



**UNIVERSIDADE FEDERAL RURAL DO SEMIÁRIDO
UNIVERSIDADE DO ESTADO DO RIO GRANDE DO NORTE
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA
COMPUTAÇÃO**



ALISSON ALAN LIMA DA COSTA

**MECANISMO DE RECOMENDAÇÃO PERSONALIZADA DE
CONTEÚDOS PARA APOIAR UM AMBIENTE DE
APRENDIZAGEM INFORMAL NO CONTEXTO DA SAÚDE**

MOSSORÓ – RN

2015

ALISSON ALAN LIMA DA COSTA

**MECANISMO DE RECOMENDAÇÃO PERSONALIZADA DE
CONTEÚDOS PARA APOIAR UM AMBIENTE DE
APRENDIZAGEM INFORMAL NO CONTEXTO DA SAÚDE**

Dissertação apresentada ao Programa de Pós-graduação em Ciência da Computação – associação ampla entre a Universidade do Estado do Rio Grande do Norte e a Universidade Federal Rural do Semiárido, para a obtenção do título de Mestre em Ciência da Computação.

Orientador: Prof. Dr. Francisco Milton Mendes Neto – UFERSA.

Coorientador: Prof. Dr. Ricardo Alexandro de Medeiros Valentim – UFRN.

MOSSORÓ – RN

2015

Catálogo na Fonte

Catálogo de Publicação na Fonte. UFERSA - BIBLIOTECA CENTRAL ORLANDO TEIXEIRA - CAMPUS MOSSORÓ

Costa, Alisson Alan Lima da.

Mecanismo de recomendação personalizada de conteúdos para apoiar um ambiente de aprendizagem informal no contexto da saúde / Alisson Alan Lima da Costa. - Mossoró, 2015.

91f. il.

1. Algoritmo genético. 2. Recomendação personalizada de conteúdo. 3. Aprendizagem Informal. 4. Saúde 2.0. 5. Qualidade de vida - Doença crônica. I. Título

RN/UFERSAUFERSA/BCOT-387
C837m

CDD 006.31

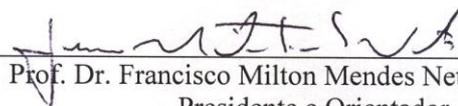
ALISSON ALAN LIMA DA COSTA

**MECANISMO DE RECOMENDAÇÃO PERSONALIZADA DE
CONTEÚDOS PARA APOIAR UM AMBIENTE DE
APRENDIZAGEM INFORMAL NO CONTEXTO DA SAÚDE**

Dissertação apresentada ao Programa de Pós-graduação em Ciência da Computação – associação ampla entre a Universidade do Estado do Rio Grande do Norte e a Universidade Federal Rural do Semiárido, para a obtenção do título de Mestre em Ciência da Computação.

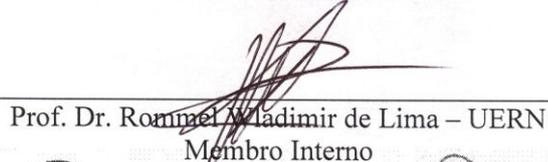
APROVADA EM: 20/03/2015.

BANCA EXAMINADORA



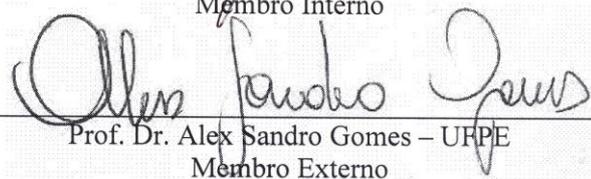
Prof. Dr. Francisco Milton Mendes Neto – UFRSA

Presidente e Orientador



Prof. Dr. Rommel Vladimir de Lima – UERN

Membro Interno



Prof. Dr. Alex Sandro Gomes – UFPE

Membro Externo

DEDICATÓRIA

Dedico este trabalho ao meu tio Valter Viana (*in memoriam*) que me incentivou bastante no início desta jornada.

Decido este trabalho, de forma especial a Deus, aos meus pais Costa Júnior e Maria de Fátima, e à minha esposa Iliane Sandrelli, pelo amor, carinho, apoio e compreensão.

AGRADECIMENTOS

Primeiramente agradeço a Deus, pela inspiração nos momentos de desenvolvimento deste trabalho, pelo amparo e pela força na superação dos desafios permitindo-me obter mais uma conquista na minha trajetória.

Aos meus pais, Costa Júnior e Maria de Fátima, pela retaguarda necessária e indispensável que oferecem sempre, com amor sincero e de dimensão indescritível. A expressão “muito obrigado” não consegue traduzir o que fez por todos os filhos e em particular por mim. Tudo o que sou, devo a eles.

À minha esposa, Iliane Sandrelli, pelo imensurável amor, carinho, compreensão, confiança e o enorme apoio durante o desenvolvimento deste trabalho.

Ao meu irmão Costa Neto, à minha cunhada Andreza Rafaela, e aos meus sobrinhos gêmeos Lucas Gabriel e Luís Gustavo, pelo carinho, amizade e momentos de descontração.

Ao meu irmão Alan Glaydson, à minha cunhada Dayse Duarte e aos meus sobrinhos Davi Natanael e Maria Laura, pelo carinho.

Ao meu orientador e amigo, Francisco Milton Mendes Neto, pela colaboração, confiança, apoio, amizade e compreensão. Sempre dispondo seu tempo e conhecimento para me orientar a trilhar pelo caminho certo. Também agradeço pelas palavras de motivação e incentivo, fundamentais para superar as dificuldades e obter sucesso na realização deste trabalho.

Ao meu coorientador e amigo, Ricardo Alexsandro de Medeiros Valentim, pela colaboração, apoio e sugestões fornecidas para o desenvolvimento deste trabalho.

Aos meus sogros Hélio Veríssimo e Maria de Lourdes pelo incentivo e apoio.

Aos meus familiares, parentes e amigos que me incentivaram no decorrer desses dois anos de mestrado.

À Universidade Federal Rural do Semi-Árido (UFERSA) e Universidade do Estado do Rio Grande do Norte (UERN), pela união de forças e competências em prol da criação do Programa de Pós-Graduação em Ciência da Computação (PPGCC), e pela oportunidade de realização desse curso.

Aos professores do mestrado, pela dedicação, experiência e ensinamentos passados.

Aos amigos da SUTIC e parceiros no mestrado Jonathan e Enio pelo compartilhamento de conhecimentos nas diversas tarefas durante o período de disciplinas do mestrado e disposição nas contribuições para a realização deste trabalho.

A todos os amigos da SUTIC, companheiros de trabalho e que na medida do possível se dispuseram a compartilhar suas experiências, conhecimentos e contribuíram de forma direta ou indireta neste trabalho.

Aos colegas do LES, pelo compartilhamento de conhecimentos e cooperação.

À coordenação e a secretaria do Mestrado da UFERSA e da UERN, pela atenção, colaboração prestada no decorrer destes dois anos de mestrado.

“A mente que se abre a uma nova idéia jamais voltará ao seu tamanho original”.

Albert Einstein

RESUMO

Pessoas com doenças crônicas sofrem com limitações impostas por sua condição de saúde e aprender mais sobre a doença ajuda na melhoria de sua qualidade de vida. O uso em massa dos dispositivos móveis e o advento das ferramentas da Web 2.0 contribuíram para o surgimento do conceito de Saúde 2.0, que visa estimular o cidadão a ser ativo e responsável pela sua saúde e pelos cuidados relativos a ela, através de iniciativas mediadas pelas tecnologias da Web 2.0 para a construção coletiva do conhecimento. No entanto, fornecer o conhecimento correto (contextualizado), no momento certo, não é tarefa trivial, devido a grande diversidade de conteúdos e perfis existentes. A solução para este problema é disponibilizar meios de promover a aprendizagem informal através da recomendação personalizada de conteúdo aos usuários, indicando conteúdos relevantes relacionados à sua condição de saúde. Desta forma, conhecendo-se o perfil do usuário e aplicando-se mecanismos de recomendação de conteúdo com o uso de algoritmo genético, é possível identificar a semelhança entre usuários e conteúdos e recomendar conteúdos de seu interesse. Este trabalho propõe um sistema de recomendação personalizada de conteúdos, que contempla a união de diferentes técnicas de recomendação de modo que seja possível alcançar a eficácia na recomendação dos conteúdos corretos para as pessoas portadoras de doenças crônicas buscando favorecer a aprendizagem informal em saúde.

Palavras-Chave: Recomendação Personalizada de Conteúdo, Aprendizagem Informal, Saúde 2.0, Algoritmo Genético.

ABSTRACT

People with chronic diseases suffer from limitations imposed by their health condition and learn more about the disease helps in improving their quality of life. The mass use of mobile devices and the advent of Web 2.0 tools contributed for the emergence of the concept of Health 2.0, which aims to stimulate the citizens to be active and responsible for her health and for her cautions, through initiatives by Web 2.0 technologies mediated for the collective construction of knowledge. However, provide the right knowledge (contextualized), at the right time, it's not trivial task, given the great diversity of content and existing profiles. The solution to this problem is to provide means to promote informal learning through personalized content recommendation to the users, indicating relevant content related to their health condition. Thus, knowing the user profile and applying recommendation engines of content using genetic algorithm is possible to discover the similarity among users and the contents and recommend content of their interest. Therefore, this work proposes a system for personalized content recommendation, which includes the union of different techniques of recommendation so that it will be possible to achieve the effectiveness on recommendation of the correct content for persons with chronic diseases in order to promote informal learning in health.

Keywords: Content Personalized Recommendation, Informal Learning, Health 2.0, Genetic Algorithms.

LISTA DE TABELAS

Tabela 1 – Características do SR Modelado.....	41
Tabela 2 – Resultado da Lista Híbrida Ubíqua.....	73
Tabela 3 – Recomendação Conjunta (cromossomo melhor avaliado pela função <i>fitness</i>)	73
Tabela 4 – Distribuição do atributo idade	75
Tabela 5 – Distribuição do atributo sexo.....	75
Tabela 6 – Distribuição dos segmentos	75
Tabela 7 – Distribuição das relações entre usuários.....	76
Tabela 8 – Distribuição das relações entre usuário e conteúdo.....	76
Tabela 9 – Distribuição das relações entre usuário e local.....	76
Tabela 10 – Distribuição das relações entre conteúdo e local.....	76
Tabela 11 – Resultado da simulação com contexto neutro e usuário de perfil definido.	78
Tabela 12 – Resultado da simulação com contexto definido e usuário de perfil neutro.	78

LISTA DE FIGURAS

Figura 1 – Estrutura Básica de um Algoritmo Genético	29
Figura 2 – Filtragem Híbrida	37
Figura 3 – Modelo Arquitetural do MobiLEHealth	44
Figura 4 – Diagrama de Componentes do MobiLEHealth	46
Figura 5 – Arquitetura do Sistema de Recomendação Personalizada de Conteúdo	49
Figura 6 – Lista de Conteúdos Resultantes da Recomendação Híbrida Ubíqua	68
Figura 7 – Recomendação Conjunta dos 03 melhores conteúdos considerando o IRH	68
Figura 8 – Código-fonte da Avaliação da População e da Função Fitness	70

LISTA DE ABREVIATURAS E SIGLAS

AG	Algoritmo Genético;
API	<i>Application Programming Interface;</i>
DM	Diabetes Mellitus;
ELA	Esclerose Lateral Amiotrófica;
FP	Falso-Positivo;
IBGE	Instituto Brasileiro de Geografia e Estatística;
IDE	<i>Integrated Development Environment;</i>
ITU	<i>International Telecommunication Union;</i>
LES	Laboratório de Engenharia de Software;
LORSys	<i>Learning Object Recommender System;</i>
MobiLEHealth	<i>Mobile Learning Environment for Health;</i>
MOODLE	<i>Modular Object-Oriented Dynamic Learning Environment;</i>
OAs	Objetos de Aprendizagem;
PHR	<i>Personal Health Records;</i>
PLN	Processamento de Linguagem Natural;
SCORM	<i>Sharable Content Object Reference Model;</i>
SCROLL	<i>System for Capturing and Reminding of Learning Log;</i>
SR	Sistema de Recomendação;
SRBC	Sistema de Recomendação Baseada em Conteúdo;
SRC	Sistema de Recomendação Colaborativa;
SRH	Sistema de Recomendação Híbrida;

TD	Traço Digital;
TIC	Tecnologias da Informação e Comunicação;
UFERSA	Universidade Federal Rural do Semi-Árido;
U-Health	<i>Ubiquitous Health</i> ;
VP	Verdadeiro-Positivo.

SUMÁRIO

1 INTRODUÇÃO	15
1.1 CONTEXTUALIZAÇÃO E MOTIVAÇÃO	15
1.2 PROBLEMÁTICA.....	18
1.3 HIPÓTESE DE PESQUISA	19
1.4 OBJETIVOS	19
1.4.1 Objetivo Geral	19
1.4.2 Objetivos Específicos	20
1.5 MÉTODO DE PESQUISA.....	21
1.6 ORGANIZAÇÃO DA DISSERTAÇÃO	23
2 REFERENCIAL TEÓRICO	25
2.1 APRENDIZAGEM INFORMAL	25
2.2 AMBIENTES SENSÍVEIS AO CONTEXTO	26
2.3 SAÚDE 2.0.....	28
2.4 ALGORITMO GENÉTICO	28
2.5 ENRIQUECIMENTO SEMÂNTICO	30
2.6 SISTEMAS DE RECOMENDAÇÃO.....	32
2.6.1 Tipos de Sistemas de Recomendação.....	33
2.6.1.1 Sistema de Recomendação Baseada em Conteúdo	33
2.6.1.2 Sistema de Recomendação Colaborativa	35
2.6.1.3 Sistema de Recomendação Híbrida.....	36
2.6.2 Estratégias de Recomendação	37
3 TRABALHOS RELACIONADOS	39
4 MOBILEHEALTH.....	43
4.1 ARQUITETURA	43
4.2 INTEGRAÇÃO DO PRC COM O SAC.....	47
5 SISTEMA DE RECOMENDAÇÃO PERSONALIZADA DE CONTEÚDOS	49
5.1 CAMADAS DA ARQUITETURA DO SRPC.....	50
5.1.1 Recomendação Colaborativa.....	51
5.1.1.1 Lista de Colaboradores.....	51

5.1.2 Recomendação Colaborativa Ponderada	54
5.1.2.1 Lista Colaborativa Ponderada	55
5.1.2.2 Índice de Semelhança Semântica entre Usuários	56
5.1.3 Recomendação Baseada em Conteúdo	57
5.1.3.1 Índice de Semelhança entre Usuário e Conteúdo	59
5.1.4 Recomendação Ubíqua	61
5.1.5 Recomendação Híbrida Ubíqua	64
5.1.5.1 Ajustes nos pesos das recomendações	66
5.1.6 Recomendação Conjunta	67
5.2 FUNÇÃO <i>FITNESS</i>	69
5.3 REPRESENTAÇÃO DO CROMOSSOMO	70
5.4 MODELO DO AG UTILIZADO	70
5.5 TECNOLOGIAS UTILIZADAS	71
6 VALIDAÇÃO DO SRPC	73
6.1 ESTRUTURAÇÃO DOS EXPERIMENTOS	73
6.2 SIMULAÇÃO	74
6.3 ANÁLISE DOS RESULTADOS DA SIMULAÇÃO	77
7 CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS	80
7.1 TRABALHOS FUTUROS	80
REFERÊNCIAS	82
APÊNDICE A – LISTA DE CONTEÚDOS DO SRPC	87

1 INTRODUÇÃO

Este trabalho é parte integrante de um projeto desenvolvido pelo Grupo de Pesquisa de Engenharia de Software em Saúde 2.0 do Laboratório de Engenharia de Software – LES/UFERSA. Tal projeto tem como objetivo a modelagem e o desenvolvimento de um sistema de recomendação de conteúdo de saúde vinculado a um ambiente denominado MobiLEHealth (*Mobile Learning Environment for Health*), para prover aprendizagem informal levando em consideração as características relevantes do contexto dos usuários.

