

Um ambiente de aprendizagem informal com recomendações de conteúdos para portadores de doenças crônicas

Salatiel D. Silva¹, Ademar F. de Sousa Neto², Francisco M. Mendes Neto¹,
Alexandre A. C. de Freitas¹, Arthur S. Domingues¹,
Jesaias C. P. Silva¹, Ramiro V. Santos Junior³, Igor Fernandes dos Santos¹

¹Programa de Pós-Graduação em Ciência da Computação
da Universidade Federal Rural do Semi-Árido (UFERSA)

²Programa de Pós-Graduação em Ciência da Computação
da Universidade Federal de Campina Grande (UFCG)

³Programa de Pós-Graduação em Sistemas e Computação
da Universidade Federal do Rio Grande do Norte (UFRN)

{ademarneto,miltonmendes,salatiel.dantas,ramiro.junior}@ufersa.edu.br,

{jesayassilva,igor.fsantos96}@gmail.com,

arthurdomingues91@hotmail.com,

alexandreadler@outlook.com

Abstract. *Chronic diseases impose several limitations on the health conditions of its wearer. These diseases have grown over 60 % over the past 10 years, thus necessitating a software that can meet both the patient's demand and the health specialist's demand. In this way, learning more about the disease helps improve the quality of life. Web 2.0, over the years, has become a great ally in the search for knowledge, enabling the patient to become more active in the treatment of his illness. However, the search for information that fits the patient's context can be difficult due to the large volume of information available. This paper presents an environment that seeks to alleviate this difficulty by analyzing the user profile, health data and relationships with people with the same health problem and thus provide a recommendation that is more adequate to their needs. Part of this environment consists of a Specialist Intermediate Module that provides access to a set of patient treatment information, seeking to make patient treatment more appropriate.*

Resumo. *Doenças crônicas impõem diversas limitações as condições de saúde de seu portador. Estas doenças, nos últimos 10 anos, cresceram mais de 60%, tornando assim necessário um software que possa atender tanto a demanda do paciente, quanto a demanda do especialista em saúde. Desse modo, aprender mais sobre a doença ajuda a melhorar a qualidade de vida. Web 2.0, ao longo dos anos, se tornou uma grande aliada na busca de conhecimento, possibilitando que o paciente se torne mais ativo no tratamento da sua doença. Todavia a procura por informações que se adequem ao contexto do paciente pode ser difícil, devido ao grande volume de informações disponíveis. Este trabalho*

apresenta uma ambiente que busca amenizar essa dificuldade, analisando o perfil do usuário, seus dados da saúde e suas relações com pessoas com o mesmo problema de saúde e assim proporcionando uma recomendação mais adequada às suas necessidades. Parte desse ambiente é constituído por um Módulo de Intermediário do Especialista que possibilita o acesso um conjunto de informações do tratamento de pacientes, buscando tornar o tratamento dos pacientes mais adequado.

1. Introdução

O problema de saúde mais importante do século XXI tem sido as doenças crônicas. Doença crônica é qualquer distúrbio que persiste por um longo período e afeta o funcionamento físico, emocional, intelectual, profissional, social ou espiritual, que possui longa duração com progressão geralmente lenta [Zwar et al. 2017].

Dentro dessa realidade, diversos estudos referentes ao uso das tecnologias para auxiliar os portadores de doenças crônicas vêm sendo realizados. Consequentemente, surgiram diversas Tecnologias da Informação e Comunicação (TICs) para fornecer cuidados clínicos a pacientes. Inserido nas TICs, existe o conceito de Saúde 2.0, que faz uso de ferramentas da Web 2.0 e, segundo Belt et al. (2010), pode ser definida como a capacidade do indivíduo de ser responsável e ativo pela sua própria saúde, bem como os cuidados relativos a ela.

Diante dessa problemática, este trabalho apresenta o módulo especialista do MobiLEHealth, um ambiente de aprendizagem ubíqua no contexto da Saúde 2.0, que busca adequar-se às características particulares dos usuários, disponibilizando conteúdos adequados às suas necessidades, independentemente do horário, a partir de qualquer local e que direcione os usuários de modo a maximizar seu aprendizado.

