipótese que pode ser incorreta. Nesse caso, as simplificações adotadas podem ter origem no conhecimento médico incompleto sobre a patologia em questão, em sintomas determinantes da patologia ainda não detectados (devido à fase de evolução da doença), ou devido a não realização de exames complementares. No entanto, esse diagnóstico tem uma confiabilidade maior do que um simples palpite porque o médico que o realizou tem uma noção da validade da hipótese formulada, quer em termos absolutos quer em comparação com outros diagnósticos alternativos.

Uma forma atual de lidar com a incerteza acima é colocar à disposição do médico procedimentos automatizados, baseados no raciocínio probabilístico, para auxílio no processo de diagnose. Esses sistemas podem ser utilizados no processo de ensino/aprendizagem e na prática diária. O *Pathfinder* desenvolvido no programa de informática médica da Universidade de Stanford, para diagnóstico de doenças do sistema linfático, é exemplo de um desses sistemas de grande sucesso de uso na prática profissional e no treinamento de médicos, nos Estados Unidos [6]. Sua versão atual supera o desempenho dos melhores patologistas mundiais [13]. Com o sucesso obtido, foi desenvolvido um produto comercial denominado *Intellipath* que inclui vídeo discos com imagens de microscópio, referencia a literatura e um gerador de relatórios, para suporte ao diagnóstico realizado por patologistas cirurgiões em diversos domínios da patologia. Esse produto é comercializado pela American Society of Clinical Pathologists, tendo até 1991, vendido mais de 250 copias, constituindo-se em uma das mais bem comercialmente sucedidas aplicações baseada em conhecimento para diagnóstico médico. Na Europa podemos citar o *Munin*, desenvolvido no Departamento de Ciência da Computação da Universidade de Aalborg, Dinamarca, utilizado para se obter um diagnóstico preliminar de doenças dos músculos e nervos [1] e o *Child* [5]. Este último foi desenvolvido para apoiar médicos do Great Ormond Street Hospital de Londres no diagnóstico à distância de doenças cardíacas congênitas em crianças recém nascidas. O GOS é um centro de referência nesta área. O pediatra que estiver atendendo a um bebê e suspeitar que ela é um *bluebaby*¹ é orientado a entrar em contato com o COS. O médico do COS consulta o *Child*, com base nas informações passadas pelo pediatra, para decidir sobre a transferência ou não do bebê para esse hospital. Esses sistemas representam o conhecimento do domínio da aplicação através de redes bayesianas.

Definição 1 (Rede bayesiana). Uma rede bayesiana é um grafo orientado acíclico onde nós são variáveis aleatórias e arcos representam relações de dependência probabilísticas direta entre os nós que conectam. A intensidade do relacionamento de X com seus pais (nós com arcos que incidem em X) é dada por $P(X|pa(X))$, distribuição de probabilidade condicional de X , dado seus pais. $P(X_1, \dots, X_n) = \prod_i P(X_i | pa(X_i))$ é a distribuição de probabilidade conjunta de todas as variáveis. Se $pa(X_i)$ for o conjunto vazio, $P(X_i | pa(X_i))$ se reduz à distribuição incondicional de X_i .

Redes bayesianas têm sido largamente utilizadas, a nível mundial, para modelar domínios [2]. A incerteza é representada pela probabilidade e a inferência básica é o raciocínio probabilístico, ou seja, o cálculo da probabilidade de uma variável ou mais, face à evidência disponível. Essa evidência é representada por um conjunto de variáveis com valores conhecidos. As inferências podem ser do tipo causal (parte-se das causas, consideradas como a evidência disponível, para os efeitos), diagnóstico (dos efeitos, i.e. evidência, para as causas), intercausal (discrimina entre causas de um efeito comum) e misto (combinação de dois ou mais tipos acima).

