

PROPOSTA DE UM ALGORITMO DE RECOMENDAÇÃO USANDO UMA REDE BAYESIANA NO HEALTH SIMULATOR

PROPOSAL FOR A RECOMMENDATION ALGORITHM USING A BAYESIAN NETWORK IN THE HEALTH SIMULATOR

Marta Bez¹, Paulo R. M. Barros², Alessandro Lima³, Fernando Helwanger⁴, Diego Reidel⁵

Recibido para publicación: 14 de julio 2016 - Aceptado para publicación: 9 de agosto 2016

ABSTRACT

This paper presents the Health Simulator project in the context of Artificial Intelligence in what regards to the storage of specialized knowledge in health care and educational strategy, that allows guiding students during learning process. Therefore, the paper covers the theory of Bayesian Networks, recommendation systems, the Health Simulator and finally a proposal for applying the techniques in the simulator environment.

INDEX TERMS: Recommendation Systems, Simulator, Health Simulator, Bayesian Networks

RESUMO

Este artigo apresenta o projeto Health Simulator no contexto de inteligência artificial, no que se refere ao armazenamento do conhecimento especializado na área da saúde e estratégia pedagógica, que permite o auxílio ao aluno no seu processo de aprendizagem. Para tanto é apresentada a teoria de redes bayesianas, sistemas de recomendação, o projeto Health Simulator e a proposta de aplicação das técnicas utilizadas neste ambiente.

PALAVRAS CHAVE: Sistemas de recomendação, Simulador, Health Simulator, Redes Bayesianas.

¹ Doutora em Informática na Educação pela Universidade Federal do Rio Grande do Sul (2013). Mestre em Ciência da Computação pela Pontifícia Universidade Católica do Rio Grande do Sul (2001) e graduada em Tecnólogo Em Processamento de Dados pela Universidade do Vale do Rio dos Sinos (1991). Atualmente é professora da Universidade Feevale nos cursos de Ciência da Computação, Sistemas de informação e no Mestrado de Indústria Criativa

² Doutorando em Computação Aplicada na Universidade do Vale dos Sinos, Mestre em Ciências da Saúde: Educação e Informática em Saúde pela Universidade Federal de Ciências da Saúde de Porto Alegre (2013), Bacharel em Sistemas de Informação pela Universidade Feevale (2009). Atualmente é Docente na Universidade Feevale e Arquiteto de Software na RJM Informática Ltd

³ Mestre em Design Virtual pela UFRGS (2015), Pós-graduado em MBA Comunicação Estratégica e Branding pela Universidade Feevale (2011) e Graduado em Design Gráfico pela Universidade Uniritter Laureate (2010).

⁴ Graduando em Ciência da Computação pela Universidade Feevale. Atualmente é Desenvolvedor de Soluções na Secullum Ponto e Acesso. Tem experiência em na área de Ciência da Computação

⁵ Ciência da Computação pela Universidade Feevale. Atualmente é Desenvolvedor de Soluções na SAP Brasil, atuando com uma das ferramentas de comércio eletrônico mais utilizadas no mundo. Tem experiência com desenvolvimento de aplicações mobile, comércio eletrônico e educação à distância

1. INTRODUÇÃO

Tem sido percebido um constante dinamismo e mudanças de conceitos nos ambientes estudantis. Novas métricas de ensino surgem de forma cada vez mais rápida e, junto a elas, as tecnologias educacionais. Segundo Botezatu et al. [1] essas, mais do que uma opção, são uma necessidade. Da mesma forma, as lacunas entre as atividades teóricas e as experiências clínicas que os estudantes da área da saúde vivenciam têm sido uma preocupação entre os educadores [2], pois os sistemas universitários fornecem uma estrutura envolvendo longos períodos de estudo intercalados com a prática clínica e os alunos, muitas vezes, não conseguem articular todos os conhecimentos e aplicar isso à prática [3], [4]. Buscando amenizar estes problemas, tem surgido diversos simuladores que permitem ao aluno articular a teoria e a prática. Exemplos desses simuladores são os desenvolvidos por [5], [1], [6], [7], entre tantos outros.

Simuladores de ensino médico podem ser compreendidos de forma ampla como ferramentas que permitam aos educadores manter o controle total em cenários clínicos pré-selecionados, descartando, nesta fase de aprendizagem, os riscos potenciais ao paciente [8]. Complementando, Kincaid e Hamilton [9], apresentam vantagens no uso de simuladores para o ensino médico, tais como: auxilia o aluno a compreender as relações complexas, que de outro modo exigiriam equipamentos caros ou experiências potencialmente perigosas; permite a aplicação de conhecimentos científicos e técnicos de forma integrada e simultânea; permite que o aluno busque novos métodos e estratégias para a solução de um mesmo caso do estudo; fornece um ambiente próximo da realidade para a formação e o reforço dos conhecimentos adquiridos; reduz o risco em situações autênticas.

Bradley [10] complementa, identificando outros benefícios, como: riscos para os pacientes e alunos são evitados; a interferência indesejada de fatores externos ao foco do ensino é reduzida; as habilidades podem ser praticadas repetidamente; o treinamento pode ser adaptado para os indivíduos; a retenção e a precisão são aumentadas; a transferência de treinamento da sala de aula para uma situação real é reforçada; normas de referência para avaliar o desempenho dos alunos e diagnosticar as necessidades

educacionais são reforçadas.