A contribuição científica deste trabalho de dissertação é a construção de um sistema de recomendação personalizada de conteúdo, que considere as características colaborativas, baseadas em conteúdo e ubíquas, e que, aplicando o enriquecimento semântico do usuário e do conteúdo e algoritmo genético, possa fornecer conteúdos com base no perfil do usuário e em suas escolhas.

1.1 CONTEXTUALIZAÇÃO E MOTIVAÇÃO

As doenças crônicas representam um alto percentual de mortalidade no mundo. Contudo, boa parte delas pode ser prevenida e controlada, promovendo uma melhor qualidade de vida. Para tanto, é preciso que o indivíduo conheça a doença e, em seguida, faça o tratamento recomendado (com medicamentos, dietas, hábitos saudáveis, mudanças no estilo de vida e prática de exercícios) resultando desta forma em tornar-se ativo e responsável pelos cuidados relativos à sua saúde.

É consenso que o conhecimento acerca da sua condição de saúde traz, aos portadores de doenças crônicas, a capacidade de conviver melhor com sua doença, a motivação para realizar o tratamento e o suporte para convivência social. Esse conhecimento pode ser obtido através de profissionais da saúde como também através da aprendizagem informal.

Segundo Cross (2012), a aprendizagem informal pode ser entendida como a maneira não oficial, não programada, de improviso, onde a maioria das pessoas aprende a fazer o seu trabalho. Como exemplo, pode-se citar o ato de andar de bicicleta: o piloto escolhe o destino e a rota. O ciclista pode fazer um desvio na observação de um momento para admirar a paisagem ou ajudar um companheiro. Com base no exposto, podemos dizer que a

aprendizagem informal pode acontecer via troca de experiências com outros portadores da doença, ou através da internet, redes sociais, etc.

Diante deste cenário, o conceito de Saúde 2.0 torna-se um fator motivador, pois une aprendizagem informal ao uso de tecnologias e ferramentas da Web 2.0 (redes sociais, registros pessoais de saúde, blogs, vídeos, serviços, etc.) como forma de capturar, através da experiência do usuário, informações referentes à saúde e, pela combinação desses dados e informações, fornecer cuidados e conteúdos personalizados (HUGHES; JOSHI; WAREHAM, 2008).

Contudo, essa aprendizagem precisa ser direcionada a cada usuário, conforme suas necessidades, interesses e limitações, e os mecanismos de recomendação de conteúdo podem contribuir nesse processo, analisando o perfil do usuário e extraindo informações para recomendar conteúdos que mais se adequem a ele. Segundo Barcellos et al. (2007), mecanismos de recomendação de conteúdo têm como objetivo auxiliar os usuários no processo de busca na Web, indicando informações e conteúdos para o usuário com base no seu perfil.

Desta forma, a fim de desenvolver um ambiente de aprendizagem no contexto da Saúde 2.0 que melhor atenda às necessidades dos usuários e que busque o aprimoramento do processo de aprendizagem, é fundamental considerar os aspectos relacionados a situações reais do cotidiano do usuário, transcendendo as barreiras do formalismo educacional. A aprendizagem ubíqua pode auxiliar a educação informal fornecendo um meio favorável para autoaprendizagem e interações do usuário com o ambiente real, através de experiências obtidas pelas mídias sociais. Conforme Saccol, Schlemmer and Barbosa (2010), a aprendizagem ubíqua é definida como a utilização de dispositivos móveis, tecnologias de comunicação móvel sem fio, sensores e mecanismo de localização, com o objetivo de auxiliar o processo educacional, levando em consideração características particulares do indivíduo.

Com base nestas prerrogativas o MobiLEHealth, através do processamento do mecanismo de recomendação, tem como propósito possibilitar o acesso, a visualização e o fornecimento de conteúdo independentemente do horário, a partir de qualquer localidade e que direcione os usuários de modo a maximizar seu aprendizado. Além disso, este ambiente pode beneficiar-se da mobilidade do usuário para fornecer oportunidades de aprendizagem presentes no ambiente real. Ele pode também obter informações de experiências reais, através do meio digital, providas pelas redes sociais, a fim de favorecer a autoaprendizagem e interações entre os usuários. Desta forma, o usuário terá acesso a conteúdos sobre sua saúde por meio da aprendizagem informal, uma vez que esta faz parte da vida cotidiana do usuário.

De um modo geral, o MobiLEHealth trata-se de um ambiente de aprendizagem ubíqua capaz de capturar os diversos conteúdos acessados ou gerados pelos usuários, através de experiências cotidianas, para identificar seu contexto e auxiliar no processo de enriquecimento semântico, do inglês *semantic augmentation*, que tem como tarefa anexar conceitos semânticos a partes específicas de um texto, provendo uma estrutura para interpretação automática de seu significado e possibilitando estender a compreensão do domínio de um determinado Traço Digital (TD) (THAKKER; DESPOTAKIS; DIMITROVA, 2012). Deste modo, é possível aperfeiçoar o processo de recomendação de conteúdos de saúde e, conseqüentemente, a personalização do ambiente.

Neste contexto, o mecanismo de recomendação desenvolvido neste trabalho foi direcionado a dois tipos de doenças crônicas: (i) Diabetes Mellitus (DM), que é considerada uma questão de saúde pública mundial, devido ao número de pessoas acometidas por esta doença ser considerado alto (WHO, 2013) e (ii) Esclerose Lateral Amiotrófica, mais conhecida pelo acrônimo ELA. Segundo Yamanaka et al. (2008) e Eisen (2009), a ELA é uma doença neurodegenerativa, caracterizada por uma progressiva e fatal perda de neurônios motores do córtex cerebral, tronco encefálico e medula espinhal, contudo as atividades intelectual e cognitiva continuam íntegras.

Através do estudo destas doenças crônicas surgiu a motivação para a realização deste trabalho. Com base nas pesquisas, foi identificado que há 10 (dez) anos atrás já vinha ocorrendo, no mundo, um aumento no índice de mortalidade de pessoas portadoras de doenças crônicas (WORLD HEALTH ORGANIZATION, 2005). Somente no Brasil, segundo estimativas do Instituto Brasileiro de Geografia e Estatística (IBGE), 29,9% da população reportou ser portadora de pelo menos uma doença crônica. Esse percentual chega a 75% quando considerado apenas os idosos (IBGE, 2009). No entanto, boa parte das doenças crônicas pode ser prevenida, controlada e promovida uma melhor qualidade de vida aos seus portadores. O primeiro passo é conhecer a doença e, em seguida, realizar o tratamento recomendado, que inclui medicamentos, dietas, hábitos saudáveis, mudanças no estilo de vida e prática de exercícios.

No entanto, a falta de adesão ao tratamento é alta, estando associada a fatores como: relação médico-paciente, educação em saúde, participação dos órgãos de saúde, formação do profissional da saúde e à própria doença. É consenso que um fator primordial é a educação em saúde, pois é necessário ao paciente conhecer a doença, aceitar e assumir a responsabilidade de proteção à sua saúde, tornando-se ativo no planejamento e execução de seu tratamento.

Todos esses fatores citados contribuem para o controle e para a melhoria na qualidade de vida dos pacientes que possuem doenças crônicas (LUSTOSA; ALCAIRES; COSTA, 2011).

A tecnologia surge como uma forte aliada nesse sentido, pois atualmente pode ser observada uma popularização das Tecnologias da Informação e Comunicação (TIC), principalmente das tecnologias móveis. Por exemplo, segundo o Relatório Global de 2013, da *International Telecommunication Union* (ITU), há 6,8 bilhões de celulares habilitados em todo o mundo e aproximadamente 2,1 bilhões com acesso à internet banda larga móvel (SANOU, 2013).

O uso de tecnologia para beneficiar a área de saúde vem sendo estudado há algum tempo, tanto que deste estudo surgiram diversos termos, como:

- **E-Health:** Que consiste no uso da internet ou outros meios eletrônicos de compartilhamento de dados e de serviços relacionados à saúde (DELLA MEA, 2001);
- **Telemedicina:** Que se utiliza das TICs para prestar cuidados clínicos à distância (DELLA MEA, 2001);
- **M-Health:** Abreviação de *Mobile Health*, usado para designar a prática da medicina e da saúde pública apoiada por dispositivos móveis (ISTEPANIAN; LAXMINARAYAN; PATTICHIS, 2006);
- **U-Health:** Abreviação de *Ubiquitous Health*, que se refere a serviços de saúde e informação incorporados ao dia-a-dia do paciente no conceito de *anywhere and anytime* (MOHAMMED; FIAIDHI, 2010); e
- **Health 2.0:** O qual define que o cidadão deve ser ativo e responsável pela sua saúde e pelos cuidados relativos a ela. Para isso, usa tecnologias e ferramentas da Web 2.0 (redes sociais, registros pessoais de saúde, *blogs*, vídeos, serviços, etc.) como forma de capturar, através da experiência do usuário, informações referentes à saúde e, pela combinação desses dados e informações, fornecer cuidados e conteúdos personalizados (HUGHES; JOSHI; WAREHAM, 2008).

1.2 PROBLEMÁTICA

Diante do exposto na seção anterior, surge o desafio: Como fornecer o conhecimento corretamente contextualizado e no momento certo? Considera-se um desafio por não ser uma tarefa fácil, devido à grande diversidade de conteúdos e perfis de usuários existentes. Outro problema a ser enfrentado é como realizar a recomendação de conteúdos personalizados de forma correta, pois muitos dos sistemas de recomendação existentes não utilizam todas as técnicas de filtragem de seleção de conteúdos necessárias para o fornecimento de conteúdos adequados ao perfil dos usuários.

1.3 HIPÓTESE DE PESQUISA

H0. É possível solucionar a problemática através da combinação de diferentes técnicas de recomendação no intuito de alcançar melhores taxas de acertos na recomendação.

H1. A combinação de diferentes técnicas de recomendação não melhora as taxas de acertos na recomendação.

1.4 OBJETIVOS

1.4.1 Objetivo Geral

A partir da problemática destacada, o presente trabalho tem como objetivo geral conceber um mecanismo de recomendação personalizada de conteúdo que, por meio do ambiente MobiLEHealth, possa prover aprendizagem informal no contexto de Saúde 2.0 às pessoas portadoras de doenças crônicas (MENDES NETO et al., 2014a,b). O MobiLEHealth fornece um leque de possibilidades para o fornecimento de conteúdos personalizados de saúde com foco no usuário, a partir de uma arquitetura modular abrangendo monitoramento de usuários, enriquecimento semântico de perfil de usuário e recomendação de conteúdos personalizados.

Com base neste escopo, pretende-se fornecer um mecanismo de recomendação capaz de adequar-se às características particulares dos usuários, indicando conteúdo adequado às

suas necessidades de saúde, sem interferir na sua rotina, interação social, profissional e assim, ajudando-as a serem ativas e responsáveis pelo seu tratamento e cuidado relativos à saúde.

1.4.2 Objetivos Específicos

Para que a meta apresentada no objetivo geral seja cumprida, alguns objetivos específicos precisam ser atendidos:

- Realizar uma revisão da literatura sobre as abordagens: aprendizagem informal, ambientes sensíveis ao contexto, saúde 2.0, enriquecimento semântico, algoritmo genético e sistemas de recomendação, buscando identificar, por meio dessa pesquisa, aspectos que contribuam para a aplicação da solução do problema que se pretende resolver neste trabalho;
- Modelar e implementar as camadas (técnicas de recomendação) que compõem o mecanismo de recomendação personalizada de conteúdo proposto;
- Implementar o algoritmo genético e definir os critérios da função *fitness* objetivando recomendar conteúdos diversificados com base no perfil do usuário e nos conteúdos de seu interesse;
- Realizar experimentos com dados simulados, no intuito de testar o funcionamento das técnicas de recomendação que contemplam o mecanismo de recomendação personalizada de conteúdo;
- Realizar validações com base em dados simulados para avaliar a eficácia da recomendação de conteúdo em um ambiente controlado, ou seja, observar a melhoria nas taxas de acerto na recomendação.

Os objetivos apresentados são atingidos através do método utilizado neste trabalho, que se divide em três etapas: (1) o método de pesquisa; (2) o método de implementação e (3) método de experimentos e validação da proposta.

- (1) O método de pesquisa está relacionado ao objetivo de: (i) identificar a solução para o problema em realizar a recomendação corretamente contextualizada e no momento certo, objetivando fornecer conteúdo adequado ao perfil do usuário; e (ii) investigar as abordagens que possam fornecer o arcabouço

teórico para o entendimento do problema e explicação sobre o contexto estudado. Com base nas etapas apresentadas, pretende-se chegar à solução em como recomendar conteúdos diversificados de forma correta objetivando promover melhor qualidade de vida às pessoas portadoras de doenças crônicas, por meio de sugestões de conteúdos de seus interesses.

- (2) O método de implementação foi definido com o objetivo de modelar e projetar a arquitetura em camadas e o funcionamento da solução (mecanismo de recomendação de conteúdo e algoritmo genético) para os problemas identificados durante as etapas do método de pesquisa.
- (3) O método de validação consiste em buscar, através dos experimentos, simulação e resultados obtidos, a resposta quanto à eficácia da solução desenvolvida no método de implementação.

1.5 MÉTODO DE PESQUISA

É importante ressaltar que este trabalho é parte integrante de um projeto desenvolvido pelo Grupo de Pesquisa de Engenharia de Software em Saúde 2.0 do Laboratório de Engenharia de Software – LES/UFERSA. Diante disto, as atividades que contemplam os métodos de pesquisa foram realizadas pelos pesquisadores (mestrandos e bolsistas) do grupo de pesquisa já citado e sob a supervisão e colaboração do professor-orientador do projeto.

Para que este trabalho possa ser desenvolvido com sucesso, são executadas as seguintes atividades:

Revisão Bibliográfica

Nesta atividade, foi realizada a pesquisa exploratória, através de revisão bibliográfica com fonte em livros, periódicos, artigos de conferências, documentações oficiais de padrões e até mesmo trabalhos relacionados de integrantes do Laboratório de Engenharia de Software (LES) da Universidade Federal Rural do Semiárido (UFERSA). O local escolhido para a realização da pesquisa foi o LES, pois este fornece toda a infraestrutura necessária.

A revisão na literatura foi realizada no intuito de buscar por conceitos, indícios e dados estatísticos, que edificassem os problemas relacionados aos cuidados relativos à saúde de pessoas portadoras de doenças crônicas, e buscar meios, técnicas para prover

aprendizagem no contexto da saúde, especificamente às pessoas com doenças crônicas, que foi o estudo de caso deste trabalho.