O artigo está organizado da seguinte forma: na Seção 2 são apresentados os trabalhos relacionados. Na Seção 3 é abordado o ambiente MobiLEHealth, na Seção 4 temos a avaliação do sistema de recomendação. Por fim, na Seção 5 temos as conclusões e trabalhos futuros.

2. Trabalhos Relacionados

A presente seção apresenta dois trabalhos relacionados à temática. Apesar de serem ferramentas que propõem acompanhamento da saúde, não possuem o acompanhamento pelo especialista e não recomendam conteúdos baseados nos dados da saúde ao usuário alvo.

Hidalgo et al. (2014) desenvolveram o glUCModel, composto por cinco módulos, uma interface de dados, um banco de dados, um sistema de recomendação, um curso e-learning e um modelo de glicose. O sistema de recomendação avalia os dados para a partir deles gerar sugestões para o paciente melhorar os hábitos diários melhorando a qualidade de vida. Essas recomendações são enviadas por e-mail. O e-learning é um espaço onde o paciente pode buscar todas as informações necessárias sobre diabetes. Finalizando, o módulo de modelo de glicose é composto por técnicas computacionais que procuram informar ao paciente como ele deve manter o nível de glicose no sangue estabilizado, de acordo com informações do banco de dados.

Outra ferramenta é uma proposta de framework para monitoramento de diabéticos que foi desenvolvido por Villarreal et al. (2009), baseado em módulos e dividido em duas

partes principais, a do especialista e a do paciente. A parte do especialista é composta por dois módulos, o estatístico, responsável por oferecer ao médico o progresso de cada paciente, e o módulo de sugestão, responsável por sugerir tratamentos de acordo com a estatística dos pacientes. A segunda parte, a do paciente, é composta pelos seguintes módulos: comunicação, dieta e sugestão. O módulo da dieta mostra quais alimentos são mais adequados e quais os proibidos para o paciente, de acordo com os dados analisados e sugeridos pelo módulo de sugestão. O módulo de comunicação é o responsável pelo canal de comunicação entre o médico e o paciente.

Os trabalhos apresentados têm como objetivo melhorar o dia-a-dia do indivíduo diagnosticado com doenças crônicas. Contudo, não foram encontrados trabalhos que tenham um módulo de gerenciamento da saúde com acompanhamento pelo especialista, e que recomende conteúdos baseados nos dados da saúde ao usuário. O corrente trabalho utilizou algumas técnicas, como ontologias, agentes de software e técnicas de recomendação para desenvolver uma ferramenta especialista capaz de melhorar o tratamento do paciente, fornecendo conteúdos relevantes para o mesmo, além de ampliar a interação e o acompanhamento do especialista sobre o paciente. Assim, através do módulo de Intermédio do Especialista, o paciente pode gerenciar os dados da sua saúde e receber conteúdos para uma melhor administração da doença. O especialista, por sua vez, poderá acompanhar a evolução do paciente por meios de gráficos com os dados da saúde do paciente e interagir com o mesmo sem a presença física, por meio de *chat*.

3. MobiLEHealth

O ambiente *Mobile Learning Environment for Health*, denominado “MobiLEHealth” é um ambiente de aprendizagem ubíqua no contexto de Saúde 2.0 destinado a pessoas com doenças crônicas, que é capaz de adequar-se às características particulares dos usuários, no intuito de disponibilizar conteúdos adequados às suas necessidades, visando a obtenção de um maior conhecimento sobre sua doença e, assim, buscar obter uma melhoria na sua qualidade de vida. Este ambiente considera o perfil do usuário, seu contexto atual e suas interações com os conteúdos web e mídias sociais [Mendes Neto et al. 2014].

O MobiLEHealth é composto por três sistemas responsáveis por partes específicas no processo de recomendação: o sistema de monitoramento, onde as ações e as interações são capturadas; o sistema de enriquecimento semântico, criado para analisar os traços digitais do usuário e verificar sua afinidade com um domínio de conhecimento; e o sistema de recomendação personalizada de conteúdo baseada em dados da saúde, encarregado de analisar todas as informações do usuário e gerar uma recomendação adequada a seu perfil. Há também uma rede social semântica, onde o paciente e o especialista podem acessar os conteúdos recomendados, compartilhar informações com os amigos e trocar experiências, e o sistema de intermédio do especialista.