Este artigo apresenta um framework resultante da transferência de tecnologia da Universidade Federal do Rio Grande do Sul para a micro empresa ARQ Systems – Arquitetura de Sistemas, financiada pelo Programa PADCT III. A ARQ Systems desenvolve sistemas de apoio à decisão, desde 1994, concentrando-se no desenvolvimento de sistemas especialistas (SE) em parceria com empresas de outras áreas e/ou profissionais liberais da área médica [4]. Esses sistemas utilizam a tecnologia convencional de SE, isto é, regras de produção com tratamento de incerteza baseado em heurísticas para cálculo de pesos para ponderação das regras [3]. Essa abordagem não é mais recomendada porque quando se raciocina em ambiente com incerteza, é básico saber se a informação sobre algum evento influencia a crença em outros. A dependência entre eventos

¹ Em um *bluebaby* o sangue arterial se mistura com o sangue venoso devido a uma má formação do coração.

é modelada por regras imutáveis, em sistemas baseados em regras de produção. Portanto eles não podem raciocinar corretamente com incerteza porque não conseguem retratar a criação e a destruição dinâmica de relacionamentos entre eventos, decorrentes da alteração da dependência entre eles, função da aquisição dinâmica de conhecimento (evidência) sobre outros eventos [10].

1.1 O Raciocínio Médico

O processo de formulação do diagnóstico médico definitivo, de forma simplificada, pode ser visto como composto das seguintes etapas: a) anamnese, b) obtenção da HDA (história da doença atual), c) formulação do diagnóstico diferencial, d) formulação do diagnóstico presuntivo, e) revisão da literatura técnica (se pertinente), f) solicitação de exames complementares (se pertinente), e g) formulação do diagnóstico definitivo.

Na anamnese o médico entrevista o paciente para levantar o histórico das suas doenças passadas. Para a obtenção da HDA o médico interroga o paciente sobre a sua *queixa principal*. A seguir determina a *clínica* do paciente, isto é, examina visualmente o paciente a procura de *sinais* no seu corpo, anota os *sintomas* referidos por ele e realiza um *exame físico* do paciente, orientado pelos sinais e sintomas coletados. De posse dessas informações o médico parte para a realização do diagnóstico diferencial, isto é, seleciona um conjunto de patologias (doenças), compatíveis com os dados coletados e procura obter novos dados que possam excluir algumas das patologias hipotéticas. Com a redução do conjunto de patologias hipotéticas é possível estabelecer o diagnóstico presuntivo, isto é, determinar a patologia mais provável. Se houver necessidade de confirmar o diagnóstico presuntivo, o médico solicita exames complementares. Enquanto aguarda a realização destes exames, pode rever a literatura técnica sobre a patologia suspeitada. A análise dos exames pode confirmar o diagnóstico presuntivo, tornando-o definitivo, ou fornecer novas informações para a formulação de novo diagnóstico presuntivo.

O uso de aplicações probabilísticas para apoio a esse procedimento médico pode facilitar as etapas do diagnóstico diferencial, diagnóstico presuntivo e diagnóstico definitivo e ainda, reduzir a necessidade de rever a literatura técnica e realizar exames complementares, sem, no entanto, reduzir a qualidade do diagnóstico definitivo. Portanto pode implicar em melhora da qualidade do diagnóstico médico, redução do tempo necessário para realização do diagnóstico definitivo e redução de custos. Essa redução potencial de custos está associada à expectativa de mudança do comportamento médico. Espera-se que o médico, de posse de um modelo probabilístico que o ajude no processo de diagnose, restrinja a solicitação de exames laboratoriais aos casos em que não possa obter o diagnóstico definitivo, com base na anamnese e análise das probabilidades das doenças hipotéticas que esteja considerando, face à queixa principal e clínica do paciente.

1.2 Construção de Aplicativos Probabilísticos com o SEAMED

Para se construir um aplicativo probabilístico para suporte ao diagnóstico médico é necessário realizar as seguintes atividades: a) obtenção de dados, b) modelagem do domínio, c) refinamento da rede bayesiana inicial, d) construção de aplicativo probabilístico baseado na rede bayesiana obtida, e e) validação do aplicativo com relação a novos casos.