Buscou-se também, através da pesquisa, identificar as necessidades da concepção de um mecanismo de recomendação de conteúdo que por meio de um ambiente de aprendizagem possa prover, através da aprendizagem informal e do uso de dispositivos móveis, melhoria na qualidade de vida às pessoas portadoras de doenças crônicas.

Também foi objeto da pesquisa verificar as classificações de técnicas de recomendações bem como a forma de utilização destas técnicas aplicadas no contexto da saúde. Através dos estudos, buscou-se entender as formas específicas que cada técnica de filtragem utiliza para fornecer conteúdos e assim tentar aplicá-las de forma combinada para o propósito deste trabalho.

As etapas realizadas para o desenvolvimento do projeto de pesquisa foram:

Modelagem e implementação das camadas (técnicas de recomendação):

Nesta etapa, foram realizados estudos sobre as diferentes técnicas de recomendação no intuito de modelar a arquitetura em camadas e assim implementar cada técnica de recomendação buscando atingir o êxito na combinação das técnicas de filtragem de conteúdos.

Implementação do algoritmo genético e definição dos critérios da função *fitness*:

Na codificação do algoritmo foram implementados os operadores genéticos e definidos os critérios da função *fitness* para atender ao proposto no trabalho que é a escolha do melhor cromossomo (composto pelos 03 (três) conteúdos melhores avaliados na função *fitness*).

Realização de experimentos com dados simulados:

Nesta fase, foram realizados experimentos e simulações envolvendo dois domínios de conhecimento (Diabetes e Esclerose Lateral Amiotrófica - ELA). Para atingir o objetivo nesta atividade, algumas ações foram realizadas:

- Criação de dados simulados de pessoa e local;
- Seleção de 120 conteúdos na Web sobre os domínios (Diabetes, ELA e diversos). Nesta ação foram escolhidos portais renomados relacionados aos domínios citados, objetivando garantir a qualidade do conteúdo a ser recomendado;

- Implementação de um gerador de contexto para o preenchimento dos campos de relações e históricos de pessoa, conteúdo e local;
- Implementação de um programa para simular as ações do usuário conforme perfil definido;
- Execução do mecanismo de recomendação em camadas e análise dos resultados obtidos.

Todas as ações realizadas nesta etapa foram realizadas no LES juntamente com os membros do grupo de pesquisa.

Realização de validações com base em dados simulados:

Nesta atividade, buscamos realizar, através de dois cenários de uso, as ações do usuário no ambiente de aprendizagem de modo a verificar a funcionalidade da recomendação de conteúdo. Para avaliar o resultado da recomendação, foi utilizada uma métrica de avaliação, denominada *Precision*, objetivando:

- Saber a eficácia da recomendação do ponto de vista do perfil do usuário;
- Obter o grau de aceitação das recomendações; e
- Quantificar o número de aceitação ou rejeição dos usuários sobre os itens recomendados.

Através da métrica, que tem como tarefa medir a probabilidade de um item recomendado ser relevante, pretendeu-se obter o número de ocorrências enquadradas nas categorias vinculadas à aceitação e rejeição sobre itens recomendados aos usuários.

1.6 ORGANIZAÇÃO DA DISSERTAÇÃO

Esta dissertação está organizada da seguinte forma:

O Capítulo 2 apresenta o embasamento teórico sobre as abordagens envolvidas no desenvolvimento desta dissertação.

No Capítulo 3 é exposta uma revisão bibliográfica mostrando os trabalhos relacionados ao objetivo deste trabalho.

No Capítulo 4 é apresentada uma visão geral do ambiente MobiLEHealth.

No Capítulo 5 é apresentado o Sistema de Recomendação Personalizada de Conteúdo, descrevendo o funcionamento de cada camada responsável pela seleção e indicação de conteúdos relevantes aos usuários com base no perfil deles.

No Capítulo 6 é apresentada a validação do SRPC que contempla, as informações inerentes à simulação (experimentos) realizados em um ambiente controlado e as análises dos resultados obtidos com a execução do SRPC.

No Capítulo 7 são apresentadas as considerações finais e trabalhos futuros.

2 REFERENCIAL TEÓRICO

Neste capítulo é apresentado o embasamento teórico sobre as áreas relacionadas ao escopo deste trabalho.

2.1 APRENDIZAGEM INFORMAL

A aprendizagem informal é um modelo de aprendizagem que define o indivíduo como responsável pelo seu aprendizado, através de informações cotidianas do seu ambiente (JIUGEN; RUONAN; XIAOQIANG, 2011). Nesse contexto, pode-se definir a aprendizagem informal como o processo de aquisição do conhecimento por meio das experiências que o indivíduo adquire no seu dia-a-dia.

Conforme o entendimento de York and Nordengren (2013), a aprendizagem informal ocorre de forma não intencional, do ponto de vista do aprendiz, surgindo de atividades cotidianas realizadas no trabalho, na escola, em grupos, entre outras. Deste modo, podemos inferir que a aprendizagem informal nunca termina, ela continua a toda hora e em qualquer lugar.

Levando em consideração o contexto diário de um indivíduo, a aprendizagem informal, que ocorre em todas as fases da vida, tem como principais características (JIUGEN; RUONAN; XIAOQIANG, 2011):

- **Autonomia:** Em que o indivíduo é responsável por sua aprendizagem, onde ele determina o objetivo a ser alcançado, o conteúdo a ser abordado e como este será processado;
- **Conhecimento:** Que é obtido por meio das interações sociais e profissionais;
- **Diversidade:** Onde a fonte de informação se apresenta de várias formas, sem que seja necessário um local determinado. A aquisição de conhecimento pode ser obtida através de experiências diárias, recursos do ambiente, bibliotecas, redes sociais, dentre outros.

Como a aprendizagem informal ocorre, em determinadas situações, de forma ocasional e inconsciente, as tecnologias móveis podem auxiliar o processo fornecendo um ambiente que favoreça a autoaprendizagem, as relações sociais, o compartilhamento de

experiências e a aprendizagem colaborativa, proporcionando o acesso ao conhecimento, em qualquer lugar e a qualquer momento.

As definições e características apresentadas sobre a aprendizagem informal têm forte relação com a solução apresentada neste trabalho, pois a ideia é recomendar conteúdos relevantes baseados no perfil do usuário e de forma flexível e ubíqua.

2.2 AMBIENTES SENSÍVEIS AO CONTEXTO

Sensibilidade ao contexto descreve um paradigma no qual o contexto de um usuário é levado em consideração para definir o seu perfil (MOORE; HU, 2010). Não existe um consenso a respeito da definição de “contexto”, sendo este específico da aplicação e da intenção desejadas, requerendo a identificação das funções e propriedades dos domínios dos indivíduos (MOORE; HU, 2010; MOORE et al., 2009). Não há como definir de forma precisa o que seria o contexto. Dessa forma, as características que serão consideradas para construção do contexto dependem da situação específica.

De acordo com Dey and Abowd (1999), “contexto é qualquer informação utilizada para caracterizar a situação de uma pessoa, lugar ou objeto relevante para a interação entre um usuário e uma aplicação”. Neste sentido, podemos definir contexto como o cenário que transparece o estado ou circunstância em que se encontra uma pessoa. Ainda segundo os autores citados, uma aplicação é sensível ao contexto, se utiliza elementos do contexto para assegurar serviços ou informações relevantes para os usuários. É com base neste escopo que foi definido neste trabalho, a técnica de recomendação ubíqua, que faz parte de uma das camadas do sistema de recomendação desenvolvido.

O contexto pode ser definido de acordo com informações relativas a propriedades que se combinam para descrever e caracterizar uma entidade e seu papel de uma forma que possa ser interpretada pelo computador (MOORE; HU; WAN, 2008; MOORE et al., 2009). A localização do estudante, por exemplo, é uma característica importante para a definição do seu contexto em um ambiente para aprendizagem móvel. Entretanto, o contexto inclui mais do que apenas a localização. De fato, quase todas as informações disponíveis no momento da interação podem ser vistas como informações contextuais, dentre as quais se destacam (MOORE et al., 2009):

- As diversas tarefas realizadas pelos usuários no sistema;

- A variada gama de dispositivos que se combinam para criar sistemas móveis, com a infraestrutura de serviços associada;
- Os recursos disponíveis (ex.: condição da bateria, tamanho de tela etc.);
- A situação física (ex.: nível de ruído, temperatura, nível de luminosidade etc.);
- A informação espacial (ex. localização, velocidade, orientação etc.);
- A informação temporal (ex. hora do dia, data etc.).

A lista acima, embora não contenha exatamente todas as informações que podem ser consideradas, serve para demonstrar a complexidade inerente ao contexto, sua natureza de domínio específico e a dificuldade em defini-lo e medi-lo (MOORE et al., 2009). Na tentativa de diminuir essa complexidade, Moore, Hu and Wan (2008) definem dois tipos gerais de contexto:

- **Contexto estático (denominado customização):** diz respeito à situação na qual um perfil do usuário é criado manualmente, estando o usuário ativamente envolvido no processo e tendo um elemento de controle.
- **Contexto dinâmico (denominado personalização):** refere-se à condição na qual o usuário é visto como sendo passivo, ou pelo menos com um pouco menos de controle. Nesse caso, o sistema monitora, analisa e reage dinamicamente ao comportamento do usuário e ao papel identificado.

No campo da aprendizagem móvel sensível ao contexto, diversas aplicações utilizam contextos de aprendizagem a fim de sugerir adequadamente atividades e conteúdos para os seus usuários (YAU; JOY, 2010). Contudo, após ampla pesquisa, constatou-se que a maioria das publicações da área não levam em consideração os recursos físicos dos dispositivos móveis, o que limita uma definição mais precisa do contexto em que os usuários estão inseridos e por consequência o nível de aceitação nos materiais recomendados, já que isto sofre interferência direta das características dos dispositivos móveis utilizados pelos usuários.

As definições e características apresentadas sobre ambientes sensíveis ao contexto são de suma importância ao escopo deste trabalho, pois o mecanismo de recomendação de conteúdos desenvolvido tem como tarefa fornecer conteúdo considerando o contexto em que se encontra o usuário. Deste modo, a aprendizagem informal por meio do recebimento dos conteúdos pode ocorrer de forma flexível e ubíqua, o que enfatiza a conexão entre as abordagens de recomendação de conteúdos e de ambientes sensíveis ao contexto.

2.3 SAÚDE 2.0

A utilização em massa de dispositivos móveis e das ferramentas sociais da Web 2.0 mostra que estas ferramentas estão cada vez mais incorporadas ao cotidiano do cidadão. O compartilhamento de experiências e as interações sociais podem acontecer a qualquer momento, independentemente do local e distância em que os indivíduos se encontram. Essas tecnologias fazem com que os cidadãos sejam ativos e responsáveis pela geração e pelo fluxo da informação, tornando-os emissores e receptores nesse processo.

Este cenário levou à formação do conceito de saúde 2.0, que define que o cidadão deve ser responsável por sua saúde, deixando de ser coadjuvante para se tornar ativo nos cuidados relacionados a ela (HUGHES; JOSHI; WAREHAM, 2008). Para isso une a aprendizagem informal ao uso de tecnologias e ferramentas da Web 2.0 (redes sociais, registros pessoais de saúde, *blogs*, vídeos, serviços, etc.), voltados à construção coletiva do conhecimento na saúde (FERNANDEZ-LUQUE et al., 2010).

Neste contexto, o indivíduo não assume o lugar do médico, mas se torna um parceiro deste, sendo mais autônomo e consciente no que se refere à sua condição de saúde e com conhecimento suficiente para participar nas tomadas de decisões.

Este trabalho está diretamente relacionado ao contexto da saúde 2.0, uma vez que busca fornecer apoio a um ambiente de aprendizagem informal em saúde com foco em usuários com doenças crônicas. Para tanto, considera a experiência cotidiana do usuário na Web para determinar os seus interesses em conteúdos relacionados à sua condição de saúde.

2.4 ALGORITMO GENÉTICO

Algoritmo Genético (AG) pode ser definido como uma metáfora do processo biológico baseado na teoria da evolução natural das espécies (HOLLAND, 1975). Os AGs são responsáveis por tentar encontrar uma solução para os problemas que não têm algoritmos conhecidos. Em geral, o AG toma como entrada uma população inicial, chamada de cromossomos, e os indivíduos mais adequados são selecionados para a solução do problema, de acordo com os critérios de avaliação. Se os indivíduos selecionados não são os melhores, é feita uma nova combinação (ROTHLAUF, 2006).

No AG, o processo de seleção feito a cada geração ocorre com base na função de avaliação, que mede o nível de aptidão dos cromossomos. A função que realiza a medição é conhecida como Função *Fitness* ou Função de Avaliação (LINDEN, 2008). Através desta, os cromossomos que tiverem o melhor nível *fitness* são selecionados para darem origem à próxima geração, através de operações como cruzamentos e mutações. Desta forma, a tendência é que a cada geração o conjunto de soluções seja melhorado, até que se chegue a uma solução que atenda aos objetivos desejados (GOLDBERG; HOLLAND, 1988). O processo básico de um AG é apresentado na Figura 1.

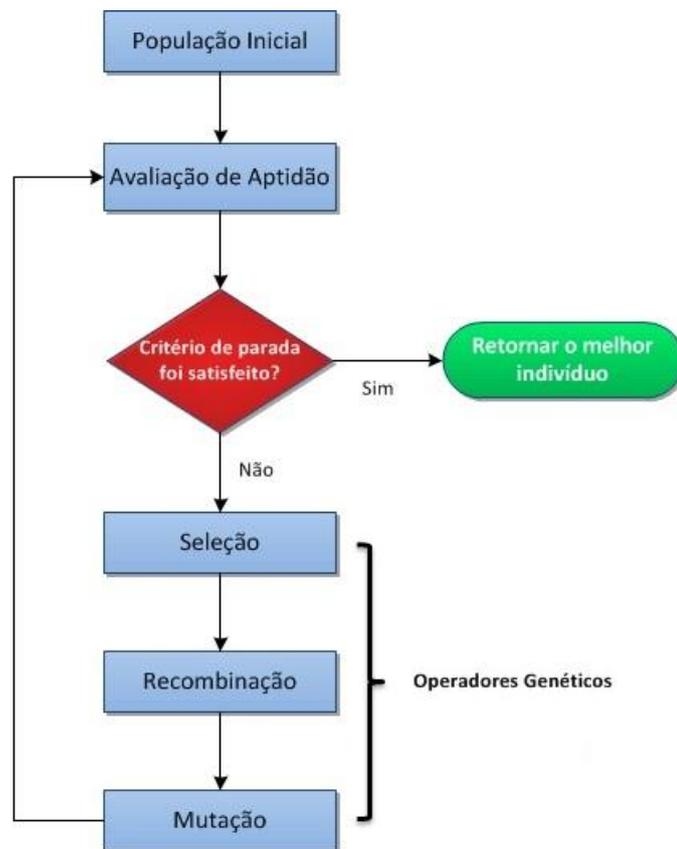


Figura 1 – Estrutura Básica de um Algoritmo Genético

Fonte: Adaptado de (ZINI, 2009)

Conforme Linden (2008), a execução de um AG pode ser resumida nos seguintes passos:

- a) Inicializa-se a população de cromossomos;
- b) Avalia-se cada cromossomo da população;
- c) Seleciona-se os indivíduos que irão assumir o papel de pais para gerar novos cromossomos;

- d) Aplica-se as operações de recombinação e mutação, a fim de selecionar os indivíduos como pais, criando uma nova geração;
- e) Elimina-se os cromossomos da geração anterior;
- f) Avalia-se os cromossomos que foram gerados e inseridos na população;
- g) Se os cromossomos encontrados representam a solução esperada para o problema ou o número máximo de gerações foi alcançado, ou o AG não conseguiu mostrar mais progresso, a execução é terminada. Caso contrário, a execução retorna para o passo c.