Este artigo apresenta a proposta de um simulador do tipo Paciente Virtual denominado Health Simulator. Este se utiliza de dois conceitos importantes da área de Inteligência Artificial: Redes Bayesianas e Sistemas de Recomendação. Estes conceitos são apresentados na sequência. Ao final é apresentado o simulador Health Simulator e a integração de Sistemas de Recomendação como forma de indicar os próximos casos de estudos a serem resolvidos de acordo com a evolução do aluno na Rede Bayesiana.

2. REDES BAYESIANAS

O processo de diagnóstico, independente se for médico, de reparo automobilístico, ou qualquer outra área, quase sempre envolve incerteza. Neste processo, usando a área médica como exemplo, o médico avalia sinais e sintomas que indicam a probabilidade de o paciente possuir determinada doença. Neste cenário, as doenças são consideradas causas e os sinais e sintomas são considerados efeitos [11], [12].

Os sinais e sintomas geralmente não indicam com 100% de certeza a causa de uma única doença, mas sim qual a probabilidade de que o paciente possua cada doença presente em um determinado conjunto. Para a solução deste tipo de problema, não é possível a utilização de técnicas, como a lógica de primeira ordem, que tratem o resultado como uma única possibilidade. É preciso utilizar técnicas que determinem o grau de confiança em cada um dos possíveis resultados [11], [13].

Para modelar este tipo de problema, é preciso identificar quais variáveis aleatórias tem relevância para o problema. Essas variáveis podem ser de diferentes tipos [13]:

- Booleanas: variáveis que representem proposições, de domínio “verdadeiro” ou “falso”.
- Numéricas: variáveis que representem medidas físicas, como altura, largura, velocidade, etc.
- Categóricas: variáveis que representem categorias, como cores, letras, entre outras.

Feita a definição das variáveis relevantes para o problema, uma maneira de resolvê-lo seria através

da construção de uma tabela que considere todos os estados possíveis e atribua uma probabilidade a cada uma das possibilidades. Porém, para problemas reais que envolvam um número relativamente grande de variáveis, essa tabela pode ter um tamanho impraticável, já que seu crescimento é exponencial em relação ao número de variáveis envolvidas [11], [12], [13].

Outra maneira mais compacta para a representação deste tipo de problema é através da utilização de Redes Bayesianas. Nas Redes Bayesianas, a propriedade de independência condicional entre as variáveis é aproveitada para que o número de combinações entre elas seja diminuído. Uma variável A é dita condicionalmente independente de uma variável B caso, dado o valor de uma variável C, B não tenha nenhuma influência em A. Com essa diminuição de tamanho adquirida pela utilização de Redes Bayesianas, problemas que seriam impraticáveis tornam-se possíveis [11], [13].

Uma Rede Bayesiana envolve duas partes, uma qualitativa e outra quantitativa. A parte qualitativa envolve a estruturação da rede na forma de um grafo acíclico dirigido. Neste grafo, cada nodo representa uma variável aleatória e a topologia do grafo representa as relações de independência condicional entre as variáveis. Se houver uma aresta que vai do nodo A até o nodo B, o nodo A é dito pai do nodo B. Neste caso, B é condicionalmente independente de todos os outros nodos que não sejam descendentes de B, dado o valor de A [11], [13]. A parte quantitativa envolve a definição de uma tabela de distribuição

de probabilidades condicionais para cada variável. Porém, ao invés de considerar todas as combinações possíveis entre todas as variáveis observadas, é considerada apenas a influência dos pais diretos de cada nodo. Com isto, não é necessário trabalhar com uma tabela normalmente grande, mas sim, com uma tabela menor associada a cada nodo, o que geralmente é mais simples [11], [13]. A definição das probabilidades para estas tabelas pode ser construída a partir da computação de dados, manualmente, por um especialista no domínio analisado ou ainda uma mistura entre as duas técnicas [14].

As arestas que conectam os nodos de uma Rede Bayesiana são normalmente interpretadas como uma relação de causa e efeito entre duas variáveis. Ou seja, se uma determinada doença causar um determinado sintoma, isso pode ser representado em uma Rede Bayesiana em que o nodo da doença é pai do nodo do sintoma, representando que ela é a causa do efeito. Isso se assemelha a maneira que humanos especialistas em domínios de conhecimento raciocinam, o que torna uma Rede Bayesiana uma representação natural do conhecimento [13].

A Figura 1, apresenta um exemplo de Rede Bayesiana composta por 5 nodos, juntamente com as tabelas de probabilidade condicional associadas a cada nodo. O problema modelado nesta rede envolve o acionamento do alarme de uma residência, que pode ter como causa um roubo ou um terremoto. O fato do alarme ser acionado pode causar mais dois efeitos, que seriam a probabilidade de dois vizinhos ligarem