3.1. Sistema de Monitoramento Ubíquo de Usuários

O Sistema de Monitoramento Ubíquo de Usuários (SMUU) monitora e captura todas as interações dos usuários com conteúdos e outros usuários. Isto ocorre de forma automática, sem o apoio dos demais sistemas e sem interferir em nenhum momento na navegação e utilização do ambiente MobiLEHealth.

O mecanismo monitora os acessos aos *links de sites, blogs* e outros conteúdos

disponibilizados pelo processo de recomendação. Também captura as interações realizadas na ferramenta Social, que possibilita a interação com outros usuários, além de informações sobre local do acesso. Além disso, é possível acessar e interagir com conteúdos existentes no YouTube por meio da “YouTube Data - API”. Após a conclusão das interações, os dados são armazenados em uma base de dados que é utilizada para análise do perfil do usuário e o processo de recomendação.

3.2. Sistema de Enriquecimento Semântico de Perfil do Usuário

O Sistema de Enriquecimento Semântico de Perfil do Usuário (SESPU) é encarregado de prover meios para determinar os interesses do usuário relacionados à sua saúde, com base em seus Traços Digitais. Parte das informações obtidas do SMUU passa pelo processamento de enriquecimento semântico, que relaciona estas informações a domínios de conhecimentos modelados em ontologia e gera um perfil semântico do usuário [Mendes Neto et al. 2014].


A integração do SESPu com o MobiLEHealth é realizada de duas formas: através de um serviço que irá disponibilizar métodos que retornam a relação do usuário ou conteúdo com um domínio; e através de agentes computacionais que analisam a base de dados do MobiLEHealth na busca de informações que necessitam ser enriquecidas e acrescentadas ao perfil semântico do usuário. O sistema percorre toda a base de dados a procura por conteúdos que possam ser processados, onde eles serão validados, verificando se o conteúdo pode ser processado pelo Sistema de Enriquecimento Semântico, analisando: tipo do conteúdo, idioma de origem, linguagem de marcação.

O conteúdo é analisado morfolologicamente e sintaticamente, isolando os tipos de palavras, suas flexões, radicais e funções semânticas. Com base nestes dados, uma busca por termos semelhantes nas ontologias de domínio é realizada. A análise sintática e semântica do texto provê robustez e eficácia ao enriquecimento semântico. Ele possibilita incrementar o mecanismo de contextualização do conteúdo com domínio de conhecimento, com isso é possível calcular o Índice de Relação entre Usuário e Conteúdo (IRUC) e o Índice de Relação entre Conteúdo e Domínio (IRCD), que serão utilizados no processo de recomendação [Mendes Neto et al. 2014].

3.3. Sistema de Recomendação Personalizada de Conteúdo Baseada em Dados da Saúde

O Sistema de Recomendação Personalizada de Conteúdo Baseada em Dados da Saúde (SRBDS) analisa as informações do perfil do usuário em suas etapas de processamento, inicialmente analisando os conteúdos de mesmo domínio do usuário, utilizando seu Índice de Semelhança de Conteúdo para a avaliação, e criando uma lista baseada em conteúdos. Em paralelo, gera uma lista com possíveis recomendações, baseando-se em escolhas e avaliações de usuários com perfis semelhantes, utilizando o resultado do cálculo da afinidade entre dois usuários, utilizando em seus cálculos o IRUC [Costa 2015]. Na Figura 1 é ilustrada a arquitetura do SRBDS.

Figura 1. Arquitetura do Sistema de Recomendação Baseada em Dados da Saúde




Essas listas passam por um novo processamento, onde será gerada uma nova lista baseada no índice de recomendação ubíqua, que representa o quanto um conteúdo é recomendado para o contexto atual do usuário, analisando local, frequência de acesso entre outros aspectos. Posteriormente há a combinação dessas listas e avaliação dos seus itens, gerando uma lista híbrida contendo os conteúdos com melhor índice de avaliação [Costa 2015].

Por fim, o SRBDS, com a utilização de um algoritmo genético, analisa todas as combinações de recomendação possíveis, escolhendo aquela onde os conteúdos finais não disputem pelas mesmas características do usuário, permitindo que a recomendação final se adeque melhor ao usuário alvo [Mendes Neto et al. 2014].