A obtenção de dados consiste na seleção do domínio médico a ser modelado, na identificação das variáveis aleatórias envolvidas e do relacionamento causal direto entre elas. As variáveis são ordenadas, segundo o relacionamento direto entre elas, iniciando com as que possuem maior impacto potencial sobre as demais (isto é, as causas principais) até as que representam apenas conseqüências sem nenhum impacto direto sobre variáveis ainda não ordenadas. Essa atividade requer o apoio de equipe médica de especialistas no domínio para caracterizar o procedimento utilizado na realização de diagnóstico diferencial, nesta área de interesse.

O domínio é modelado por uma rede bayesiana. A rede bayesiana é construída de forma incremental, agregando-se uma variável de cada vez, de acordo com a ordenação dada pelo relacionamento causal entre elas. Começa-se com uma variável causa principal e finaliza-se com aquelas que não têm influência causa direta em outras variáveis. Enquanto existirem variáveis no conjunto ordenado, pega-se a variável da ordem e acrescenta-se um nó na rede para ela. Essa variável é ligada por arcos aos seus pais - conjunto mínimo de nós que já estão na rede e que têm

uma influência causal direta sobre ela. Após a conclusão desse processo, os especialistas validam a qualidade da estrutura (relacionamento pai/filho) da rede obtida. Quando essa estrutura for considerada adequada, os especialistas são solicitados a fornecerem frequências típicas disponíveis na literatura médica. Essas frequências constituem estimativas de probabilidades condicionais de cada variável na rede, condicionadas aos seus pais (causas diretas).

O refinamento da rede consiste na comparação da rede bayesiana inicial com a rede obtida com a aplicação de métodos automatizados para aprendizagem da estrutura causal e das probabilidades condicionais das variáveis, a partir de casos históricos disponíveis. Como na atividade anterior, a ordenação estabelecida pelo especialista influencia o modelo probabilístico a ser obtido.

O framework SEAMED suporta a etapa de modelagem do domínio através de uma interface gráfica para facilitar a construção da rede bayesiana e a entrada das probabilidades condicionais. Essa atividade é desenvolvida pela ARQ Systems com o apoio de equipe dos especialistas. A construção do aplicativo probabilístico é suportada pelo SEAMED através do provimento das seguintes facilidades: encapsulamento da rede bayesiana (tornando-a inacessível ao usuário), implementação de método de inferência probabilística para propagação eficiente de evidência, e interface gráfica para entrada de evidência, compatível com a metáfora do raciocínio médico, baseado na anamnese, realização de exames complementares, entrada dos resultados obtidos e realização de diagnóstico diferencial. O detalhamento dessa interface será apresentado na próxima seção.

O método de inferência implementado é o método de passagem de mensagens em árvores de junções [7][8][12]. Esse método requer a transformação da rede bayesiana em uma árvore de junções probabilisticamente equivalente, para permitir a propagação correta de evidência em redes multiconectadas² sem ciclos. Esse método é muito eficiente computacionalmente porque permite a entrada de evidência múltipla (por exemplo, resultados de diversos exames), as mensagens são locais no sentido de que um nó da árvore de junções troca mensagens apenas com seus vizinhos, e após uma mensagem ter trafegado em cada direção de cada arco da árvore de junções, o processo se encerra. Esse método constitui o estado da arte na propagação de evidências em redes bayesianas a nível mundial, não existindo método mais eficiente [12].

O processo de transferência de tecnologia para a ARQ Systems finalizou com o desenvolvimento dessa versão do SEAMED. Essa empresa, com o suporte desse framework, desenvolveu uma aplicação de apoio ao diagnóstico de cardiopatias congênitas em crianças. Essa aplicação está sendo avaliada no Setor de Cardiologia Fetal do Instituto do Coração do Estado do Rio Grande do Sul, com vistas a geração de um produto comercial. A modelagem da rede bayesiana e a estimação de probabilidade foram realizadas com o apoio da equipe do Dr. Paulo Zielinski, professor da Faculdade de Medicina da UFRGS e chefe do Setor de Cardiologia Fetal do IC. Essa equipe atuou como especialista do domínio durante o projeto PADCT. Atualmente a ARQ Systems pensa em dar continuidade ao desenvolvimento da aplicação, no sentido de incluir informações multimídia (imagens radiológicas e de ultra-som e arquivos com sons de batimentos cardíacos com sopro) na aplicação de forma a facilitar ao médico o entendimento do diagnóstico sugerido.