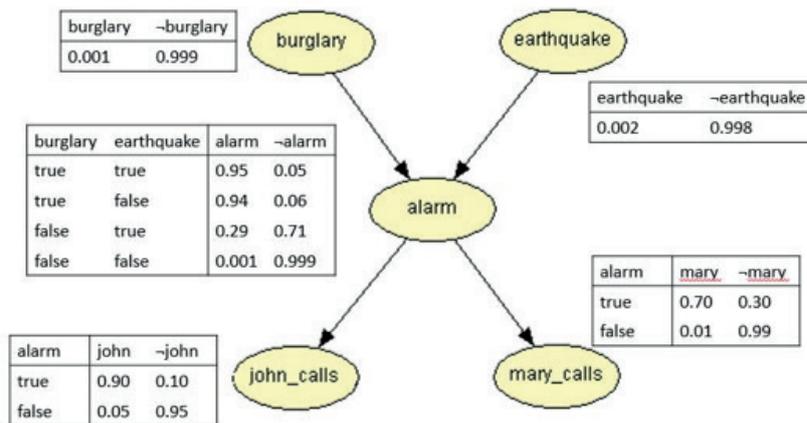


Figura 1. Exemplo de Rede Bayesiana [11].

para o morador avisando do ocorrido. A partir dessa definição é possível realizar diversas inferências probabilísticas, como, por exemplo, dado que os dois vizinhos ligaram, qual a probabilidade de que tenha ocorrido um roubo?.

O uso de software para a construção e o cálculo de Redes Bayesianas pode ser utilizado para auxiliar o processo de diagnóstico médico, tanto na prática quanto no ensino. No contexto do ensino, o aluno precisa praticar a construção de modelos hipotéticos que relacionem doenças com suas causas e sintomas. É preciso que ele possa avaliar a situação e tomar decisões durante este processo. Desta forma, o uso de simuladores proporciona ao aluno um ambiente em que ele possa praticar este tipo de raciocínio. Nestes simuladores, o uso de Redes Bayesianas provê uma maneira para a representação e inferência do conhecimento e raciocínio [15].

3. SISTEMAS DE RECOMENDAÇÃO

Um sistema de recomendação (SR) é uma ferramenta computacional que, dado um grupo extenso de itens recomendáveis, apresenta a um usuário aqueles que possam ser de seu maior interesse. Geralmente essa apresentação se dá na forma de uma recomendação simples ou como uma predição do valor da utilidade de um dado item para o usuário em questão.

O estudo desses sistemas ganhou destaque por volta da década de 90, principalmente quando cientistas do Palo Alto Research Center (PARC), na Califórnia, desenvolveram um algoritmo para filtragem de correio eletrônico [17], [16].

Em ferramentas ou sistemas com grande volume de itens, como fóruns de debate, bibliotecas virtuais, ou mesmo a Internet, uma sobrecarga de conteúdo pode acabar atrapalhando a busca de um usuário por aquilo que ele precisa ou acha mais relevante. Quando a informação que se busca é mais especializada, esse problema se acentua, de forma que frequentemente faz-se necessário que se dedique uma grande porção de tempo garimpando as respostas obtidas em uma busca. Além disso, é possível que informações importantes se percam por estarem contidas em materiais indexados posteriormente [18]. Um sistema de recomendação é uma ferramenta de inteligência artificial que aprende as preferências de um ou mais usuários e lhe apresenta aquilo que

se prevê ter maior valor, mitigando os problemas descritos anteriormente.

Cada técnica de recomendação traz consigo características distintas, porém grande parte dos estudos classificam os sistemas de recomendação em três categorias: content-based filters (filtragem baseada em conteúdo), collaborative filtering (filtragem colaborativa) e algoritmos híbridos, sendo o último o resultado da união das duas primeiras categorias em um mesmo algoritmo [16].

3.1. Filtragem Colaborativa

As técnicas de filtragem colaborativa baseiam-se em recomendar itens com base nas avaliações feitas por outros usuários do sistema. Nessa abordagem duas subcategorias se destacam: recomendação baseada no usuário (*user based*) e baseada no item (*item based*). Na abordagem do tipo *user based*, se cria um agrupamento de indivíduos com perfil similar ao do usuário ativo (vizinhos) e assume-se que a avaliação a um item pelo usuário ativo será bastante similar às avaliações realizadas por parte do seu grupo de vizinhos. Dessa forma, itens bem avaliados pelo grupo de vizinhos serão apresentados ao usuário ativo. Já aqueles que não tenham sido bem avaliados, terão menor importância para o usuário e por isso podem ser indexados posteriormente, por exemplo [19], [20]. Um elemento de grande importância nesse método é a escolha dos indivíduos que farão parte do grupo de vizinhos do usuário em questão [20]. Geralmente esse agrupamento é feito através de uma função de similaridade, como a correlação de Pearson. A equação (1) mostra uma fórmula da correlação de Pearson, que indica a similaridade *sim* entre dois usuários *ua* e *ub*, onde um grupo de *m* usuários *uk*, com *k* = 1, 2, ..., *m*, *Um* = {*u1*, *u2*, ..., *um*}, realizaram uma avaliação *R(uk, il)* para um item *il*, onde *l* = 1, 2, ..., *n*, *ln* = {*i1*, *i2*, ..., *in*} é um grupo de itens [21], [22], [20]:

$$sim_{u_a, u_b} = \frac{\sum_{l=1}^n R_{u_a, i_l} \bar{R}_{u_a} R_{u_b, i_l} \bar{R}_{u_b}}{\sqrt{\sum_{l=1}^n R_{u_a, i_l}^2 - \bar{R}_{u_a}^2} \sqrt{\sum_{l=1}^n R_{u_b, i_l}^2 - \bar{R}_{u_b}^2}}$$

Já algoritmos baseados em itens traçam similaridades entre itens usando as avaliações de usuários. Desta forma, quando o sistema detecta

o interesse do usuário por um item, ele pode recomendar outro item similar. Se os usuários que avaliam o item i positivamente também avaliam positivamente o item j , é possível assumir que i e j são similares e, portanto, pode-se recomendar j a um usuário u que avalie i de forma positiva, ou vice-versa. Caso o contrário ocorra e um item k seja avaliado negativamente por usuários que bem avaliaram i , pode-se assumir que k não é similar a i e, portanto, não deve ser recomendado a u [21].