3.4. Rede Social Semântica

A Rede Social Semântica oferece um ambiente onde o paciente com diabetes possa realizar pesquisas a respeito da sua saúde, acessar conteúdos recomendados para si, compartilhar conteúdos com seus amigos e trocar experiências com eles. Ela mantém a característica do MobiLEHealth de ser multiplataforma, podendo ser acessada de qualquer dispositivo móvel ou computador, desde que o dispositivo tenha acesso à internet e possua uma aplicação para navegar na Web [Silva 2017]. Na Figura 2 é demonstrada a tela da Rede Social Semântica.

Figura 2. Tela de Rede Social Semântica




O usuário pode gerenciar suas interações sociais dentro do sistema. Assim, pode buscar amigos, receber a recomendação de amizades, ver quais são os seus amigos e trocar informações com eles, através de mensagens dentro da própria ferramenta. Todas as informações coletadas no ambiente da Rede Social Semântica são enviadas a um repositório de dados. Neste repositório há uma ontologia de classificação de usuário, que oferece informações para realizar a classificação dos pacientes. Através desta tecnologia, é possível inferir relações entre os usuários da rede social. Essas relações são inferidas levando em consideração alguns aspectos entre os usuários: Tipo de diabetes, tempo que o paciente possui diabetes, idade do paciente, gênero, afinidade com tecnologia e quantidades de amigos em comum. A partir destes aspectos, a ontologia desenvolvida os analisa e, ao identificar as informações semelhantes entre dois ou mais usuários, faz a recomendação um ao outro.

3.5. Sistema de Intermédio do Especialista

O Sistema de Intermédio do Especialista também provê o Módulo de Gerenciamento da Saúde e o Sistema de Inferência da quantidade de unidades de Insulina necessária para o usuário diabético. O Módulo de Gerenciamento da Saúde e o Sistema de Inferência da quantidade de unidades de Insulina necessária para o usuários diabéticos. O módulo de gerenciamento da saúde tem o acompanhamento dos exames mais exigidos pelos especialistas que acompanham pacientes com doenças crônicas, em especial a Diabetes. Como exemplo de exames: Fundo de Olho, Glicemia de Jejum, Hemoglobina Glicada, Microalbuminúria, Colesterol Total, Pressão Arterial, IMC, Alergia, HDL, LDL e Triglicerídeos. Alguns desses valores podem ser obtidos através de sensores que se comunicam com a aplicação por *bluetooth* e também podem ser inseridos de forma manual. O paciente faz a inserção desses dados e o especialista pode acompanhar a evolução do paciente por meio de gráficos com os resultados dos exames por períodos. Na Figura 3 é apresentada a

ilustração dos gráficos.

Figura 3. Tela Escolha do Paciente



Neste sistema também é possível calcular a quantidade de insulina necessária ao paciente com diabetes, levando em consideração o peso, situação alimentar e o nível da glicose do paciente no momento da insulinização. Todo esse procedimento é monitorado pelo especialista. Esse cálculo é realizado com ajuda de uma ontologia de domínio e um sistema multiagente que monitora a base de dados e manipula a ontologia. Na Figura 4 é apresentado o processo para obtenção da quantidade necessária de insulina que o paciente necessita no Módulo de Gerenciamento da Saúde.

Figura 4. Processo de obtenção da quantidade de insulina

Minha Saúde		
Peso 80	Peso 80	Quantidade de Insulina: 3 unidades
Valor da Glicose 101	Valor da Glicose 101	
Situação Alimentar Dieta	Situação Alimentar Jejum	
Jejum	CALCULAR LIMPAR	
		CALCULAR LIMPAR

Para obter a quantidade de insulina pelo Módulo de Gerenciamento da Saúde, são

necessárias as informações de Peso, que já vem do banco de dados, Valor da Glicose, que pode ser inserido a partir de um seletor, e também a Situação Alimentar (Dieta ou Jejum). Com os campos preenchidos, o próximo passo é clicar em “CALCULAR”, logo em seguida o resultado do cálculo da quantidade de insulina é apresentado ao usuário.

Na etapa de recomendação dos conteúdos, o Sistema de Intermédio permite que os conteúdos recomendados sejam analisados pelo profissional antes de serem de fato enviados ao paciente. Assim, o especialista pode validar ou não o conteúdo, sendo que o conteúdo será enviado somente se for validado pelo médico.