2 O Framework SEAMED

O Sistema SEAMED é formado por dois módulos distintos: o módulo de construção e o módulo de consulta. A razão que levou a separação de ambos os módulos foi garantir a inviolabilidade do conhecimento do especialista. O sistema permite, através do módulo de construção, a definição (através de um ambiente gráfico) da estrutura da rede bayesiana e a entrada das probabilidades *a priori* (i.e., antes da entrada de evidência), para um domínio de conhecimento previamente definido. O módulo de consulta permite a realização de inferências probabilísticas, a avaliação das probabilidades *a posteriori* (i.e., condicionada à evidência entrada no sistema) e a explanação do diagnóstico sugerido.

² Um grafo orientado é multiconectado se entre dois nós quaisquer podem existir mais do que um caminho.

Neste artigo, para fins de compreensão, descreveremos a modelagem do domínio de cardiopatias congênitas. A metodologia de aquisição de conhecimento utilizada foi capaz de explicitar os procedimentos envolvidos no processo diagnóstico das 12 cardiopatias congênitas mais freqüentes, segundo levantamento realizado no banco de dados de pacientes do Instituto de Cardiologia do Rio Grande do Sul.

Foram considerados os seguintes diagnósticos: comunicação interatrial (CIA), persistência do canal arterial (PCA), comunicação interventricular (CIV), tetralogia de Fallot (FALLOT), estenose pulmonar (EP), coarctação da aorta (COAO), transposição dos grandes vasos (TGV), defeito septal atrioventricular (DSAV), drenagem venosa anômala pulmonar total (DVAPT), atresia tricúspide (ATRTRI), estenose aórtica (EAO) e atresia pulmonar (ATRPUL). O processo de decisão considera a seleção dos sinais, sintomas e exames subsidiários necessários para a formulação da hipótese diagnóstica. Os ítems considerados estão ordenados em exames físicos (ausculta, cianose...), exames laboratoriais, história clínica (tosse, posição de cócoras...) e exames complementares (Raio X, ECG...).

2.1 Módulo de Construção

Este módulo permite a representação gráfica do domínio através de um grafo acíclico orientado, onde os nós modelam variáveis aleatórias (sinais, sintomas e exames complementares), ilustradas por elipses; e o arco unindo duas elipses representa a dependência probabilística entre elas.

Na Figura 1, a elipse selecionada modela a variável DSAV - Defeito do Septo Atrioventricular. A distribuição de probabilidade condicional dos valores que pode assumir, dados os valores de seus pais, está apresentada na parte inferior da tela. Os nós de seus pais representam sinais e exames relacionados ao diagnóstico em questão (Frase_107 - RX com cardiomegalia, Frase_18 - Síndrome de Down, Frase_137 - ECG com padrão de hemibloqueio anterior esquerdo, e Frase_104 - RX com hiperfluxo pulmonar).