3.2. Filtragem Baseada em Conteúdo

Na abordagem de recomendação baseada em conteúdo busca-se identificar itens que possam ser de interesse do usuário tomando como base para a decisão avaliações que o usuário já tenha realizado a outros itens. Neste método cada item recomendável traz consigo atributos ou palavras-chave que descrevem o seu conteúdo. Além disso, busca-se construir um perfil para cada usuário com atributos que por ele já tenham sido avaliados. Ou seja, toda vez que o usuário u avalia um item i , o perfil que descreve as preferências de u é atualizado para cada um dos atributos de i . Para realizar uma recomendação, se busca por itens que apresentem atributos e características similares às quais o perfil do usuário mostre boa aceitação [21].

Existem diversas maneiras para captar o conteúdo de um item e identificar suas características, sendo uma das principais técnicas conhecida como Term Frequency – Inverse Document Frequency (TF-IDF). Essa técnica consiste em identificar termos frequentes em um documento que não sejam frequentes no restante do grupo de itens [23].

3.3. Sistemas Híbridos

As técnicas híbridas consistem em agrupar dois ou mais algoritmos distintos em uma mesma solução, com o intuito de maximizar a relevância da recomendação para o usuário. Cada método de recomendação apresenta forças e desvantagens. A recomendação baseada em conteúdo, por exemplo, é suscetível ao problema conhecido como superespecialização. Já a abordagem colaborativa sofre com o cold-start (falta de informações sobre um item ou usuário quando ele foi recém inserido no sistema). Ao utilizar um método híbrido, se busca usar o potencial de uma abordagem para minimizar as fraquezas de outra. Diversos algoritmos híbridos já foram propostos

para as mais variadas áreas, demonstrando o potencial dessa técnica.

4. HEALTH SIMULATOR

O Health Simulator é um jogo que simula um Paciente Virtual (PV), projetado para ser um recurso adicional na formação de estudantes da área de saúde. O seu desenvolvimento tem como foco os benefícios do uso de simuladores virtuais e as principais características dos jogos, que além de ser utilizados como recurso de diversão e interatividade de cunho colaborativo [26], permitem ao jogador entender a dinâmica, sistemática de ações, o ambiente e condições que lhe dão vitória ou perda, fazendo com que ele compreenda seus erros e acertos de forma segura e controlada. Outra característica interessante que se vislumbra, é permitir o entendimento de diversas relações complexas, sem a necessidade de equipamentos caros ou situações que possibilitem risco ou dano; permitindo a aplicação de conhecimentos científicos e técnicos de forma integrada e simultânea.

Deste modo, o Health Simulator apresenta-se como um ambiente complexo, sendo dividido em duas grandes áreas, em função das diferentes arquiteturas utilizadas, o aplicativo do jogo, chamado de Front-end, e o servidor, que é utilizado como um repositório de informações, chamado de Back-end.

A estrutura do simulador é apresentada na Fig. 2, e suas etapas serão especificadas na sequência.

4.1. Front-end

Front-end compõem a parte do simulador que será destinado aos alunos, apresentada em formato de um jogo sério, desenvolvido sob a plataforma da Unity, que permite que o jogo rode em diferentes plataformas e ambientes. O jogo possui cenários e personagens que representam profissionais da área da saúde e pacientes, reproduzindo da forma mais fiel possível um ambiente real.

O ambiente desenvolvido conta com diversos modelos de personagens (Fig. 3). São quatro categorias de personagens (médicos, pacientes, dentistas e enfermeiros), de ambos os gêneros, idades e etnias. Os cenários desenvolvidos (Fig. 4), são formados por consultórios, hospitais das classes A, B ou C e um hospital do Sistema Único de Saúde (SUS). Destaca-se também

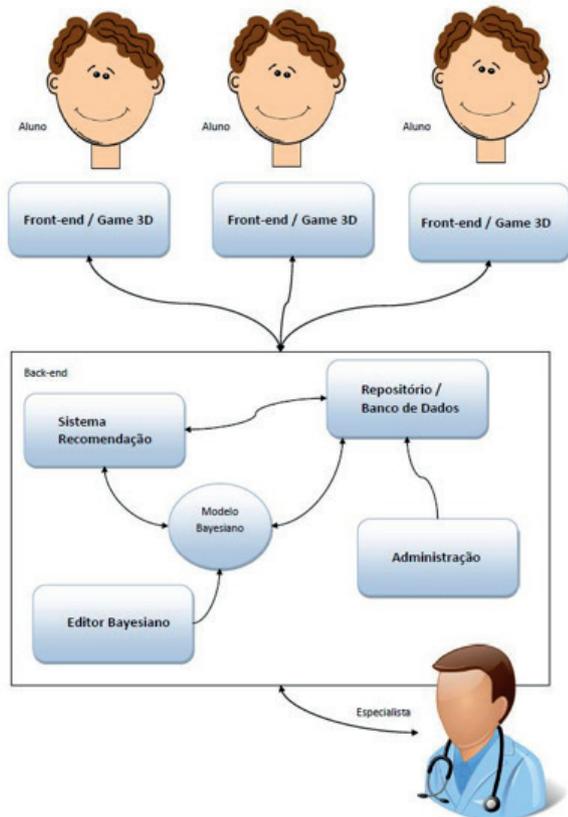


Figura 2. Estrutura do Health Simulator.