Ao final da execução do algoritmo, espera-se que a população de cromossomos gerada seja a melhor adaptada à função e, por conseguinte, a que melhor represente o resultado do problema. Porém, apesar do processo apresentado na Figura 1 fornecer uma representação geral e esclarecedora a respeito do funcionamento de um AG, é apenas uma visão de alto nível do problema. Ou seja, ele esconde aspectos mais complexos que devem ser tratados, tais como (LINDEN, 2008; PETROLI NETO, 2011; SILVA, 2012):

- a) Escolha de uma codificação dos cromossomos adequada ao problema;
- b) Definição do tamanho da população necessária;
- c) Definição da forma como será realizada a mutação; e
- d) Seleção de uma função de aptidão que avalie satisfatoriamente o grau de adequação de cada indivíduo como solução do problema em questão.

Esses são os principais pontos a serem tratados quanto ao AG em questão e, portanto, serão detalhados na seção que trata da implementação do AG (SILVA, 2012).

Com base nas características apresentadas sobre o AG, foi decidido pelo grupo de pesquisa a escolha de implementar o AG e verificar se o mesmo atende ao propósito que é recomendar, de forma correta, conteúdos de saúde contextualizados e diversificados, objetivando prover aprendizagem informal às pessoas portadoras de doenças crônicas.

2.5 ENRIQUECIMENTO SEMÂNTICO

Para que os ambientes de aprendizagem forneçam conteúdos relevantes ao contexto do usuário faz-se necessário que tanto o perfil do mesmo como o teor dos conteúdos a serem apresentados sejam conhecidos. As técnicas de enriquecimento semântico podem ser empregadas para análise e classificação de conteúdo, enquanto a imensa quantidade de dados

gerados pelos usuários nas redes sociais proporciona uma visão clara e ampla sobre suas preferências e características.

Segundo Despotakis et al. (2011), a mídia social irá ter um forte impacto sobre a aprendizagem informal ao fornecer informações sobre as experiências reais dos usuários, suas preferências e interações tanto internamente às redes sociais quanto externamente, uma vez que podem ser utilizadas para:

- a) comentar sobre experiências com outras pessoas, serviços ou lugares (shoppings, hotéis, praias, etc.);
- b) compartilhar histórias (*blogs*, livro, twitter, etc.);
- c) comentar situações vivenciadas (vídeo, livro, viagem, etc.).

A estas experiências reais experimentadas através das mídias sociais dá-se o nome de Traços Digitais (TDs) (DESPOTAKIS et al., 2011). Quando selecionados com atenção, os TDs possuem grande potencial para a aprendizagem, onde ambientes de aprendizagem modernos podem explorar o conteúdo gerado pelo usuário para proporcionar situações relacionadas com sua experiência no mundo real no processo de aprendizagem.

Sendo um reflexo da vida social humana, as redes sociais, de maneira geral, não tratam de apenas um domínio de conhecimento específico, acarretando em múltiplas possibilidades de interpretação de seu conteúdo. No entanto, novas arquiteturas têm surgido com o intuito de criar, agregar, organizar e explorar os TDs, facilitando o processo de interpretação e, conseqüentemente, o processo de categorização e recomendação de conteúdo em situações de aprendizagem informal (DESPOTAKIS et al., 2011).

Estas arquiteturas são fortemente baseadas em técnicas de enriquecimento semântico. O enriquecimento semântico é o processo de anexar conceitos semânticos a partes específicas de um texto, provendo uma estrutura para interpretação automática de seu significado e possibilitando estender a compreensão do domínio de um determinado TD (KARANASIOS et al., 2013). Para isso, é realizada a identificação e o mapeamento de termos-chave a partir do conteúdo textual, como, por exemplo, comentários, através de técnicas e ferramentas de Processamento de Linguagem Natural (PLN). Os termos podem, então, serem semanticamente associadas a conceitos oriundos de uma ontologia¹, que são de contextos específicos, a fim de realizar uma marcação semântica (KARANASIOS et al., 2013).

¹ Ontologia é uma especificação explícita e formal de uma conceituação compartilhada de um domínio de interesse (STUMME, 2002)

O processo de enriquecimento é então fortemente baseado no PLN e em ontologias para, de posse do resultado destes, traçar o perfil dos usuários e realizar a categorização dos conteúdos automaticamente.

O enriquecimento semântico é fundamental para o escopo deste trabalho, pois através do processamento de suas técnicas é possível obter informações mais corretas sobre o perfil dos usuários bem como a semelhança semântica entre eles e os conteúdos. Desta forma, esta técnica ajuda na tarefa de recomendar conteúdos de forma personalizada baseado nas necessidades, preferências, interesses e características sociais do usuário.

2.6 SISTEMAS DE RECOMENDAÇÃO

O aumento de meios de disponibilização de conteúdo, podendo ser serviços ou informação, através de sistemas Web, provoca uma situação onde o usuário possui muitas opções de escolha antes mesmo de estar apto a selecionar uma opção que atenda suas necessidades. Sistemas de Recomendação (SR) buscam amenizar os impactos gerados por essa sobrecarga de informação. Ao contrário de sistemas de busca, os SR permitem o acesso à informação sem uma consulta explícita de um dado usuário (COELLO; YUMING; TOBAR, 2013).

Para tanto, os SR utilizam repositórios de informação e dados de preferência dos usuários para direcionar conteúdos aos indivíduos com potenciais interesses. Um dos desafios dos SR é realizar a indicação de produtos, serviços e/ou informação que melhor atendam às expectativas dos usuários, bem como ao seu perfil.

No que concerne à definição de uma estratégia de recomendação, diversas técnicas podem ser utilizadas, de forma isolada ou combinada, para que as recomendações sejam geradas (REATEGUI; CAZELLA, 2005).

Desta forma, encontramos na literatura alguns tipos de estratégias de recomendação. Segundo Vieira e Nunes (2012), os SR podem ser classificados em três tipos:

- Sistema de Recomendação Baseada em Conteúdo (SRBC), que é realizada através de informações recuperadas do usuário (perfil, comportamento, etc.) e/ou do seu histórico de escolhas. Deste modo, a recomendação personalizada pode obter no final do seu processamento um resultado satisfatório para o usuário;

- Sistema de Recomendação Colaborativa (SRC), que leva em consideração as escolhas realizadas por usuários com características similares, ou seja, os conteúdos recomendados já foram utilizados em recomendações feitas a outros usuários com perfis semelhantes; e
- Sistema de Recomendação Híbrida (SRH), que efetua a recomendação através das técnicas utilizadas pelos SRBC e SRC, de forma a atingir um maior número de possibilidades e sugerir objetos que diretamente não aparentam estar relacionados (MARTINS JÚNIOR et al., 2011).

A classificação tradicional dos SR não exclui outras possibilidades de classificação, sob outras características ou técnicas, aplicadas da maneira mais adequada para solucionar um caso específico. As subseções seguintes apresentam, de forma resumida, algumas das técnicas de mais destaque na literatura.

2.6.1 Tipos de Sistemas de Recomendação

Nas próximas subseções são apresentados os tipos de sistemas de recomendação mais comumente usados e para cada uma das técnicas será dado destaque à importância da construção do perfil do usuário para o sucesso na recomendação.

2.6.1.1 Sistema de Recomendação Baseada em Conteúdo

A abordagem baseada em conteúdo tem suas raízes na área de recuperação de informação. Devido aos significativos avanços feitos pelas comunidades de filtragem de informação e filtragem de conteúdo, muitos sistemas baseados em filtragem de conteúdo focam na recomendação de itens com informações textuais, como documentos e *sites* (CAZELLA; NUNES; REATEGUI, 2010).

Desta forma, a filtragem baseada em conteúdo parte do princípio de que os usuários tendem a interessar-se por itens similares aos que demonstraram interesse no passado, definindo então a similaridade entre os itens (HERLOCKER, 2000).

Em muitos casos, verificar esta similaridade pode não ser trivial. Por exemplo, para que seja estabelecida a similaridade entre itens como roupas e brinquedos, talvez seja necessária a identificação dos atributos nos itens a serem comparados (peso, preço ou marca) (ACOSTA; REATEGUI, 2012). Já se os itens são documentos textuais, este processo de comparação pode ser facilitado, por exemplo, pela análise de termos em comum.

Em relação ao perfil do usuário, a construção deste é um dos pontos-chave do método baseado em conteúdo. O perfil do usuário contém características descritivas (palavras-chave) dos conteúdos que o usuário deseja ou não deseja. As comparações são realizadas comparando-se o perfil do usuário a todos os conteúdos, identificando os conteúdos mais similares ao perfil desse usuário (MACÁRIO FILHO, 2006).

Como pontos fortes desta técnica são citadas: a capacidade de recomendar todos os itens (reduzindo a esparsidade) e a ausência do problema do primeiro avaliador. Diferentemente da filtragem colaborativa, um conteúdo não precisa ser lido por um usuário para que seja recomendado a outro, basta que existam palavras em comum entre o conteúdo e o perfil do usuário para que este receba a recomendação desse item. Já a esparsidade é reduzida porque para todo conteúdo pode ser medida a similaridade com o perfil do usuário e assim todos possuem chances de serem recomendados (TORRES, 2004) citado por (ROCHA, 2007).

A filtragem baseada em conteúdos também apresenta alguns pontos fracos, a saber: (i) a impossibilidade de análise em domínios não textuais; (ii) a superespecialização; (iii) a não utilização de avaliações baseadas em qualidades e gostos; e (iv) a não consideração de aspectos como qualidade do texto e renome do autor. Esta técnica também não consegue analisar com eficiência arquivos multimídia, como imagens, áudios e vídeos (TORRES, 2004) citado por (ROCHA, 2007).

Apesar de a técnica mencionada analisar o conteúdo de um texto, sua qualidade, clareza e elegância não são levadas em consideração e, como o usuário não fornece notas nessa filtragem, torna-se mais difícil ainda para um sistema saber se o usuário achou esse um texto bem escrito ou não. Além disso, não é considerado o renome de quem produziu o conteúdo, por exemplo, diretores de filmes ou autores renomados em determinada área são tratados igualmente com as outras pessoas nesse tipo de filtragem (MACÁRIO FILHO, 2006).

A filtragem baseada em conteúdo é contemplada neste trabalho pelos seguintes motivos: (i) por ser uma das técnicas mais utilizadas e relevantes no processo de fornecimento

de conteúdos de aprendizagem e (ii) por ser utilizado em conjunto com outras técnicas de recomendação utilizadas neste trabalho, atendendo a metodologia proposta.

2.6.1.2 Sistema de Recomendação Colaborativa

A filtragem colaborativa se diferencia da filtragem baseada em conteúdo pelo fato de exigir a compreensão ou reconhecimento do conteúdo dos itens, atendendo pontos que ficaram em aberto na abordagem baseada em conteúdo (ACOSTA; REATEGUI, 2012).

Nos sistemas colaborativos, a essência está na troca de experiências entre as pessoas que possuem interesses comuns. Nestes sistemas, os itens são filtrados com base nas avaliações feitas pelos usuários (CAZELLA; NUNES; REATEGUI, 2010). Dessa forma, os sistemas colaborativos partem do princípio de que os usuários semelhantes irão gostar de itens semelhantes.

A pontuação permite ao usuário descobrir itens que são considerados de interesse pelo grupo e evitar os itens que são considerados de pouco interesse. Sistemas mais avançados descobrem de maneira automática relações entre usuários (vizinhos mais próximos), com base na descoberta de padrões comuns de comportamento (CAZELLA; NUNES; REATEGUI, 2010).

A filtragem colaborativa apresenta algumas vantagens como, por exemplo, a possibilidade de apresentar aos usuários recomendações inesperadas, ou seja, o usuário pode receber recomendações de itens que não estavam sendo pesquisados de forma ativa (ACOSTA; REATEGUI, 2012).

Com base nas características desta técnica, é importante destacar a forma como é construído o perfil do usuário. O armazenamento dos perfis de usuários geralmente é composto por suas avaliações para alguns conteúdos. Após o armazenamento dessas informações, é realizado um processamento para identificar pessoas com preferências semelhantes através de similaridades entre as notas que foram dadas para um mesmo conteúdo (MACÁRIO FILHO, 2006).

Como pontos fortes deste método em relação ao perfil do usuário, destacamos:

- A independência de conteúdo, onde se torna possível fazer recomendações de produtos de tipos distintos, isto é, o mesmo sistema pode recomendar livros, filmes e músicas, por exemplo.

- É possível apresentar aos usuários recomendações inesperadas e com qualidade. O usuário pode receber recomendações de itens que não estavam sendo pesquisados de forma ativa (REATEGUI; CAZELLA, 2005). O fato de surpreender o usuário positivamente pode ser chamado de serendipidade (MACÁRIO FILHO, 2006).
- Possibilidade de formação de comunidades de usuários pela identificação de seus gostos e interesses similares (REATEGUI; CAZELLA, 2005).

Apesar das vantagens apresentadas, também existe pontos negativos. A base da filtragem colaborativa é a avaliação de conteúdos por usuários. Portanto, um conteúdo que não tenha sido avaliado por nenhum usuário e um novo item que foi inserido no banco de dados nunca serão recomendados, pois esses conteúdos nunca irão aparecer como opções de recomendação para o sistema. Essa limitação é conhecida como o problema do primeiro avaliador.

Sites de comércio eletrônico possuem uma base de dados, normalmente, muito grande. Para um usuário formar um perfil com 0,1% dos produtos de uma loja que tenha um milhão de produtos em seu catálogo é preciso que o usuário compre ou avalie 1000 (um mil) produtos. Esse problema é chamado de dispersão dos dados porque existe um grande risco das pontuações se tornarem muito esparsas devido ao pequeno número de usuários em relação ao grande volume de informações no banco de dados (MACÁRIO FILHO, 2006).

O problema do falso vizinho ou ovelha negra acontece quando usuários são considerados semelhantes para o sistema, porém, na verdade, esses usuários não possuem preferências parecidas para outros itens. Pode ocorrer que usuários, coincidentemente, avaliem alguns itens igualmente e nos perfis dos mesmos possuam poucos itens. Usuários com mais produtos avaliados igualmente têm muito mais chance de realmente serem semelhantes (MACÁRIO FILHO, 2006).

2.6.1.3 Sistema de Recomendação Híbrida

Há diversas técnicas que podem ser utilizadas para recomendar produtos aos usuários. Cada uma destas técnicas possui vantagens e desvantagens e algumas são melhores que outras quando aplicadas em diferentes domínios.

A filtragem híbrida emprega técnicas advindas tanto da abordagem de filtragem colaborativa quanto da filtragem baseada em conteúdo. A ideia é baseada na busca de itens de

acordo com os perfis de interesse dos usuários, mas considerando também a similaridade de conteúdo entre os itens (ACOSTA; REATEGUI, 2012). Ao integrar ambas as técnicas, a filtragem híbrida busca incorporar as vantagens tanto da filtragem colaborativa quanto da filtragem baseada em conteúdo, ao mesmo tempo em que minimiza possíveis limitações de uma ou outra abordagem (HERLOCKER, 2000).