4. Validação do SRBDS

Na primeira etapa da validação da aplicação, foi definida a Diabetes como domínio da aplicação. A escolha da Diabetes se deu por se tratar uma doença crônica que atinge uma parcela da população, e também pelo fato de que a falta de informação dificulta a convivência e tratamento dessa doença.

Na segunda etapa, foram selecionados 50 conteúdos do domínio. Essa seleção foi feita pela internet e de forma manual, de modo a garantir que o conteúdo era fortemente relacionado ao domínio, além da sua qualidade e confiabilidade.

Foram criados dados fictícios utilizando nomes de pessoas, nomes de cidades reais, etc. Os perfis de usuários foram criados para mostrar as características desejadas quanto à idade, sexo e os dados da saúde. Através dos dados do Instituto Brasileiro de Geografia e Estatística (IBGE), definiu-se as distribuições das características e foram criados perfis de usuários do sexo masculino, variando de 25 a 40 anos de idade. Na Tabela 1 mostra as descrições dos dados dos usuários criados.

Tabela 1. Usuários fictícios com os dados da Saúde

Usuário	Alergia (tipo)	Altura (cm)	Peso (Kg)	Colesterol (mg/dl)	IMC (Kg/m ²)	Insulina (UI)
User1	10	140	50	100	25,5	0
User2	10	150	55	110	24,5	2
User3	20	160	60	120	23,4	4
User4	20	170	65	130	21,6	6
User5	30	180	70	140	20,8	8
User6	30	190	75	150	20,0	10
User7	40	185	80	160	23,4	12
User8	40	175	85	170	27,8	14
User9	50	190	90	180	24,9	16
User10	50	190	95	190	26,3	18

Os dados das relações e históricos foram inseridos através de um gerador de contextos, onde ocorre a simulação de ações que disparam gatilhos de contexto que geram históricos e relações para os usuários, conteúdos e locais, no intuito de simular todas as possibilidades de interação entre usuários, conteúdos e locais.

Sistemas de recomendação, normalmente, são avaliados sob a satisfação do utilizador, pois, tipicamente, há a preocupação em perceber o grau de aceitação das recomendações, ou seja, quantificar o número de aceitação ou rejeição dos utilizadores sobre os itens recomendados [Herlocker et al. 2004]. A qualidade de um sistema de recomendação pode ser avaliada comparando as recomendações a um conjunto de testes

conhecidos do utilizador. Esta avaliação é efetuada recorrendo a um conjunto de métricas conhecidas como *predictive accuracy metrics* [Herlocker et al. 2004].

Assim, foi possível obter o número de ocorrências enquadradas nas categorias vinculadas à aceitação e rejeição, utilizando Verdadeiro-Positivo (VP), referentes a conteúdos recomendados e “preferidos” pelo usuário, e Falso-Positivo (FP), considerados como recomendados e “não preferidos”. Neste sentido, na simulação, foi utilizada a aplicação da métrica *Precision*, que tem a tarefa de medir a probabilidade de um item recomendado ser relevante [Herlocker et al. 2004]. A referida métrica é calculada por meio da Equação 1:

$$Precision = \frac{n^{\circ}deVP}{n^{\circ}deVP + n^{\circ}deFP} \quad (1)$$

Baseado nas características do algoritmo, a *Precision* foi escolhida, pois atende ao que se propõe o algoritmo de recomendação. Como pode ser visto na Equação 1, não há possibilidade de fazer análise de conteúdos considerados Negativos (Falso-Negativo ou Verdadeiro-Negativo), assim como nosso algoritmo não tem conteúdos negativos. Diante disso, justifica-se a escolha da métrica *Precision*, que não utiliza conteúdos Negativos, descartando a *Recall*, *False Positive Rate* e a *F-measure* (F1), que são encontradas em [Herlocker et al. 2004].

A análise dos resultado da execução do algoritmo, com os dados descritos, por meio da métrica *Precisions* está apresentada na Tabela 2.