o número elevado de *assets* (objetos) que foram desenvolvidos para compor os cenários. Exemplos de *assets* são cadeiras, mesas, poltronas, macas, estetoscópio, etc. Estes podem ser reaproveitados, compondo novos cenários de acordo com a necessidade.

O projeto da interface do game está em fase final de desenvolvimento, a estrutura foi definida por turnos, onde, a cada turno, a engine envia informações ao Back-end, recebendo respostas da mesma. A troca de informações entre o jogo

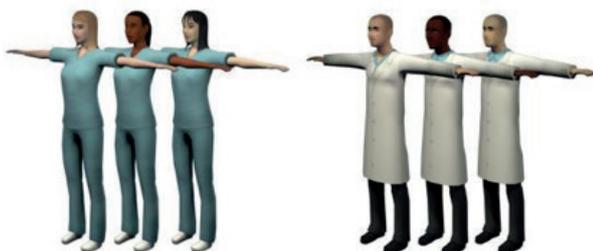


Figura 3. Modelos de enfermeiras e médicos nas etnias branco, negro e asiático.



Figura 4. Exemplo de cenário para consultório Classe C.

e o servidor ocorre de tempo em tempo, sendo representada como turno. A cada comunicação são inferidas novas variáveis em função das ações tomadas e, de acordo com o modelo bayesiano analisado. É apresentada uma resposta adequada, fornecendo ao jogador uma nova orientação.

4.2. Back-end

Para o back-end, tem-se uma estrutura complexa, sendo dividido em: Modelagem do conhecimento; Interface de administração e Sistema de recomendação, além da estrutura de comunicação.

A modelagem do conhecimento, primeira etapa, consiste em delimitar o conhecimento a ser representado pelo especialista. Para isto, ele faz uso de uma diretriz clínica, uma forma sistemática de orientação e delimitação do conteúdo a ser desenvolvida a partir de evidências, característica relatada como muito importante para um software educacional voltado ao ensino médico [27]. A partir deste momento, é necessário desenvolver um modelo estatístico de representação do conhecimento, através de uma rede bayesiana. A Fig. 5 apresenta uma rede bayesiana de cefaleia, baseada na diretriz clínica de cefaleia. Esta encontra-se disponível para acesso no site da Associação Médica Brasileira (http://www.projetodiretrizes.org.br/8_volume/16-Cefaleias.pdf). Cabe salientar que uma mesma Rede Bayesiana permite a geração de mais de cinquenta casos de estudo diferentes, dependendo da criatividade do professor.

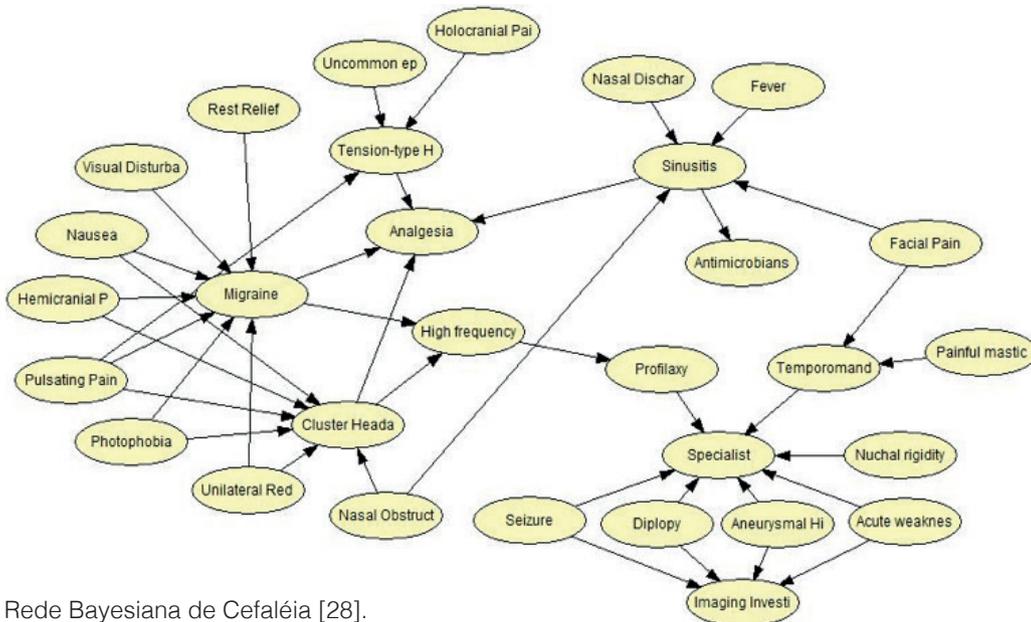


Figura 5. Rede Bayesiana de Cefaléia [28].