A Figura 2 apresenta de forma gráfica a junção das filtragens baseada em conteúdo e colaborativa.

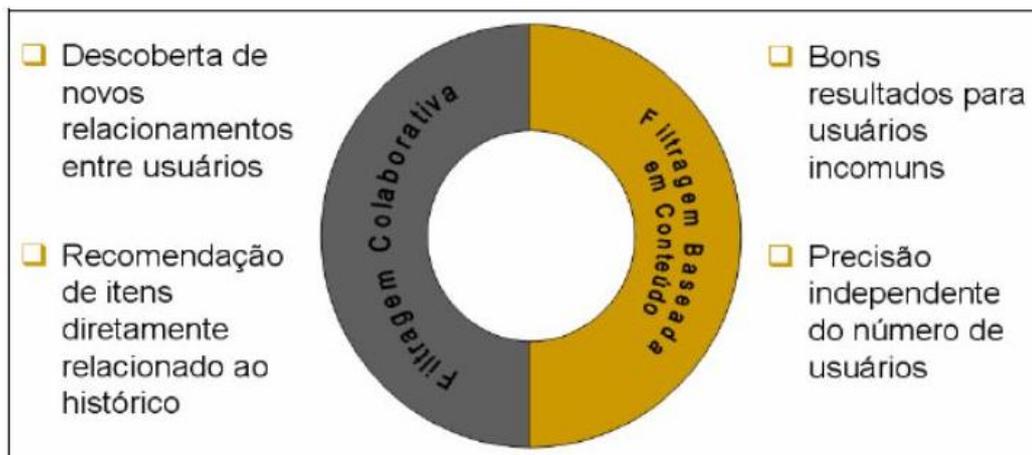


Figura 2 – Filtragem Híbrida

Fonte: Adaptado de (CAZELLA; NUNES; REATEGUI, 2010)

Além dos tipos de recomendação, existe na literatura estratégias de recomendação que servem para ranquear os itens filtrados pelas técnicas de recomendações. A próxima subseção trata dos tipos de estratégias de recomendação e como elas podem influenciar o grau de personalização do usuário.

2.6.2 Estratégias de Recomendação

O ranqueamento dos itens filtrados pode ser feito através de diversas estratégias. Veremos aqui conceitos básicos sobre essa tarefa, bem como algumas das estratégias mais usadas no ranqueamento de itens.

Para melhor entendimento das estratégias de recomendação Cazella, Nunes e Reategui (2010), é importante que sejam analisados os graus de personalização que uma recomendação

pode ter. Segundo Moraes Neto (2011), quanto ao grau de personalização, a recomendação pode ser:

- **Não personalizada:** Quando uma aplicação oferece a mesma recomendação para todos os usuários;
- **Efêmera:** Sistemas que utilizam as informações fornecidas pelo usuário para personalizar a recomendação;
- **Persistente:** Trata cada usuário de acordo com as suas preferências, oferecendo diferentes itens para diferentes usuários, mesmo que eles tenham escolhido os mesmos itens. Isso acontece porque as demais informações dos perfis destes são levadas em consideração;

Como descrito acima, existem muitas estratégias de recomendação, as quais podem variar de acordo com o domínio e os objetivos do sistema. Este trabalho tem a característica para atender o grau de personalização efêmera e persistente.

3 TRABALHOS RELACIONADOS

A utilização de Sistemas de Recomendação (SR) tem sido bastante útil para o usuário na busca por informações de seu interesse na Web. No âmbito da aprendizagem informal, os usuários são expostos a uma grande quantidade de recursos de informação, onde muitas vezes não estão aptos para realizar tais escolhas. Desta forma, um SR vem suprir esta carência recomendando recursos apropriados e auxiliando na escolha do usuário, que passará a lidar com um volume menor de informação. No contexto da saúde e da aprendizagem informal, várias pesquisas vêm sendo desenvolvidas a respeito do uso de sistemas de recomendação, no entanto, nenhum deles aborda todos os pontos considerados neste trabalho.

Weitzel, Palazzo e Oliveira (2010) propõem um modelo de classificação de perfis de usuários que compõe um SR de informação médica. O SR proposto abrange cinco módulos: Módulo de Interface, de Avaliação de Conteúdo, de Extração de Conteúdo, e de Qualidade e de Usuário. O desenvolvimento de alguns destes módulos foi realizado por outros pesquisadores.

Lichtnow e Oliveira (2009) desenvolveram o módulo de Avaliação de Conteúdo que tem como tarefa avaliar sites Web da área da saúde e, com o uso de ontologias, obter a taxonomia para tratar os assuntos relacionados à área médica.

Oliveira e Fleischmann (2009) realizaram pesquisas fundamentais para a criação do Módulo de Extração de Conteúdo. Este obtém, de forma automática, conteúdos de *sites* na área médica.

Childs (2004) apresenta o projeto “Judge”, que tem o objetivo de desenvolver diretrizes de qualidade de *sites* Web na área de saúde em relação ao uso de medicamentos.

Su e Wu (2011) propõem um SR voltado para *blogs* na área da saúde, onde são observados *sites* de redes sociais, como Twitter, Facebook, LinkedIn, entre outros.

Li et al., (2012) desenvolveram o sistema SCROLL (*System for Capturing and Reminding of Learning Log*). Este sistema proporciona aos usuários registrarem suas experiências de aprendizagem, associando a elas fotos, áudio, vídeos, localização, dados de sensores e outras informações. Embora utilize captura, armazenagem e organização de conteúdo de forma ubíqua, este sistema não fornece uma recomendação sensível ao contexto, que possa disponibilizar essas informações direcionando-a aos usuários mais adequados.

Já Ferreira e Raabe (2010) apresentam o LORSys (*Learning Object Recommender System*), um sistema de recomendação de Objetos de Aprendizagem (OAs) no formato

SCORM (*Sharable Content Object Reference Model*) (SCORM, 2013), para o Ambiente Sophia, que é uma personalização do Moodle² (*Modular Object-Oriented Dynamic Learning Environment*) (MOODLE, 2012). O LORSys utiliza a técnica de recomendação híbrida, aplicada a informações de preferências dos estudantes e dados de acesso aos OAs. Apesar disso, tem como ponto fraco o fato de recomendar apenas OAs padronizados e não ser sensível ao contexto do usuário.

Ávila (2008) apresenta o SisRecAC, que tem o objetivo de encontrar na Web, através de uma meta-busca, artigos científicos que sejam de interesse de um usuário através de um texto exemplo. Uma consulta, por exemplo, é realizada a partir de um texto exemplo informado pelo usuário e não a partir de palavras-chave, o que é, atualmente, o padrão para busca de informações. Os artigos localizados e recomendados pela ferramenta de meta-busca passam por uma avaliação do próprio usuário, que pode comentá-los e recomendá-los a outras pessoas, criando uma rede de cooperação. O sistema apresentou-se bastante eficaz, entretanto como sistema de busca e não de recomendação.

Acosta e Reategui (2012) apresentaram um trabalho com foco na ampliação da ferramenta SMILE por meio da integração de um sistema de recomendação de conteúdo a esta, com o objetivo de facilitar os processos investigativos e ampliar a reflexão dos estudantes com relação aos temas abordados. As recomendações de conteúdo na ferramenta SMILE são baseadas em um texto selecionado pelo professor, que determina o tema de uma atividade. Estas recomendações podem ser desde textos que auxiliem na elaboração de questionamentos, imagens, vídeos ou até autores que escrevem sobre tema proposto. Mas uma vez o sistema não apresenta sensibilidade ao contexto ou mobilidade, assim como neste caso também não personaliza o conteúdo recomendado de acordo com o perfil do usuário.

Costa (2013) apresentou um trabalho que tem como objetivo a concepção, implementação e apresentação de um modelo semântico de personalização para recomendação de conteúdo ao usuário de acordo com suas preferências e necessidades. O modelo é estruturado e beneficiado pela interoperabilidade, a qual expande o espaço de busca para bases de dados heterogêneas, permitindo a recomendação dinâmica de conteúdo em um maior volume de dados e garantindo maior eficiência à personalização. Entretanto também não apresenta suporte à mobilidade e à ubiquidade.

Diferentemente dos trabalhos expostos neste capítulo, o SR apresentado neste trabalho combina diferentes técnicas de recomendação, que serão descritas na próxima seção e um Algoritmo Genético (AG), para realizar a recomendação de conteúdos relacionados à saúde de

² Ambiente de Aprendizagem Moodle. <http://www.moodle.org.br/>

acordo com o perfil dos usuários. Foi verificado que a abordagem desenvolvida aumenta a eficácia da recomendação.

3.1 DIFERENCIAL DA ABORDAGEM DE RECOMENDAÇÃO PROPOSTA

No que concerne à contribuição deste trabalho, se faz necessária à realização de um comparativo com os trabalhos expostos neste capítulo. Conforme foi visto nos trabalhos relacionados, o perfil do usuário é sempre muito importante no processo de recomendação, porém preencher formulários exaustivos com suas características/preferências não é uma solução viável e, por outro lado, ao utilizar-se de poucos dados sobre o usuário, dificulta o conhecimento sobre o mesmo. Nesse contexto, o enriquecimento semântico vem a suprir essa necessidade e, juntamente com a análise dos históricos de acessos e relações, podem prover uma solução que ajudará o que é tratado no escopo deste trabalho que é realizar uma recomendação apropriada.

O segundo fator importante observado nos trabalhos citados é que, apesar de alguns deles até utilizarem-se do aspecto mobilidade, não utilizam-se da sensibilidade ao contexto, ou vice-versa, deixando a desejar na recomendação.

Outro fator importante está relacionado ao fato de todos os sistemas vistos recomendarem conteúdos padronizados em algum formato, o que dificulta a aprendizagem informal, limitando a quantidade e a diversidade dos conteúdos.

Dessa forma, a modelagem do SR desenvolvida destaca-se como sendo a principal contribuição científica desse trabalho, pois uni todos os pontos fortes dos trabalhos anteriores e tenta minimizar os pontos fracos. A Tabela 1 apresenta as principais características do SR modelado neste trabalho.

Tabela 1 – Características do SR Modelado

Características	Descrição
Colaborativa	Ponderando inclusive o grau de influência que um usuário tem em relação a outro.
Baseada em Conteúdo	Analisando as características dos históricos de acessos de cada usuário com as características do conteúdo a ser recomendado.

Mobilidade	Com utilização destinada a dispositivos móveis.
Ubiquidade	Considerando as características inerentes ao contexto do usuário e do dispositivo móvel que o mesmo está usando.
Recomendação Conjunta	Priorizando a diversidade na recomendação, e assim evitando recomendar conteúdos que disputem pelo mesmo tipo de características, priorizando, desta forma, o sucesso no conjunto de conteúdos a serem recomendados.
Enriquecimento Semântico	É incluído como característica, pois o mesmo é utilizado para comparação entre usuários e para análise de recomendação de conteúdo a usuário.
Adaptação Automática e Personalização	Onde são realizados ajustes automáticos dos pesos com base no histórico dos usuários.

Fonte: Autoria Própria

4 MOBILEHEALTH

Para contextualizar as funcionalidades do Sistema de Recomendação Personalizada de Conteúdo (SRPC) faz-se necessário antes expor os elementos e o funcionamento do ambiente de aprendizagem informal MobiLEHealth, desenvolvido pelo grupo de pesquisa no qual está inserido o SRPC desenvolvido.

A arquitetura desenvolvida para o MobiLEHealth descreve a comunicação entre os elementos que compõem a estrutura, sendo esta organizada em cinco ambientes distintos (Registro Pessoal de Saúde e Serviços Web 2.0, Componente de Interação com o Usuário, Componente de Monitoramento, Enriquecimento Semântico, Repositório Semântico e Recomendação de Conteúdo), envolvendo três áreas de conhecimentos:

- (i) Monitoramento Ubíquo de Usuários, que realiza o monitoramento dos acessos dos usuários, coletando as informações de registro dos usuários, *sites* visitados e gravando os metatados tanto dos usuários como dos *sites* visitados;
- (ii) Enriquecimento Semântico de Perfil de Usuário e de Conteúdos, que tem a função de avaliar o interesse do usuário de forma implícita no intuito de enriquecer semanticamente o perfil destes usuários com os dados coletados pelo componente de interação com usuário, componente de monitoramento, e com base nos domínios de conhecimentos registrados no repositório semântico (MOREIRA et al., 2014); e
- (iii) Recomendação Personalizada de Conteúdos, que é o foco deste trabalho. Tem a função de recomendar conteúdos personalizados com base nas informações monitoradas e enriquecidas pelos componentes anteriores.

4.1 ARQUITETURA

A arquitetura do MobiLEHealth foi definida de forma que os componentes sejam modulares e independentes, delegando atividades e funções específicas para cada componente, do modo a manter a consistência da arquitetura.

A Figura 3 apresenta a o modelo arquitetural do MobiLEHealth.