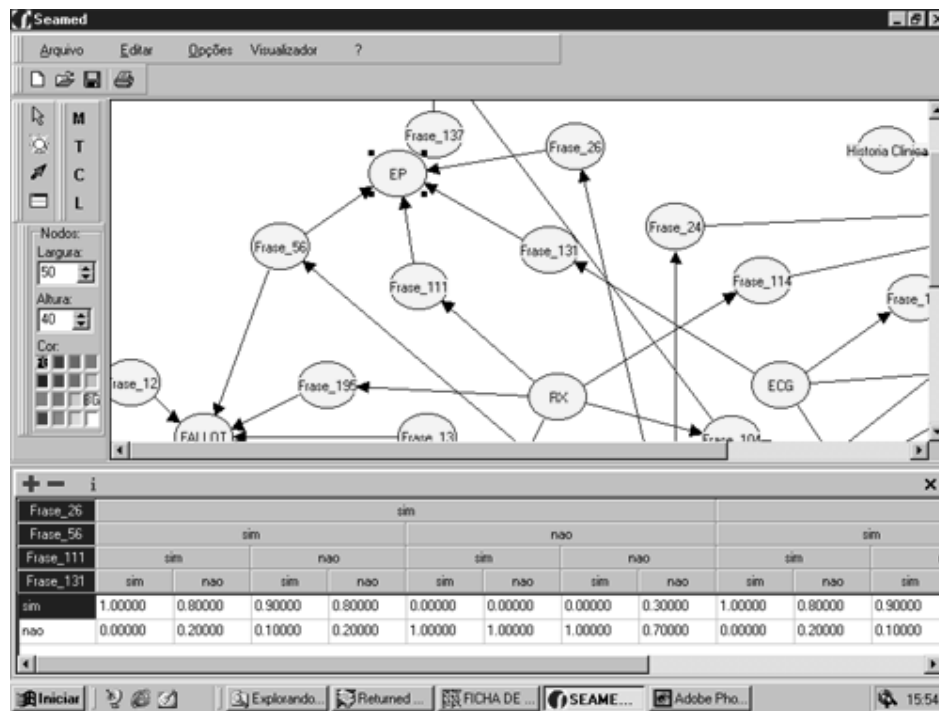


Figura 1 – Módulo de Construção de BN

Além dos relacionamentos probabilísticos, para facilitar a utilização pelos médicos, foi agregado ao sistema um recurso para auxílio a explanação do mecanismo de inferência do sistema. No módulo de construção, a partir da seleção de uma elipse, é possível interagir com a janela de informações sobre a variável, apresentada na Figura 2.

Nela, pode-se:

- alterar o nome da variável;
- alterar a descrição da variável;
- acrescentar comentários que serão visíveis durante a consulta;
- agregar recursos multimídia como sons, imagens e filmes destinados a facilitar a compreensão do usuário médico;
- classificar a variável em um grupo, como por exemplo, a Frase_107 - RX com cardiomegalia é um exame complementar;
- acrescentar textos que relacionam a variável com um determinado diagnóstico, como por exemplo, a Frase_107 - RX com cardiomegalia, possui o seguinte texto relacionado ao diagnóstico DSAV - Defeito do Septo Atrioventricular:

DSAV parcial:

Pode ocorrer cardiomegalia.

DSAV completo:

Cardiomegalia está sempre presente. Artéria pulmonar é proeminente.