A interface de administração permite que o sistema seja gerenciado através da criação de usuários, cadastros principais (instituição, disciplina, avatar, tipo de exame, criação do caso clínico, entre outros).

A parte principal da interface de administração (Fig. 6), é um ambiente web onde o professor tem acesso aos sinais e sintomas presentes na rede, definidos na etapa anterior, possíveis históricos anteriores do paciente, bem como exames físicos e complementares. Conforme sua seleção, o sistema deve apresentar o desfecho do caso, apontando os diagnósticos e condutas, conforme

as probabilidades são propagadas na rede, facilitando o processo e a elaboração de cada caso clínico. Esse processo pode ser observado a direita nos quadros Diagnóstico e Conduta. Com isso, o professor que desenvolverá os casos de estudo não necessita conhecer a rede bayesiana ou qualquer formalismo da área da informática.

Um caso clínico gerado no *Health Simulator* é armazenado no banco de dados, ficando disponível para utilização pelos alunos a partir do jogo através dos módulos de comunicação, e pelo módulo do sistema de recomendação, que representa o suporte pedagógico ao ambiente.



Figura 6. Cadastro de Avatar.

5. PROPOSTA DE USO DE SISTEMAS DE RECOMENDAÇÃO NO HEALTH SIMULATOR

O sistema de recomendação está em fase de prototipagem, e tem como objetivo auxiliar pedagogicamente o aluno, dando orientações mais amplas do que o simples resultado da inferência. Sua responsabilidade é muito maior, ele deve atuar de forma ativa durante a partida, analisando cada passo dado pelo aluno, coletando informações pertinentes ao seu desempenho e registrando estas informações para que sirvam de base de conhecimento para fornecer recomendação, colaborando com indicações pertinentes a sua fase de aprendizado. Desta forma, o objetivo é que este possa auxiliar o aluno na sua construção do conhecimento.

Manouselis et al. [19] apontam que os objetivos da recomendação no contexto da educação podem diferir daqueles nas demais áreas que fazem uso desse recurso, trazendo assim a necessidade de se mapear esses requisitos particulares, buscando a construção de ferramentas mais adequadas ao uso na educação. Estes autores mostram que tarefas recorrentes em sistemas de recomendação, tais como encontrar os melhores itens para um usuário ou prever quão relevante um determinado item pode ser para um usuário, são também aplicáveis ao contexto da educação. Entretanto, quando se busca a construção do aprendizado em um indivíduo, é possível explorar outros recursos que não estão presentes em sistemas de recomendação tradicionais. A

Tabela I apresenta algumas tarefas que podem ser abordadas em sistemas de recomendação voltados à educação, conforme apontado por [19].

proposto aqui um algoritmo de recomendação híbrido para uso no Health Simulator. O principal objetivo do algoritmo é analisar o desempenho do usuário durante a partida, identificar o grau de entendimento no conteúdo apresentado e, com base nessa análise, recomendar os próximos materiais ou casos clínicos, de forma que o usuário exercite suas fraquezas, reforce seu conhecimento ou adquira novos conhecimentos.

A abordagem toma como entrada uma diretriz clínica, representada na forma de uma rede bayesiana, como descrito anteriormente. O algoritmo deve recomendar ao aluno uma maneira de explorar a diretriz clínica, indicando áreas da rede bayesiana na qual ele ainda apresenta dificuldade de aprendizado ou que não tenha sido estudada. Ou seja, se busca notar áreas da rede bayesiana da diretriz clínica na qual o aluno já tem forte conhecimento e então lhe induzir a casos similares que estejam em áreas que o aluno ainda não domina. Um exemplo disso seria, ao notar que o aluno tem experiência no diagnóstico de enxaqueca, recomendar-lhe algo que o faça explorar mais a diretriz clínica, como um caso de sinusite. Busca-se, com isso, abordar o terceiro item listado por [19] na Tabela I, visto que o aluno terá uma indicação de caminho de aprendizagem personalizada de acordo com seus conhecimentos.

Tabela 1. Tarefas que podem ser abordadas em sistemas de recomendação [19].

Tarefa	Descrição	Uso na educação
Encontrar novos itens	Recomendação de itens recém inseridos no sistema	Apontar itens recentes ou de conteúdo controverso
Encontrar parceiros	Recomendar usuários com interesses similares	Apontar estudantes de uma mesma classe, com preferências ou dificuldades similares
Encontrar bons caminhos	Recomendar uma sequência de itens	Apontar uma sequência de itens a serem estudados, buscando aprendizado em uma determinada área

Dessa forma, vê-se a necessidade de dois passos para a recomendação. O primeiro é a identificação de quão longe na rede bayesiana se pode avançar. Ou seja, tendo em vista que o usuário ativo está estudando um caso clínico x , quanto é possível afastar-se de x para proporcionar ao aluno o melhor aprendizado? Essa identificação se dá através de uma avaliação do conhecimento do aluno no diagnóstico do caso clínico x . Tomando como partida o nodo da diretriz clínica que representa o diagnóstico de x , a rede bayesiana será expandida com o uso do algoritmo de busca em largura com um limite de nível. Esse limite de nível será determinado pela avaliação do conhecimento do aluno.