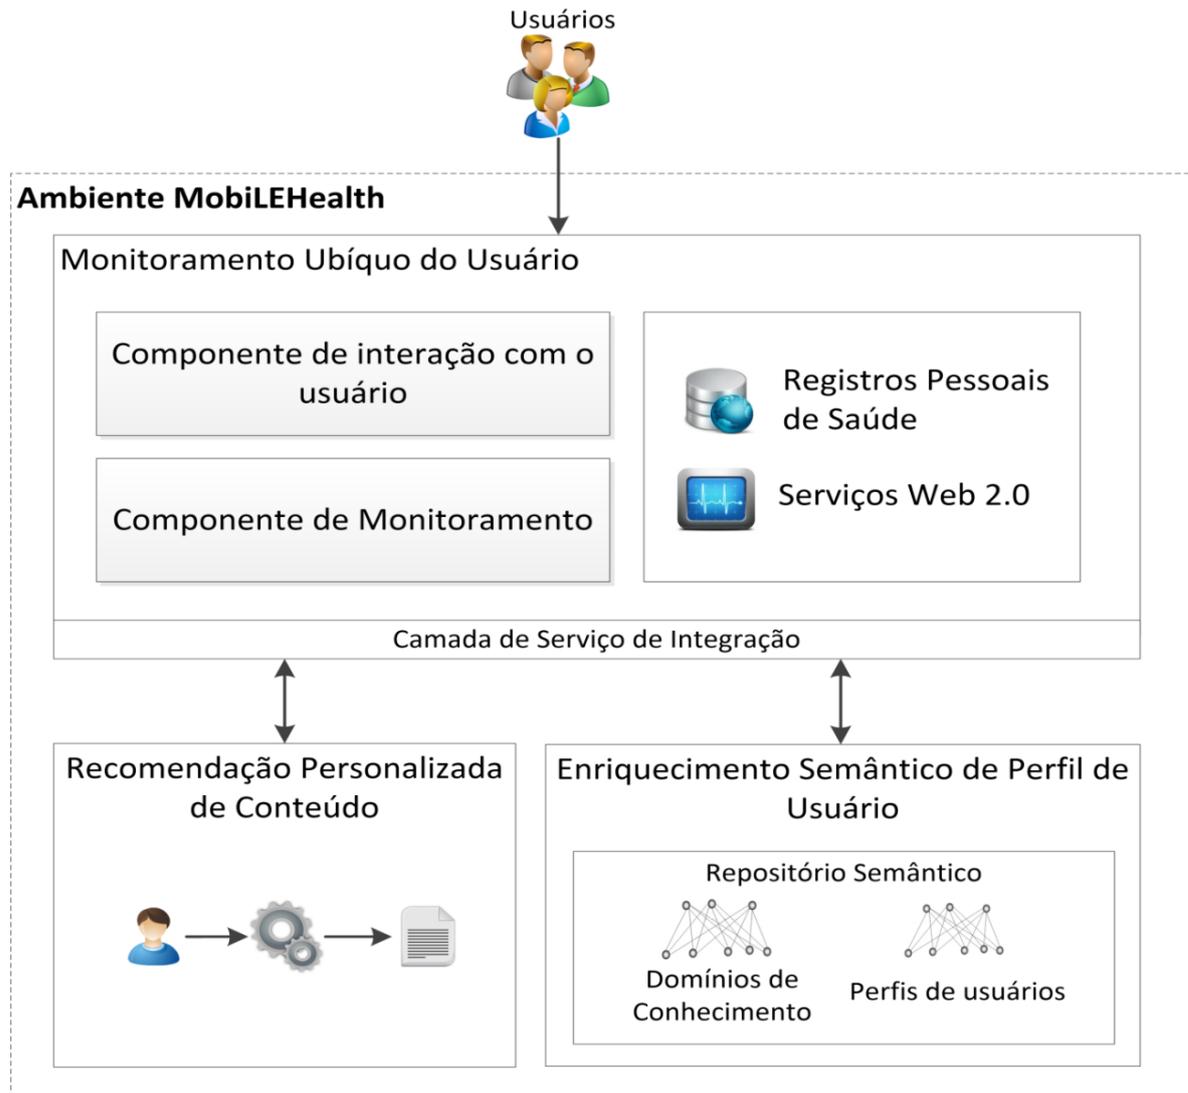


Figura 3 – Modelo Arquitetural do MobiLEHealth

Fonte: Adaptado de (MENDES NETO et al., 2014a,b)

A seguir é apresentada uma breve descrição de cada elemento que compõe a arquitetura do MobiLEHealth:

(A) Serviços Web 2.0

São ferramentas, como redes sociais, registros pessoais de saúde, *blogs*, servidores de vídeos, etc., que ajudam o ambiente MobiLEHealth a capturar, através da experiência do usuário, informações referentes à saúde e, pela combinação desses dados e informações, fornecer cuidados e conteúdos personalizados.

(B) Registro Pessoal de Saúde (*Personal Health Record - PHR*)

Interface com base de dados disponível na Web oriunda de Sistemas de Registros Pessoais de Saúde (PHRs), com informações mantidas pelo próprio usuário relacionadas à sua saúde. Pode conter diversos dados, incluindo, mas não limitados a, relatos do paciente, informações sobre a saúde, medicamentos, histórico familiar, exames laboratoriais e dados de dispositivos, como, por exemplo, celulares e sensores.

(C) Componente de Interação com o Usuário

O Componente de Interação com o Usuário é a interface de comunicação entre o usuário e o Componente de Recomendação de Conteúdo. Através de uma aplicação móvel, o usuário receberá alertas e conteúdos recomendados.

(D) Componente de Monitoramento

O Componente de Monitoramento é usado para fazer o monitoramento ubíquo do usuário. Esta operação envolve a coleta de dados em dispositivos monitorados, monitoramento de serviços Web que o usuário utiliza, como redes sociais, dados de equipamentos, etc., para, posteriormente, possibilitar a realização de alertas e recomendações de conteúdos.

(E) Repositório Semântico de Perfil do Usuário

O Repositório Semântico de Perfil do Usuário é uma base de dados (ontologia) que armazena informações sobre o perfil do usuário (histórico clínico, hábitos, atividades diárias, tratamentos sendo realizados, etc.).

(F) Repositório Semântico do Domínio de Conhecimento

O Repositório Semântico do Domínio de Conhecimento é uma base de dados (ontologia) que armazena informações sobre domínios de conhecimento referentes à área de Saúde (doenças crônicas, terminologias médicas, etc.).

(G) Enriquecimento Semântico do Perfil do Usuário

O Enriquecimento Semântico do Perfil do Usuário tem a tarefa de vincular ao perfil do usuário o conteúdo contextualizado e informações referentes a dados de saúde do usuário a partir do Registro Pessoal de Saúde (PHR) e do Componente de Monitoramento.

(H) Recomendação Personalizada de Conteúdo

A Recomendação Personalizada de Conteúdo tem a função de recomendar conteúdo ao Componente de Interação com o Usuário com base no perfil do usuário e em ontologias recebidas do Repositório Semântico de Perfil do Usuário e do Repositório Semântico do Domínio de Conhecimento.

As características apresentadas sobre o modelo são primordiais no apoio à aprendizagem informal no contexto de Saúde 2.0, pois através das atividades específicas de cada componente permite-se selecionar e direcionar conteúdos que atendam, especificamente, pessoas portadoras de doença crônica, promovendo, desta forma, o conhecimento sobre a doença e, conseqüentemente, uma melhoria na sua qualidade de vida.

A arquitetura do MobiLEHealth foi modelada para que os componentes estejam integrados, mas que funcionem de forma independente e autônoma. Atuando de forma isolada, cada componente desempenha o seu papel para alcançar um objetivo comum. A Figura 4 mostra o diagrama de componentes do MobiLEHealth.

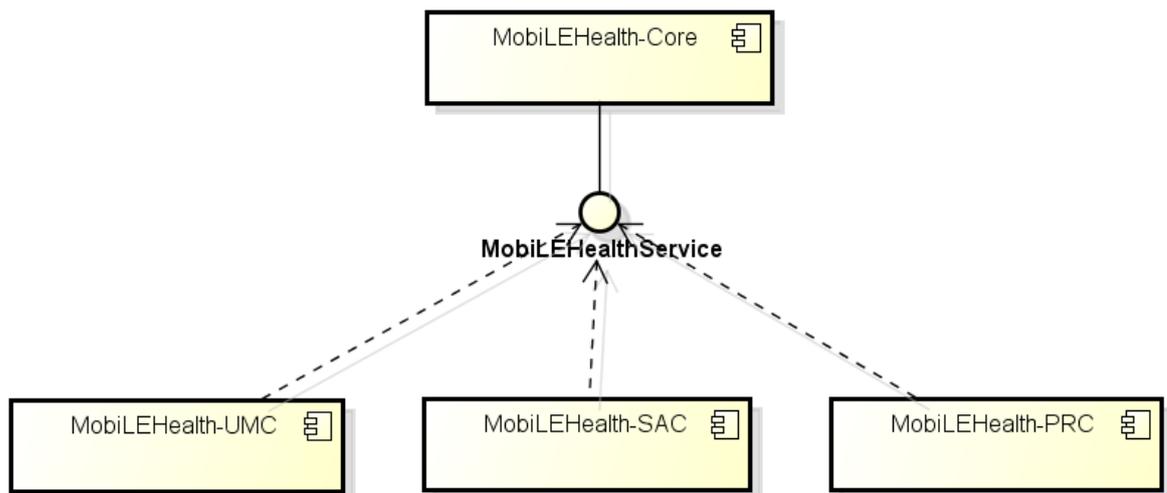


Figura 4 – Diagrama de Componentes do MobiLEHealth

Fonte: (MOREIRA, 2014).

Uma breve descrição da especialização e colaboração de cada componente mostrado na Figura 4 é apresentada a seguir.

O *Core* é o núcleo central do MobiLEHealth e dispõe de uma interface de serviços para a integração dos componentes, que não se comunicam diretamente entre si. Ele é responsável por garantir a padronização e a integridade das informações manipuladas pelos demais sistemas.

O *User Monitoring Component* (UMC) contém as aplicações móveis responsáveis por interagir com o usuário e monitorar suas atividades diárias em seus dispositivos móveis,

enviando estas informações ao *Core* para que sejam armazenadas na base de dados do *MobiLEHealth*.

O *Semantic Augmentation Component* (SAC) é o componente responsável por realizar o processamento semântico das informações contidas no *MobiLEHealth* e gerar o perfil semântico do usuário.

O *Personalized Recommendation Component* (PRC) analisa a base de dados e o perfil semântico contidos no componente SAC, para gerar as recomendações apropriadas aos usuários.

4.2 INTEGRAÇÃO DO PRC COM O SAC

A integração entre os componentes PRC e SAC é feita através da Camada de Serviço de Integração e é considerada de suma importância para o resultado final da recomendação. O resultado através do SAC é utilizado tanto na criação da Lista de Colaboradores (LC) como da Lista Baseada em Conteúdo (LBC).

O SAC é composto pela seguinte estrutura de ontologias:

a) Ontologias de Domínio: Representam os mais variados temas ou assuntos que podem ser implantados no sistema. Atualmente tem-se: Diabetes e Esclerose Lateral Amiotrófica (ELA).

b) Ontologias de Perfil: Representam os usuários ou os conteúdos do sistema.

O Sistema de Recomendação interage com SAC por meio da classe de interface *SACExternalService interface*. Os métodos a seguir retornam os índices a serem utilizados na geração das listas:

- *getDegreeOfInterestsDomains(Person person)*: Retorna o índice que representa o grau de interesse de uma pessoa para todos os domínios registrados no sistema. Este índice pode variar de 0,0 a 1,0 determinando assim a relação do usuário com o conhecimento de domínio. Se o valor do índice for maior ou igual a 0,3³, significa que o usuário tem interesse no domínio.
- *getDegreeofInterest(Person person, String domain)*: Retorna o grau de interesse de uma pessoa para um domínio específico. Caso não exista domínio,

³ É o valor mínimo definido na validação do Sistema de Enriquecimento Semântico que representa a existência de relação de interesse de usuário por domínio e de relação do conteúdo com o domínio (MOREIRA, 2014).

é retornado 0 para este domínio. O índice pode variar de 0,0 a 1,0 determinando assim a relação do usuário com o conhecimento de domínio. Caso o valor seja maior ou igual a 0,3, o usuário tem interesse no domínio.

- *getRelationshipLevelDomains(Content content)*: Retorna o índice que representa o nível de relação de um conteúdo para todos os domínios registrados no sistema. O índice também pode variar de 0,0 a 1,0 determinando a relação entre o conteúdo com o conhecimento de domínio. Se o valor for maior ou igual a 0,3, o conteúdo está relacionado com o domínio.
- *getRelationshipLevelDomain(Content content, String domain)*: Retorna o índice que representa o nível de relacionamento do conteúdo para um domínio específico. Se o domínio não existir, retorna o valor 0 (zero) para o domínio. O índice pode variar de 0,0 a 1,0 determinando a relação entre o conteúdo e o domínio de conhecimento. Se o valor for maior ou igual a 0,3, o conteúdo está relacionado com o domínio.

Como não faz parte do escopo desse trabalho o detalhamento do funcionamento do SAC, é necessário somente expor a descrição e o funcionamento das interfaces da classe *SACExternalService interface*. No Capítulo 5 demonstraremos como estes índices influenciam o peso usado nas técnicas de recomendação baseada em conteúdo e colaborativa.

5 SISTEMA DE RECOMENDAÇÃO PERSONALIZADA DE CONTEÚDOS

A solução desenvolvida neste trabalho é um Sistema de Recomendação Personalizada de Conteúdos (SRPC) integrado ao MobiLEHealth, porém funcionando de forma isolada e garantindo a consistência do modelo.

O SRPC fornece apoio à aprendizagem informal e ubíqua a pessoas portadoras de doenças crônicas, provendo conhecimento ao usuário no intuito de ajudá-lo a conviver melhor com sua doença, e conseqüentemente adquirir melhoria na sua qualidade de vida. Esse conhecimento é fornecido através da recomendação de conteúdo de forma personalizada ao usuário, considerando características do seu perfil, que se baseia no seu contexto diário e na sua condição de saúde.

Para atender às características inerentes do SRPC, a arquitetura foi desenvolvida em camadas, de forma que cada elemento seja responsável por técnicas de filtragem e seleção específicas, permitindo a aplicação de diversas técnicas e selecionando de forma mais eficiente conteúdos relevantes ao usuário. Desta maneira, a arquitetura, apresentada na Figura 5, torna-se expansível a novas técnicas.

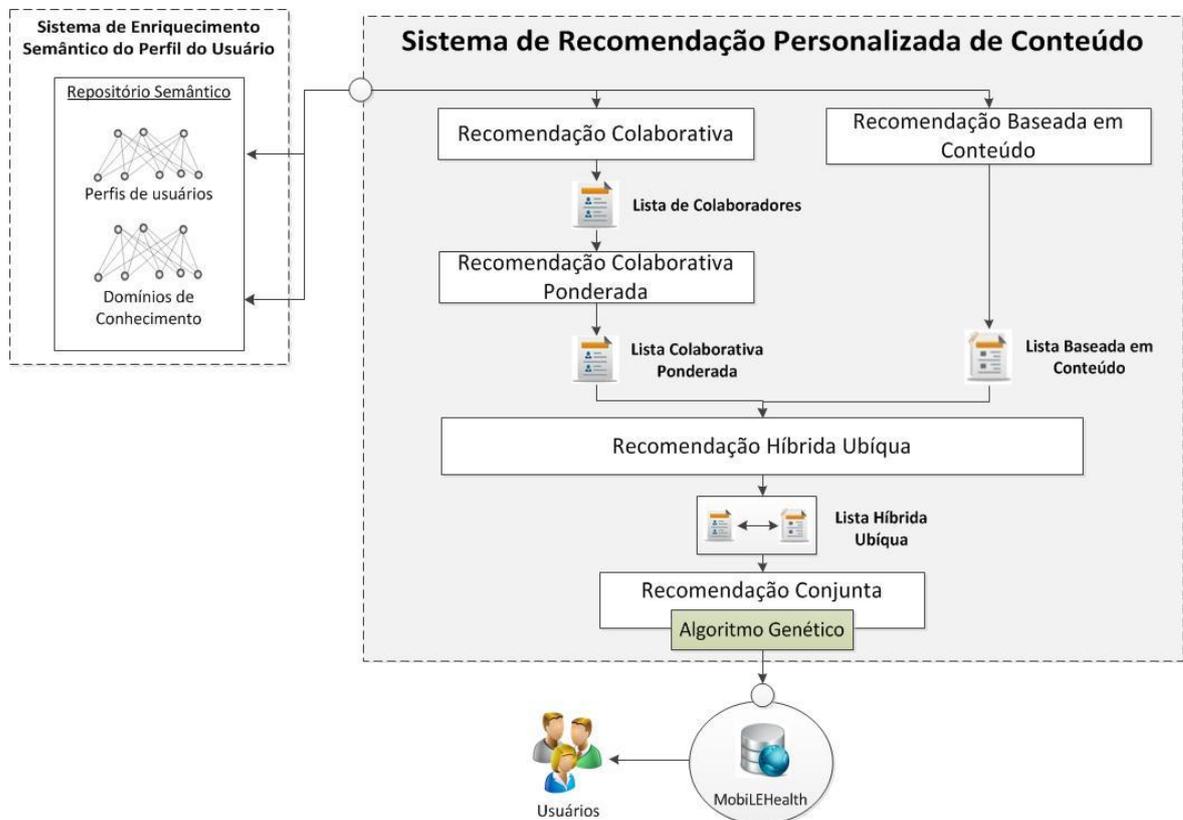


Figura 5 – Arquitetura do Sistema de Recomendação Personalizada de Conteúdo

Fonte: Adaptado de (COSTA et al., 2014a, b)

Conforme a Figura 5, o processo é iniciado através do acesso que o SRPC faz à interface do Sistema de Enriquecimento Semântico do Perfil do Usuário (SESPU) na tarefa de consultar os dados resultantes do processamento do enriquecimento semântico.