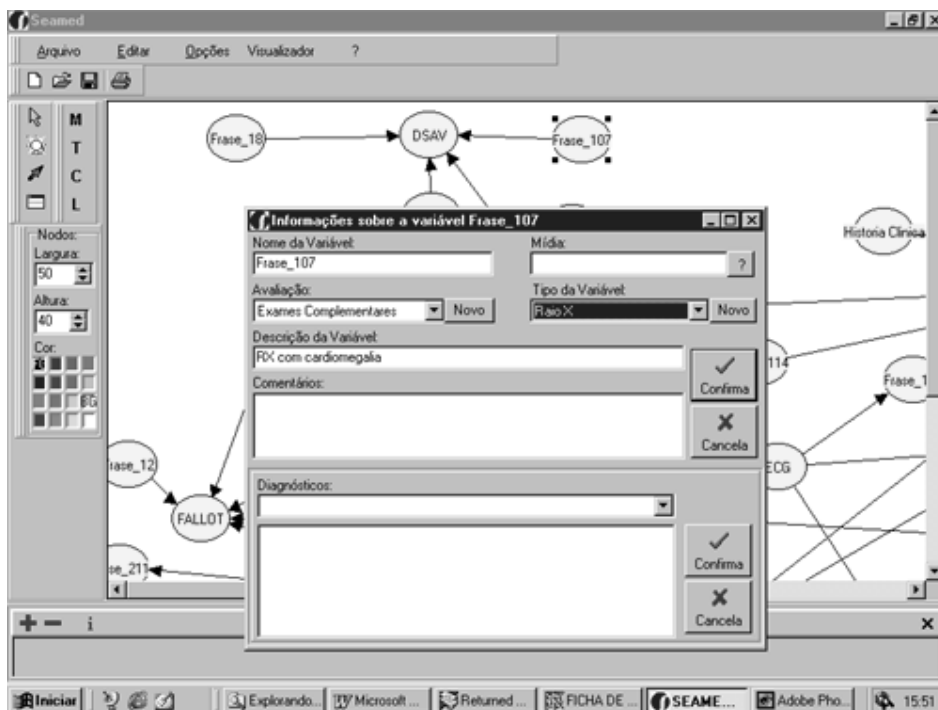


Figura 2 – Informações sobre a Variável

Com a rede bayesiana bem formada (sem ciclos e com todos os nós conectados), pode-se compilar a rede. Esse processo envolve uma série de algoritmos, não tratados neste artigo, que resulta em uma árvore de universo de crenças, probabilisticamente equivalente a rede bayesiana inicial, adequada para coletar e distribuir evidência de forma correta e eficiente [7][8][11].

2.2 Módulo de Consulta

O módulo de consulta é dividido em duas páginas: Entrada de Evidências e Laudo. A entrada de evidência permite que o usuário altere as probabilidades de ocorrência de uma determinada variável. Para tanto, seleciona-se a evidência que forma a anamnese do paciente, indicando a probabilidade para cada evidência observada.

A Figura 3 ilustra a entrada da probabilidade associada à não ocorrência de *B2 com desdobramento fixo* no exame de *Ausculata*, durante a avaliação do *Exame Físico* do paciente. Se houvesse uma média relacionada a variável selecionada, no caso *B2 com desdobramento fixo*, a mesma estaria visível na área superior direita da tela.

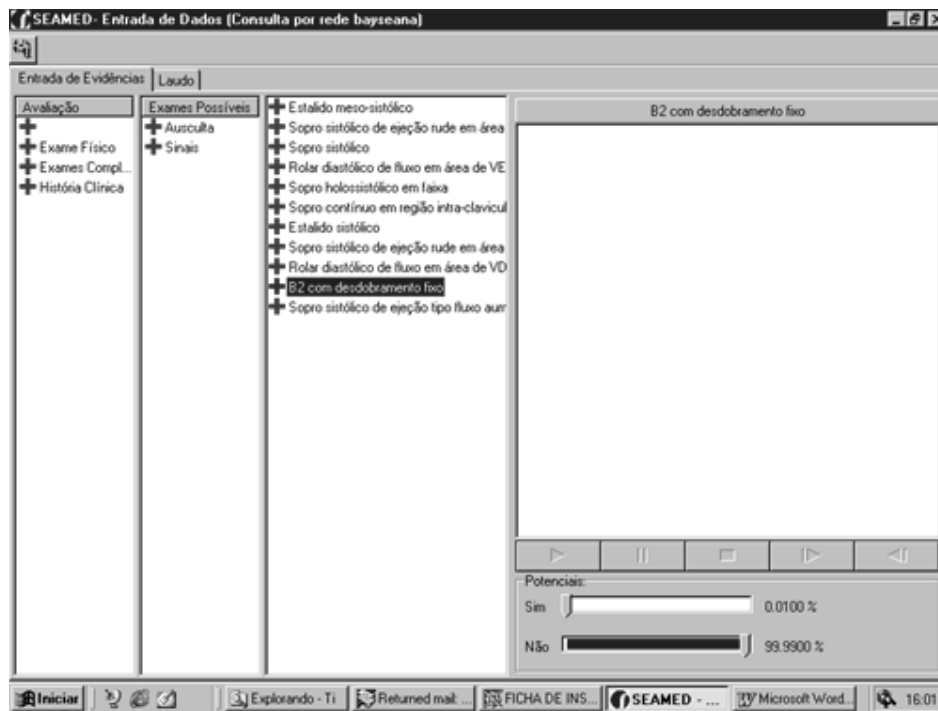


Figura 3 – Entrada de Evidência

Após a entrada de evidência sobre uma ou mais variáveis, o sistema inicia um procedimento de atualização das probabilidades associadas a cada uma das variáveis, face à evidência disponível.