O segundo passo é identificar, dentro do grupo de itens nos níveis recomendáveis ao aluno, quais lhe trariam maior aprendizado. Para tal, decidiu-se utilizar o algoritmo descrito por [25]. Nesse algoritmo se identificam os alunos com melhor aprendizado, chamados de *good learners*. Um *good learner* é um aluno com aproveitamento maior que 80%. A avaliação desses alunos à itens e materiais é, então, levada em consideração para a recomendação. Entende-se que os itens melhor avaliados por bons alunos são mais indicados para os demais colegas. Essa técnica foi avaliada pelos autores e mostrou um aumento de 12,16% no desempenho dos alunos em comparação às técnicas tradicionais de recomendação [25]. Esse mesmo algoritmo pode ainda suprir as necessidades do segundo item descrito na Tabela I [19], recomendado um colega de estudos – um dos *good learners* – ao usuário ativo.

Espera-se que com o crescimento do uso do simulador, novos casos clínicos sejam gerados a partir da rede, que se tornará, eventualmente, bastante abrangente. Por isso a importância de um sistema de recomendação que deve não somente mostrar bons casos de estudo a um usuário, mas também guiá-lo pela rede bayesiana da diretriz clínica, proporcionando assim, maior oportunidade de aprendizado ao aluno.

Logo, a primeira fase da recomendação deve filtrar os casos clínicos tomando como base o nível do aluno e a área do caso de estudo. Como o ponto de partida para essa etapa da recomendação é baseado no conteúdo do caso inicial e então faz-se a seleção de outros casos similares, classificamos essa primeira etapa como uma recomendação baseada em

conteúdo. Depois, a segunda etapa deve realizar um segundo filtro, buscando dentre os casos apontados pela primeira etapa os que tem maior aceitação da comunidade de estudantes, ou seja, um filtro colaborativo.

6. CONSIDERAÇÕES FINAIS

Este artigo apresentou o simulador do tipo paciente virtual Health Simulator, que faz uso de dois formalismos de inteligência artificial: redes bayesianas e sistemas de recomendação. Para entendimento do seu funcionamento, os dois foram apresentados e exemplificados.

O Health Simulator foi dividido em duas partes distintas: Front-end e Back-end. O front-end foi desenvolvido no formato de um jogo sério, contendo mais de 150 personagens modelados e diversos cenários. Este está em fase de finalização e testes. O back-end, foco deste artigo, é composto pelo sistema que armazena o conhecimento do especialista, o sistema de recomendações e o sistema a ser utilizado pelos professores para a criação dos casos clínicos.

As redes bayesianas são utilizadas para o armazenamento do conhecimento do especialista. Essa representação parte das diretrizes clínicas a serem utilizadas pelos alunos para aprendizado em saúde. Essa mesma rede bayesiana é então empregada no sistema de recomendação, para seleção dos materiais a serem recomendados ao usuário ativo.

simulador encontra-se em fase final de desenvolvimento. O sistema de recomendação a ser empregado está ainda em fase de prototipagem. Faz-se necessário ainda a identificação de como se dará a análise do nível de conhecimento do aluno em uma determinada área, bem como definir como isso será traduzido para uma representação numérica a ser utilizada como limite de nível para a busca em largura no grafo da rede bayesiana.

Após a implementação completa será possível realizar as primeiras avaliações com as duas etapas da recomendação: a busca em largura e o algoritmo descrito por [25]. Acredita-se que o sistema de recomendação proposto trará um aumento do desempenho dos alunos, se comparado ao aprendizado sem recomendação ou às técnicas comuns baseadas em conteúdo ou

de filtragem colaborativa.

3, p.193-199, 2005.