O SRPC tem a tarefa de selecionar usuários para realizar o processamento de recomendação de conteúdo. Esse processamento analisa os dados do contexto do usuário contidos no sistema de Enriquecimento Semântico de Perfil de Usuário (SESPU), como conteúdos acessados, dados de cadastro, localização, relações com outras pessoas, conteúdos que ele gostou ou não, aceitação ou recusa de recomendação, dados relacionado à saúde, relações semânticas, etc. A estrutura do SESPu é composta por ontologias de perfil, necessárias para a geração de relações semânticas com um determinado domínio.

Após a obtenção das informações do SESPu, é dado início ao processamento, realizado em camadas, das técnicas de recomendação do SRPC. Explicando de forma resumida, primeiramente ocorre a execução da Recomendação Colaborativa (RC) e da Recomendação Baseada em Conteúdo (RBC). Da recomendação colaborativa, gera-se a Lista de Colaboradores, que servirá como entrada para o processamento da Recomendação Colaborativa Ponderada (RCP), a partir da qual se obtém a Lista Colaborativa Ponderada (LCP). A Recomendação Baseada em Conteúdo gera ao final do seu processamento a lista de conteúdos com domínio semelhante ao perfil do usuário. Na etapa seguinte há um cruzamento dos resultados da RCP e da RBC, e esta junção é usada como entrada para a execução da Recomendação Híbrida Ubíqua (RHU), que também considera informações referentes à ubiquidade do usuário. Por fim o resultado da RHU é processado pela Recomendação Conjunta (RCJ), procurando relações entre os seus itens e o interesse do usuário, gerando um conjunto de conteúdos finais a serem recomendados ao usuário. Esse conjunto é formado com o objetivo de buscar a diversidade da recomendação. O resultado é disponibilizado em uma interface denominada Camada de Serviço de Integração, onde o MobiLEHealth faz acesso na busca por conteúdos recomendados.

Para entender melhor sobre o processamento da diversidade da recomendação é necessário conhecer cada camada (técnica de recomendação) que está embutida no SRPC. A Seção 5.1 descreve todas as camadas da arquitetura do SRPC.

5.1 CAMADAS DA ARQUITETURA DO SRPC

Nas subseções a seguir são apresentados os elementos que compõem a arquitetura do SRPC, bem como o detalhamento dos passos executados em cada técnica de recomendação.

5.1.1 Recomendação Colaborativa

A Recomendação Colaborativa consiste na análise das escolhas e avaliações de usuários semelhantes ao usuário alvo, formando a Lista de Colaboradores (LC) e vinculando-os ao Índice de Semelhança entre Usuários (ISU).

5.1.1.1 Lista de Colaboradores

A técnica colaborativa executa uma rotina onde escolhe, para todos os usuários, quem são seus respectivos colaboradores, ou seja, pessoas com maior grau de semelhança, ordenando-os assim na Lista de Colaboradores e vinculando-os ao Índice de Semelhança entre Usuários - ISU.

Para o cálculo do ISU, leva-se em consideração os seguintes aspectos:

(a) Metadados (S1): Analisa os dados de ambos os usuários, como idade, sexo, renda, religião, cor/raça, doença crônica, nível educacional, estilo de aprendizagem, área de formação e suas especificações, de forma que dados coincidentes acrescentam o índice de semelhança de metadados, enquanto que dados divergentes decrescem este índice.

(b) Relações (S2): As relações existentes entre dois usuários podem ser: amigos, requisitou amizade, amizade requisitada, rejeitou amizade, amizade rejeitada, deletou amizade, amizade deletada, visualizou usuário e usuário visualizado. Neste item o sistema analisa quais tipos de relações existem entre os usuários alvo, assim como as relações em comum destes com outros. Usuários onde ambos possuem relação “amigos” referente à relação entre eles acrescentará a pontuação na semelhança de relações entre eles, enquanto que se um usuário possui uma relação “amigos” e o outro uma relação “amizade deletada” isso decrescerá o índice entre ambos.

(c) Conteúdos (S3): Analisa quais relações com conteúdo são comuns aos usuários alvo. As possíveis relações analisadas são: aceitação e rejeição de recomendação, e a

visualização de conteúdo. Usuários que aceitam visualizar o mesmo conteúdo são acrescidos em sua pontuação de semelhança de conteúdo, enquanto que um usuário que rejeita um conteúdo visualizado por outro terá sua semelhança de conteúdo entre eles decrescida.

(d) Locais (S4): Analisa quais relações com locais são comuns aos usuários alvo. Para fins da recomendação, as relações com locais são de aceitação e rejeição de recomendação, e de visualização de conteúdo. Se dois usuários relacionam-se da mesma forma com um local, isso acrescentará pontos na semelhança de locais, entretanto se um usuário sempre aceita conteúdos e outro sempre rejeita conteúdos no mesmo local, isso decrescerá a semelhança de locais entre esses usuários.

(e) Frequência (S5): Os histogramas de frequência armazenam as respostas de aceitação e rejeição em relação às recomendações geradas para os usuários, conteúdos e locais. Eles são de dois tipos: semanais, que acumulam os valores classificando-os em cada dia da semana; e os diários, classificando-os por hora do dia. Neste item o sistema analisa a semelhança entre os histogramas de aceitação e rejeição de conteúdos pelos usuários alvo, ou seja, se dois usuários possuem percentuais de aceitações semelhantes na mesma hora do dia, ou no mesmo dia da semana, isso incrementará o índice de semelhança de frequências, enquanto que se divergir decrescerá este índice.

(f) Tags (S6): Analisa a semelhança entre a lista de *tags* dos usuários alvo, onde *tags* semelhantes incrementam o índice de semelhança de *tags*.

(g) Enriquecimento Semântico (S7): Analisa a semelhança entre os enriquecimentos semânticos dos usuários alvo. O sistema de recomendação solicita ao sistema de enriquecimento quais as afinidades de dois usuários com cada um dos domínios instalados, e as compara, extraíndo assim a semelhança semântica entre os usuários.

O ISU entre o usuário “i” e o usuário “j” é calculado como sendo a média ponderada de cada uma das semelhanças descritas nos itens anteriores, de acordo com a Equação 1.

$$ISU_{i,j} = \frac{S1*P1 + S2*P2 + S3*P3 + S4*P4 + S5*P5 + S6*P6 + S7*P7}{P1 + P2 + P3 + P4 + P5 + P6 + P7} \quad (1)$$

Onde S_i representa o nível de semelhança de determinada característica e P_i representa o peso dessa característica na avaliação. O peso é definido na primeira recomendação com valor 5,0 e, com base nas ações de aceitação e rejeição do usuário em relação à recomendação, os valores incrementam ou decrementam 1.0 ponto. É importante ressaltar que essas definições do valor do peso ocorrem em todas as recomendações que possuem o fator

peso em seu cálculo. Os n maiores resultados de ISU, vinculados aos seus respectivos pares de usuários, são armazenados na Lista de Colaboradores de tamanho n de um usuário. Todo esse processo é executado no servidor periodicamente sobre todos os usuários, atualizando-se assim sua Lista de Colaboradores para posterior uso no cálculo da Lista Colaborativa Ponderada.

Os passos do processo de obtenção da lista de colaboradores e do ISU são descritos no Algoritmo 1.

Algoritmo 1: Gera a lista de colaboradores através do Índice de Semelhança entre os Usuários.

Entrada: Lista de todas as pessoas

Variáveis: `aparenciaFinal[i][j]`, `aparenciaMetaDados`, `aparenciaTags`, `aparenciaLocais`, `aparenciaFrequencia`, `aparenciaSemantica` {

`lerTodasPessoas()`: Realiza a leitura dos metadados de todas as pessoas inseridas no banco de dados.

`comparaTodasPessoas()` { Faz a comparação entre a pessoa i e j buscando a semelhança entre elas sob os seguintes aspectos:

`comparaMetaDados()`: Analisa metadados (idade, sexo, renda, religião, cor/raça, doença crônica, nível educacional, estilo de aprendizagem, área de formação) entre dois usuários.

`comparaAmigos()`: Analisa, na lista da relação `PessoaPessoa`, o relacionamento de amizade entre duas pessoas.

se tiver relação com `Status = Amigos` **então**

 adiciona `aparenciaAmigos` na relação `PessoaPessoa`

senão

 procura outra pessoa na lista `relaçãoPessoaLocal`.

fim se

`comparaConteudos()`: Analisa, na lista da relação `PessoaConteúdo`, os tipos de relações com conteúdos comuns a duas pessoas i e j .

se tiver relação com `Status = ConteudoFavorito` **então**

 adiciona `aparenciaConteudos` na relação `PessoaConteudo`

senão

 procura outro conteúdo na lista `relacaoPessoaConteudo`

fim se

`comparaLocais()`: Analisa, na lista da relação `PessoaLocal`, os locais favoritos entre duas pessoas i e j .

Para cada pessoa da lista pessoa é feita a comparação por local favorito.

se tiver relação com Status = LocalFavorito **então**

adiciona aparenciaLocais na relaçãoPessoaLocal

senão

procura outra pessoa na lista relaçãoPessoaLocal

fim se

comparaFrequencia(): Analisa, na lista de Pessoa, os histogramas de frequência de aceitação ou rejeição de recomendações geradas para pessoa, conteúdo e locais.

comparaTags(): Analisa a semelhança entre a lista de *tags* dos usuários alvos, onde *tags* semelhantes incrementam o índice de semelhança de *tags*.

comparaSemantica(): Analisa, na lista Pessoa, a semelhançaSemantica entre as pessoas *i* e *j*.

}
calculaSemelhanca() { Calcula através de média ponderada a semelhança (todas as aparencias) entre a pessoa *i* e a pessoa *j*.

aparenciaFinal[i][j] = aparenciaMetaDados + aparenciaAmigos +
aparenciaConteudos + aparenciaLocais + aparenciaFrequencia + aparenciaTags +
aparenciaSemantica;

}
listaColaborativa = MaioresISU(): Na lista pessoa, seleciona os mais semelhantes entre si para compor a lista de Colaboradores.

// Retorna a listaColaborativa como resultado

retorna listaColaborativa: Mostra a lista de colaboradores que servirão como entrada para a Recomendação Colaborativa Ponderada.

}

Saída: Lista de Pessoas com perfis semelhantes, ou seja, colaboradores entre si.

Resultado: O resultado deste algoritmo, que é a Lista de Colaboradores, é usado no cálculo da próxima técnica de recomendação: Recomendação Colaborativa Ponderada.

Considerando as definições e características da abordagem da aprendizagem informal, foi necessária a implementação desta técnica de recomendação que prima por fornecer uma lista de pessoas consideradas colaboradores. Deste modo, tenta-se mostrar que, através da técnica colaborativa, há a possibilidade da aprendizagem informal ser adquirida através da recomendação de conteúdos entre pessoas colaboradoras.

5.1.2 Recomendação Colaborativa Ponderada

A Recomendação Colaborativa Ponderada analisa o histórico das relações do usuário com o conteúdo e as avaliações de cada usuário da LC, gerando a Lista Colaborativa Ponderada (LCP). Essa lista baseia-se na relação de um conteúdo com o usuário alvo, considerando a média de todas as avaliações do conteúdo pelos usuários presentes na LC.

5.1.2.1 Lista Colaborativa Ponderada

A Lista Colaborativa Ponderada (LCP) é resultante da análise do histórico das relações com conteúdo dos usuários presentes na Lista de Colaboradores de cada usuário alvo. Logo, a LCP é uma lista de conteúdos escolhidos com base nas escolhas dos colaboradores dos usuários. O sistema percorre toda a Lista de Colaboradores de cada usuário analisando as relações destes com os conteúdos e suas respectivas avaliações. Cada conteúdo novo identificado é adicionado a uma lista temporária que contém o identificador do conteúdo e um Índice de Semelhança Colaborativa – ISC.

Dado um usuário alvo identificado por U_i , sabe-se que: (a) U_i possui sua Lista de Colaboradores contendo n usuários e seus respectivos ISU relativos a U_i ; (b) Cada usuário j , pertencente à Lista de Colaboradores, possui uma lista de relações com conteúdo; (c) $A_{j,k}$ é a avaliação dada pelo usuário j (pertencente à Lista de Colaboradores) ao conteúdo k , pertencente à sua Lista de Relações de Conteúdo, e (d) t é o total de vezes que um conteúdo k aparece nas listas de relações com conteúdo dos usuários presentes na Lista de Colaboradores.

O $ISC_{i,k}$ de um determinado conteúdo k com um usuário i é calculado como sendo a média de todas as avaliações deste conteúdo pelos n usuários presentes na Lista Colaborativa do usuário i , ponderada por seus respectivos $ISU_{i,j}$, como mostra a Equação 2.

$$ISC_{i,k} = \frac{1}{t} \sum_{j=0}^{n-1} A_{j,k} * ISU_{i,j} \quad (2)$$

Os m maiores resultados de ISC são armazenados como a Lista Colaborativa Ponderada (LCP) de tamanho m de um usuário. Esse processo é executado no servidor periodicamente sobre todos os usuários, atualizando-se assim sua Lista Colaborativa Ponderada para posterior uso no cálculo da Lista Ubíqua e da Lista Híbrida.

5.1.2.2 Índice de Semelhança Semântica entre Usuários

Foi apresentado na Subseção 5.1.1.1. que no cálculo do ISU aparece o índice $S7$, calculado como resultado do retorno do SES. Como o enriquecimento semântico é um dos pilares da recomendação, vamos detalhar como se dá o cálculo de $S7$, que aqui representa a semelhança semântica entre dois usuários i e j . Como o SES calcula apenas o quanto um usuário se interessa por um determinado domínio, para calcularmos o quanto dois usuários, i e j , se assemelham semanticamente utilizamos a Equação 3.

$$S7_{i,j} = \frac{10 * n - \sum_{k=1}^n |A_{i,k} - A_{j,k}|}{n} \quad (3)$$

Para o cálculo acima, apresentamos as seguintes descrições:

- (a) $S7_{i,j}$ é o índice de semelhança semântica entre o usuário i e o usuário j ;
- (b) n é o número de domínios implantados no SES;
- (c) $A_{i,k}$ é o índice de interesse do usuário i pelo domínio k , retornado pelo SES; e
- (d) $A_{j,k}$ é o índice de interesse do usuário j pelo domínio k , retornado pelo SES.

Os passos do processo de obtenção da Lista Colaborativa Ponderada são descritos no Algoritmo 2.