Encerrada essa etapa, são listados os diagnósticos que obtiveram uma probabilidade de ocorrência superior a 50% (Figura 4).

Para cada diagnóstico listado, o sistema apresenta uma explicação textual que descreve o diagnóstico selecionado, bem como o laudo propriamente dito, que possui intrinsecamente informações sobre as alterações ocorridas no relacionamento dinâmico entre as variáveis aleatórias, em função da propagação da evidência. Na área inferior esquerda da tela, o sistema permite a visualização das variáveis e suas probabilidades agrupadas sob a forma que foram classificadas no módulo de construção. A Figura 4 apresenta o diagnóstico *DSAV - Defeito do Septo Atrioventricular* selecionado e sua respectiva explicação textual.

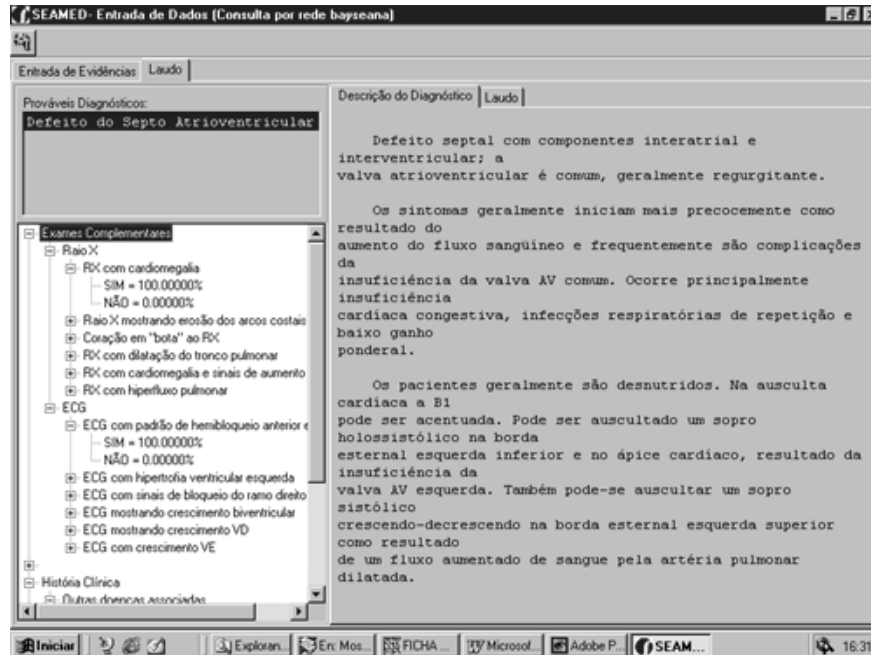


Figura 4 - Laudo

3 Conclusões

Com o uso da tecnologia de raciocínio probabilístico é possível melhorar a performance dos produtos já desenvolvidos pela empresa. Atualmente o raciocínio probabilístico possui larga aceitação mundial por ser considerado como uma forma correta e eficiente para se representar e tratar a incerteza. A técnica da árvore de junções constitui o atual estado da arte para a realização de inferência probabilística. A transferência de tecnologia para a ARQ Systems capacita essa empresa a desenvolver produtos de suporte à tomada de decisão com potencial de exportação.

Os seguintes desenvolvimentos da ferramenta criada estão previstos para previstos:

- construção de outros aplicativos para apoio a decisão na área médica, através da modelagem de novos domínios na área de saúde;
- expansão da ferramenta computacional para que também possa avaliar diagramas de influências. Um diagrama de influências é uma rede probabilística que representa a formalização de um problema de tomada de decisão em um ambiente com incerteza [11][12].
- expansão da ferramenta computacional para realização de inferências em redes bayesianas múltiplas seccionadas [14].