REFERENCIAS

- [1]. M. BOTEZATU, H. HULT, U. G. FORS. Virtual patient simulation: what do students make of it? A focus group study. *BMC Medical Education*, v. 10, n. 91, 2010.
- [2]. J. HIGGS, M. A. JONES, S. LOFTUS, H. CHRISTENSEN. *Clinical reasoning in the health professions*. 3.ed., China: Elsevier, 2008.
- [3]. M. FORTE, W. L. de SOUZA, A. F. PRADO. Portfólio Eletrônico Ubíquo no Aprendizado de Medicina. In: Congresso Brasileiro de Informática em Saúde – CBIS, 12., 2010, Recife/PE. Anais do XII Congresso Brasileiro de Informática em Saúde – CBIS 2010, São Paulo: Sociedade Brasileira de Informática em Saúde, 2010, p.1-6.
- [4]. S. D. BROOKFIELD. *The power of critical theory: liberating adult learning and teaching*. 1.ed., San Francisco: Jossey-Bass, 2005, 414p.
- [5]. A. HOLZINGER, M. D. KICKMEIER-RUST, S. WASSERTHEURER, M. HESSINGER, M. Learning performance with interactive simulations in medical education: Lessons learned from results of learning complex physiological models with the HAEMOdynamics Simulator. *Computer & Education*, v. 52, n. 2, p.292-301, 2009
- [6]. S. J. SMITH, C. J. ROEHRS. High-fidelity simulation: Factor correlated with nursing student satisfaction and self-confidence. *Nursing Education Perspectives*, v. 30, n. 2, p.77-78, 2009.
- [7]. P. R. BARROS, S. C. CAZELLA, M. B. BEZ, C. D. FLORES, A. DAHMER, J. B. MOSSMANN, J. M. FONSECA, V. MARONI. Um Simulador de Casos Clínicos Complexos no Processo de Aprendizagem em Saúde. *RENTE. Revista Novas Tecnologias na Educação*, v. 12, p. 1-11, 2012.
- [8]. A. ZIV, S. BEN-DAVID, M. ZIV, M. Simulation Based Medical Education: an opportunity to learn from errors. *Medical Teacher*, v. 27, n. 3, p.193-199, 2005.
- [9]. J. P. KINCAID. *Simulation in Education and Training*. In: *Modeling and Simulation: Theory and Applications*, 1. ed., Boston: Kluwer, 2004, Cap.19, p. 273-280.
- [10]. P. BRADLEY. The history of simulation in medical education and possible future directions. *Medical Education*, v. 40, n. 3, p.254-262, 2006.
- [11]. S. RUSSELL, P. NORVIG. *Artificial Intelligence: A modern approach*. 3rd ed. New Jersey: Prentice-Hall. 1995. 1132 p.
- [12]. R. L. MARQUES, I. DUTRA. *Redes Bayesianas: o que são, para que servem, algoritmos e exemplos de aplicações*. Coppe Sistemas – Universidade Federal do Rio de Janeiro, Rio de Janeiro, Brasil, 2002.
- [13]. N. J. NILSSON. *Artificial intelligence: a new synthesis*. San Francisco: Morgan Kaufmann, 1998. 513 p.
- [14]. W. WIEGERINCK, B. KAPPEN, W. BURGERS. *Bayesian networks for expert systems: Theory and practical applications*. In: *Interactive collaborative information systems*. Springer Berlin Heidelberg, 2010. p. 547-578.
- [15]. L. J. SEIXAS et al. An architecture for an intelligent learning environment with a constructivist approach. *ITS2002*. San Sebastian, Spain. 2002.
- [16]. M. R. FAZIO. *Previsão de avaliações em sistemas de recomendação para nichos de mercado*. Ph.D. Dissertation, COPPE, UFRJ, Rio de Janeiro, RJ, Brazil, 2013.
- [17]. D. GOLDBERG, D. NICHOLS, B. M. OKI, D. TERRY. Using collaborative filtering to weave an information tapestry. *Commun. ACM*, vol. 35, no. 12, pp. 61-70, Dec. 1992.
- [18]. G. R. LOPES. *Avaliação e recomendação de colaborações em redes sociais acadêmicas*. M.S. thesis, PPGC, UFRGS, Porto Alegre, RS, Brazil, 2012.
- [19]. N. MANOUSELIS, H. DRACHSLER, R.

- VUORIKARI, H. HUMMEL, R. KOPER. Recommender systems in technology enhanced learning. In: Recommender Systems Handbook, 1st ed., F. Ricci, L. Rokach, B. Shapira, P. B. Kantor, Ed. New York: Springer, 2010, pp. 387 – 409.
- [20]. G. G. TESTA. Uma abordagem híbrida para recomendação de parceiros em ambientes virtuais colaborativos de composição musical. Ph. D. dissertation, Prog. de Pós-Grad. em Comp., UFRGS, Porto Alegre, RS, Brazil, 2013.
- [21]. A. S. LAMPROPOULOS, G. A. TSIHRINTZIS. Review of previous work related to recommender systems. In: Machine Learning Paradigms, Applications in Recommender Systems, 1st ed., New York: Springer, 2015, pp. 13 – 30.
- [22]. B. SARWAR, G. KARYPIS, J. KONSTAN, J. RIEDL. Item-based collaborative filtering recommendation algorithms. In: Proceedings of the 10th International Conference on World Wide Web. ACM, pp. 285-295.
- [23]. H. WU, Y. PEI, B. LI, Z. KANG, X. LIU, H. LI. Item recommendation in collaborative tagging systems via heuristic data fusion. Knowledge Based Systems, v. 75, pp. 124 – 140, Feb., 2015.
- [24]. F. RICCI, L. ROKACH, B. SHAPIRA, P. B. KANTOR. Introduction to recommender systems handbook. In: Recommender systems handbook, 1st ed., New York: Springer, 2010, pp. 1 – 38.
- [25]. K. I. GHAUTH, N. A. ABDULLAH. The effect of incorporating good learners' ratings in e-Learning recommender system. Educational Technology & Society, v. 14, n. 2, pp. 248 – 257, Feb., 2012.
- [26]. P. SCHUYTEMA. Design de Games: uma abordagem prática. São Paulo: Cengage Learning, 2008. p. 447.
- [27]. V. JHA, S. DUFFY. 'Ten golden rules' for designing software in medical education: results from a formative evaluation of DIALOG. Med Teach. 24(4), 417–421. 2002. DOI: 10.1080/01421590220145798.
- [28]. C. F. FLORES, J. M. FONSECA, M. R. BEZ, A. RESPÍCIO, H. COELHO. Method for Building a Medical Training Simulator with Bayesian Networks: SimDeCS. Studies in health technology and informatics, 207, 102-114. 2013.