Tabela 2. Resultado da simulação do algoritmo RBDS

Número de Recomendações	Quantidade de Conteúdos	Verdadeiros Positivos (VP)	Falsos Positivos (FP)
50	50	2306	194

Feito isso, aplicamos a métrica *Precision*:

$$Precision = \frac{n^{\circ}deVP}{n^{\circ}deVP + n^{\circ}deFP} = \frac{2306}{2306 + 194} = 0.9224(92, 24\%)$$

Apesar de os experimentos terem sido realizados em uma base com dados simulados, por meio da métrica *Precision*, apresentou um satisfatório resultado. Resultado esse superior a 90%. Dito isto, a melhora deste percentual pode ser obtida se aplicado em um ambiente com um maior números de usuários e relações validados com usuários reais, aplicando outras métricas para garantir a qualidade do algoritmo de recomendação.

5. Considerações Finais

Este trabalho apresenta um ambiente capaz de integrar mecanismos de monitoramento da saúde, análise semântica, recomendação e intervenção do especialista, interagindo entre si. Utiliza o contexto da aprendizagem ubíqua e da aprendizagem informal, monitora seus usuários através de suas interações sociais, estabelecendo uma relação de interesse relacionada à saúde deste de forma implícita e automatizada através de relações semânticas com

domínios de conhecimento. Por fim, combinando diferentes técnicas de recomendação e um algoritmo genético, permite recomendar conteúdos relevantes ao portador de doença crônica. Foi visto nos resultados que o sistema de recomendação apresenta um ótimo nível de realização de suas tarefas de forma adequada, proporcionando resultados satisfatórios. Possibilita também observar que a integração dos mecanismos tende a melhorar a qualidade da recomendação final, tornando o sistema mais adequado a cada usuário alvo.

Como trabalhos futuros, será realizado o estudo de caso com pessoas portadoras de doenças crônicas, a priori, usuários com Diabetes. Nessa ocasião, os usuários utilizarão a ferramenta para avaliar a utilidade e facilidade de uso da ferramenta, bem como o preenchimento de dados de sua saúde, além de verificar a relevância do conteúdo recomendado. Também será realizada a validação real com os usuários diabéticos, podem-se utilizar outras métricas que forneçam resultados satisfatórios, comprovando, desta forma, que os resultados obtidos nas simulações foram condizentes ao que se propôs neste trabalho.

Referências

- Costa, A. (2015). *Mecanismo de Recomendação Personalizada de Conteúdos para apoiar um Ambiente de Aprendizagem Informal no contexto da Saúde*. 2015. 92 f. PhD thesis, Dissertação (Mestrado)-Curso de Pós-graduação em Ciência da Computação
- Herlocker, J. L., Konstan, J. A., Terveen, L. G., and Riedl, J. T. (2004). Evaluating collaborative filtering recommender systems. *ACM Transactions on Information Systems (TOIS)*, 22(1):5–53.
- Hidalgo, J. I., Maqueda, E., Risco-Martín, J. L., Cuesta-Infante, A., Colmenar, J. M., and Nobel, J. (2014). glucmodel: A monitoring and modeling system for chronic diseases applied to diabetes. *Journal of biomedical informatics*, 48:183–192.
- Mendes Neto, F. M., da Costa, A. A. L., Sombra, E. L., Moreira, J. D. C., de Medeiros Valentim, R. A., Zapater, J. J. S., do Nascimento, R. P. C., and Flores, C. D. (2014). Content’s personalized recommendation for implementing ubiquitous learning in health 2.0. *IEEE Latin America Transactions*, 12(8):1515–1522.
- Silva, B. E. C. R. d. (2017). Desenvolvimento de uma rede social semântica e um sistema de intermédio do especialista para pacientes diabéticos.
- Van De Belt, T. H., Engelen, L. J., Berben, S. A., and Schoonhoven, L. (2010). Definition of health 2.0 and medicine 2.0: a systematic review. *Journal of medical Internet research*, 12(2).
- Villarreal, V., Laguna, J., López, S., Fontecha, J., Fuentes, C., Hervás, R., De Ipiña, D. L., and Bravo, J. (2009). A proposal for mobile diabetes self-control: towards a patient monitoring framework. In *International Work-Conference on Artificial Neural Networks*, pages 870–877. Springer.
- Zwar, N., Harris, M., Griffiths, R., Roland, M., Dennis, S., Powell Davies, G., Hasan, I., et al. (2017). A systematic review of chronic disease management.