Agradecimentos

O framework SEAMED foi desenvolvido com recursos do PADCT III, projeto SEAMED – Sistema Especialista para a Área Médica, processo 03-AMPE-01/98-01/01-22.

Referências Bibliográficas

1. ANDREASSEN, V.; JENSEN, F.V.; ANDERSEN, S.K.; FALCK, B.; KJAERULFF, U.; WOLDBYE, M.; SORENSEN, A.; ROSENFALCK, A. & JENSEN, F. MUNIN – an expert EMG assistant. In: *Computer-aided electromyography and expert systems*. DESMEDT, J.E. (ed.). Amsterdam: Elsevier Science, p. 255-277, 1989.
2. COMMUNICATIONS OF THE ACM, v.38, n.3, March 1995 (*Real-World Applications of Bayesian Networks*).

3. DAVIS, R.; BUCHANAN, B. & SHORTLIFFE, E. Production Rules as a Representation for a Knowledge-Based Consultation Program. *Artificial Intelligence*. Amsterdam: North-Holland, v.8, 1977, p.15-45.
4. FLORES, C. & VICCARI, R. Architecture of an expert system for the pharmacological treatment of affective disorders. In: IV SIMPOSIO INTERNACIONAL DE COMUNICACIÓN SOCIAL. Proc. ... Santiago de Cuba, 1995.
5. FRANKLIN, R.; SPIEGELHALTER, D.; MACARTNEY, F. & BULL, K. Combining clinical judgements and statistical data in expert systems: over the telephone management decisions for critical congenital heart disease in the first month of life. In: *International Journal of Clinical Monitoring and Computing*, 6, p.157-66, 1989.
6. HECKERMAN, D.; HORVITZ, E. & NATHWANI, B. Towards normative experts systems: Part I. the Pathfinder project. *Methods of Information in Medicine*, 31, p.90-105, 1992.
7. JENSEN, F.V.; OLSEN, K. G. & ANDERSEN, S. K. An Algebra of Bayesian Belief Universes for Knowledge-Based Systems. *Networks*. New York: John Wiley & Sons, Inc., v.20, p.637-659, 1990.
8. JENSEN, F. V.; LAURITZEN, S. L & OLSEN, K. G. Bayesian Updating in Causal Probabilistic Networks by Local Computations. *Computational Statistics Quarterly*. Heidelberg: Physica-Verlag v.4, p.269-282, 1990
9. JENSEN, F. V. & JENSEN, F. Optimal Junction Trees. In: 10th CONF. ON UNCERTAINTY IN ARTIFICIAL INTELLIGENCE (UAI 94). Proc. ... San Francisco: Morgan Kaufmann, p.360-366, 1994.
10. JENSEN, F. V. *An Introduction to Bayesian Networks*. London: UCL Press, 1996. 188p
11. JENSEN, F.; JENSEN, F.V.; DITTMER, S.L. From Influence Diagrams to Junction Trees. In: 10th CONF. ON UNCERTAINTY IN ARTIFICIAL INTELLIGENCE (UAI 94). Proc.... San Francisco: Morgan Kaufmann, p.367-373, 1994.
12. LADEIRA, M.; VICCARI, R. M. & COELHO, H. Raciocínio Probabilístico em Sistemas Inteligentes. In: CONGRESSO DA SOCIEDADE BRASILEIRA DE COMPUTAÇÃO, XIX, 1999, Rio de Janeiro. *Anais ... v.2, JAI – Jornada de Atualização em Informática*. Rio de Janeiro: EntreLugar, 1999. 544p. p.307-365.
13. RUSSEL, S. & NORVIG, P. *Artificial Intelligence: a Modern Approach*. New Jersey: Prentice-Hall, 1995. 932p.
14. XIANG, Y. A Probabilistic Framework for Co-operative Multi-Agent Distributed Interpretation and Optimization of Communication. *Artificial Intelligence*. Amsterdam: Elsevier, v.87, p.295-342, 1996