Algoritmo 2: Gera a Lista Colaborativa Ponderada

Entrada: Lista de todas as pessoas, Lista de Colaboradores, Lista de todos os conteúdos;

Variáveis: `aparenciaFinal[i][j]`, `aparenciaMetaDados`, `aparenciaTags`, `aparenciaLocais`, `aparenciaFrequencia`, `aparenciaSemantica`, `aparenciaHistorico`, {

`lerTodasPessoas()`: Realiza a leitura dos metadados de todas as pessoas inseridas no banco de dados.

`lerListaColaboradores()`: Faz a leitura na lista de colaboradores.

`lerTodosConteudos()`: Realiza a leitura na Lista de todos os Conteúdos.

`calculaIndiceColaborativo()` { : Compara a semelhança entre todas as pessoas e todos os conteúdos.

`comparasemelhancaPessoaPessoa()`: Analisa, na lista da relação `PessoaPessoa`, a pessoa com `Status = Colaboradores`.

se tiver relação com `Status = Colaboradores` **então**

```

        adiciona a lista pessoasRecomendadas na listaColaborativaPonderada
    então
        procura outra pessoa na lista relaçãoPessoaPessoa
    fim se
}
comparasemelhancaPessoaConteudo(): Analisa, na lista da relaçãoPessoaConteudo,
conteúdos com Status = Favorito.
se tiver relação com Status = ConteudoFavorito então
    adiciona a listaRelacaoConteudo na relaçãoPessoaConteudo
    então
        procura outro conteúdo na lista relacaoPessoaConteudo
    fim se
}
// Seleciona os mais semelhantes entre si para compor as suas listas colaborativas.
listaColaborativaPonderada = MaioresISC(): É feito o cálculo buscando na lista
ColaborativaPonderada os índices mais semelhantes entre pessoas colaboradoras e conteúdos
favoritos.
// Retorna a listaColaborativa como resultado.
retorna listaColaborativaPonderada: Onde é retornada a listaColaborativa.
}

```

Saída: Lista ColaborativaPonderada considerando pessoas e conteúdos semelhantes entre si.

Resultado: O resultado deste algoritmo é usado no cálculo da técnica de recomendação: Recomendação Híbrida Ubíqua.

No intuito de obter melhor êxito na recomendação de conteúdos que estimulem a aprendizagem informal, foi necessária a implementação da recomendação colaborativa ponderada. Por meio desta técnica, são conhecidas todas as avaliações do conteúdo pelos usuários presentes na LC e, desta forma, são obtidas as semelhanças entre usuários, o que favorece ainda mais a colaboração no fornecimento de conteúdos entre os mesmos.

5.1.3 Recomendação Baseada em Conteúdo

A Recomendação Baseada em Conteúdo (RBC) analisa toda a base de usuários e gera, para cada um deles, uma Lista Baseada em Conteúdo (LBC). A RBC calcula o Índice

Baseado em Conteúdo (IBC), que representa o quanto um conteúdo é recomendável a um usuário, considerando os históricos do conteúdo e do usuário.

Para o cálculo do IBC, leva-se em consideração os seguintes aspectos:

(a) Metadados (S1): Analisa os dados do histórico de relacionamento de visualização de conteúdo do usuário, como tipo, tamanho, duração, autor, tempo da publicação, e compara as mesmas características às características do conteúdo alvo. Se as características são coincidentes ou semelhantes, incrementa-se o índice de semelhança de metadados. O sistema também considera os índices de aceitação e de avaliação do conteúdo alvo, onde conteúdos com índices altos são priorizados.

(b) Tags (S2): Analisa a semelhança entre a lista de *tags* do usuário e do conteúdo, onde *tags* semelhantes incrementam o índice de semelhança de *tags*.

(c) Locais (S3): Analisa quais relações com locais são comuns ao usuário e ao conteúdo. Para fins da recomendação, as relações com locais podem ser de aceitação ou de rejeição de recomendação, e de visualização de conteúdo. Se um usuário e um conteúdo relacionam-se da mesma forma com um local, isso acrescentará pontos na semelhança de locais, entretanto se um usuário sempre aceita conteúdos nesse local e um determinado conteúdo sempre é rejeitado nesse mesmo local, isso decrescerá a semelhança de locais entre esse usuário e o conteúdo.

(d) Frequência (S4): Os histogramas de frequência armazenam as respostas de aceitação e de rejeição em relação às recomendações geradas para os usuários, conteúdos e locais. Eles são de dois tipos: semanais, que acumulam os valores classificando-os em cada dia da semana, e os diários, classificando-os por hora do dia. Neste item o sistema analisa a semelhança entre os histogramas de aceitação e de rejeição de conteúdo do usuário alvo e do conteúdo, ou seja, se ambos possuem percentuais de aceitação semelhantes na mesma hora do dia, ou no mesmo dia da semana, isso incrementará o índice de semelhança de frequências, enquanto que se divergir decrescerá este índice.

(e) Enriquecimento Semântico (S5): Analisa a semelhança entre os enriquecimentos semânticos do usuário alvo e do conteúdo. O sistema de recomendação solicita ao sistema de enriquecimento quais as afinidades do usuário alvo com cada um dos domínios instalados, e as compara com a afinidade do conteúdo com os mesmos domínios, extraindo assim a semelhança semântica entre o usuário e o conteúdo.

O IBC entre o usuário i e o usuário j é calculado como sendo a média ponderada de cada uma das semelhanças descritas nos itens anteriores, de acordo com a Equação 4.

$$IBC_{i,j} = \frac{S1*P1 + S2*P2 + S3*P3 + S4*P4 + S5*P5}{P1 + P2 + P3 + P4 + P5} \quad (4)$$

Onde S_i representa o nível de semelhança de determinada característica e P_i representa o peso dessa característica na avaliação. Os n maiores resultados de IBC, vinculados aos seus respectivos pares, usuário e conteúdo, são armazenados como a Lista Baseada em Conteúdo de tamanho n de um usuário.

5.1.3.1 Índice de Semelhança entre Usuário e Conteúdo

Foi visto que no cálculo do IBC aparece o índice S5, calculado como resultado do retorno do SES. Como o enriquecimento semântico é um dos pilares da recomendação, vamos detalhar como se dá o cálculo de S5, que representa a semelhança semântica entre um usuário e um conteúdo. O SES calcula o quanto um recurso (conteúdo) se relaciona com um determinado domínio. Logo, para calcularmos o quanto um usuário se assemelha semanticamente a um conteúdo, utilizamos a Equação 5.

$$S5_{i,j} = \frac{10*n - \sum_{k=1}^n |A_{i,k} - B_{j,k}|}{n} \quad (5)$$

Onde: (a) $S5_{i,j}$ é o índice de semelhança semântica entre o usuário i e o conteúdo j ; (b) n é o número de domínios implantados no SES; (c) $A_{i,k}$ é o índice de interesse do usuário i pelo domínio k , retornado pelo SES; (d) $B_{j,k}$ é o índice que mede o quanto o conteúdo j se relaciona com o domínio k , retornado pelo SES.

Os passos da obtenção do Índice Baseado em Conteúdo (IBC) são descritos no Algoritmo 3.

Algoritmo 3: Geração do Índice Baseado em Conteúdo.

Entrada: Lista de todas as pessoas, Lista de todos os conteúdos

Variáveis: `aparenciaFinal[i][j]`, `aparenciaMetaDados`, `aparenciaTags`, `aparenciaLocais`, `aparenciaFrequencia`, `aparenciaSemantica` {

`lerTodasPessoas()`: Realiza a leitura dos metadados de todas as pessoas inseridas no banco de dados.

lerTodosConteúdos(): Realiza a leitura dos metadados de todos os conteúdos inseridos no banco de dados.

comparaTodasPessoas() { Faz a comparação entre as pessoas i e j buscando a semelhança entre elas e os conteúdos sob os seguintes aspectos:

comparaMetaDados(): Analisa conteúdos e pessoas da lista relacaoPessoaConteúdo verificando se relação entre eles tem Status = ConteudoFavorito.

se tiver relação com Status = ConteudoFavorito **então**

adiciona aparenciaMetadados na relação PessoaConteudo

senão

procura outro conteúdo na lista relacaoPessoaConteudo

fim se

comparaTags(): Analisa a semelhança entre a lista de *Tags* de pessoa e do conteúdo, onde *Tags* semelhantes incrementam o índice de semelhança de *Tags*.

se *Tag* da lista relacaoPessoaTag = *Tag* da lista relacaoConteudoTag **então**

adiciona aparenciaTags na relação PessoaTag e ConteudoTag

senão

procura outra *Tag* que tenha semelhança com Pessoa e Conteudo

fim se

comparaLocais(): Analisa pessoas e conteúdos nas listas relacaoPessoaLocal e relacaoContentLocal verificando se estas relações tem Status = LocalFavorito.

se Local da lista relacaoPessoaLocal = Local da lista relacaoConteudoLocal

então

adiciona aparenciaLocal na relação PessoaLocal e ConteudoLocal

senão

procura outro Local que tenha semelhança com Pessoa e Conteudo

fim se

comparaFrequencia(): Analisa, na lista de Pessoa e de Conteudo, os histogramas de frequência de aceitação ou rejeição de recomendações de pessoas e de conteúdos.

comparaSemantica(): Analisa, na lista Pessoa, a semelhançaSemantica entre pessoa e conteúdo.

}
calculaSemelhanca() { Calcula através de média ponderada a semelhança (todas as aparencias) entre a pessoa i e a pessoa j .

aparenciaFinal[i][j] = aparenciaMetaDados + aparenciaTags + aparenciaLocais +

aparenciaFrequencia + aparenciaSemantica;

}

listaBaseadaConteudo = MaioresIBC(): Da lista Baseada em Conteúdo (listas pessoa e

conteúdo), seleciona através de cálculo buscando os índices mais semelhantes entre si para compor a listaBaseadaConteúdo.

retorna listaBaseadaConteúdo: Retorna a lista Baseada em Conteúdo como resultado

}

Saída: Lista Baseada em Conteúdo.

Resultado: O resultado deste algoritmo é usado no cálculo da técnica de recomendação: Recomendação Híbrida Ubíqua, assim como acontece com o resultado do Algoritmo 2.

As características apresentadas na Recomendação Baseada em Conteúdo torna esta técnica importante para a proposta de prover o conhecimento corretamente contextualizado e no momento certo, através da recomendação correta de conteúdo personalizado. A justificativa é que no resultado desta recomendação é conhecida a lista de conteúdos recomendáveis aos usuários. Com base na semelhança entre o perfil do usuário e o conteúdo, é possível fornecer conteúdo que realmente seja de interesse do usuário e assim estimule-o à aprendizagem informal.

5.1.4 Recomendação Ubíqua

A Recomendação Ubíqua (RU) é executada em tempo real, considerado como o tempo de resposta em que não se altere o contexto da recomendação, para um determinado usuário alvo, e calcula o Índice de Recomendação Ubíquo (IRU), que representa o quanto um conteúdo é adequado ao contexto do usuário alvo.

É importante ressaltar que a RU não é executada sobre toda a base de dados, mas apenas sobre a Lista Baseada em Conteúdo e sobre a Lista Colaborativa Ponderada, garantindo assim a resposta em tempo hábil ao contexto do usuário e agregando um novo índice aos conteúdos dessas listas, o IRU. Para o cálculo do IRU, leva-se em consideração os seguintes aspectos:

(a) **Frequência do Conteúdo (S1):** Analisa os histogramas de aceitação, rejeição e visualização do conteúdo em relação ao horário considerado no contexto em que está inserido o usuário alvo. Se o conteúdo possui forte aceitação no dia da semana e no horário do contexto, isso incrementará a semelhança de frequência, no entanto se o conteúdo possui forte rejeição isso decrescerá o índice.

(b) **Histórico de Locais do Conteúdo (S2):** Analisa o histórico de relações com locais do conteúdo e sua adequação ao local considerado no contexto do usuário alvo. Se o conteúdo possui forte aceitação no local do contexto do usuário, isso incrementará a semelhança de locais, no entanto se o conteúdo possui forte rejeição isso decrescerá o índice. Além disso, analisa a semelhança entre a lista de *tags* do local do contexto e do conteúdo alvo, onde *tags* semelhantes incrementam o índice de semelhança de locais do conteúdo.

(c) **Situação do Usuário (S3):** Analisa a adequação do conteúdo em relação à velocidade em que está se locomovendo o usuário alvo. Para usuários em velocidades maiores serão priorizados conteúdos de áudio, posteriormente vídeos, e por último, textos, com menor incremento.

(d) **Situação do Dispositivo (S4):** Analisa a situação do dispositivo (percentual de bateria e velocidade da conexão com a internet) e sua adequação ao contexto para executar a visualização do conteúdo. Para conexões consideradas lentas, são priorizados conteúdos de pequeno tamanho em *bytes*, como textos, em detrimento dos vídeos, principalmente se forem longos.

O IRU do conteúdo j em relação ao contexto é calculado como sendo a média ponderada de cada uma das semelhanças descritas nos itens anteriores, conforme a Equação 6.

$$IRU_j = \frac{S1*P1 + S2*P2 + S3*P3 + S4*P4}{P1 + P2 + P3 + P4} \quad (6)$$

Onde S_i representa o nível de semelhança de determinada característica e P_i representa o peso dessa característica na avaliação. Os n maiores resultados de IRU, vinculados aos seus respectivos pares, usuário e conteúdo, são armazenados como a Lista Ubíqua (LU) de tamanho n de um usuário.

Os passos da obtenção do Índice Baseado na Ubiquidade (IBU) são descritos no Algoritmo 4.

Algoritmo 4: Geração da Lista Ubíqua.

Entrada: Lista de todas as pessoas, Lista de todos os conteúdos.

Variáveis: `adequacaoFinal[i][j]`, `adequacaoFrequencia`, `adequacaoLocais`, `adequacaoSituacao`, `adequacaoDispositivo` {

`lerTodasPessoas()`: Realiza a leitura dos metadados de todas as pessoas.

`lerTodosConteudos()`: Realiza a leitura dos metadados de todos os conteúdos.

`comparaTodasPessoas()` { Faz a comparação entre as pessoas i e j buscando a semelhança entre elas e em relação ao contexto.

`comparaFrequencia()`: Analisa os histogramas de aceitação, rejeição e visualização do conteúdo em relação ao horário considerado no contexto em que está inserido o usuário alvo. A variável `adequacaoFrequencia` é inicializada com 0.

`comparaSituacao()`: Analisa a adequação (subtipo) do conteúdo em relação à velocidade em que está se locomovendo o usuário alvo.

se `historicoVelocidadePessoa > 20` **então**

se `subtipo de RelacaoConteudo = 1 (texto), 2 (imagem), 3 (vídeo) ou 4 (página)` **então**

`adiciona adequacaoSituacao`

senão

`procura próxima pessoa na listaPessoa`

fim se

fim se

`comparaLocais()`: Verifica o histórico da relação do conteúdo com o local e faz a adequação ao local considerando o contexto da pessoa.

se `Conteúdo e Local da lista relacaoConteudoLocal = histórico de Local` **então**

se `Conteúdo da relacaoConteudoLocal tiver status = SOBRE na relacaoConteudoLocal` **então**

`adiciona adequacaoLocal`

senão

se `Conteúdo da relacaoConteudoLocal tiver status = CITADO na relacaoConteudoLocal` **então**

`adiciona adequacaoLocal`

senão

se `Conteúdo da relacaoConteudoLocal tiver status = RELACIONADO na relacaoConteudoLocal` **então**

`adiciona adequacaoLocal`

`procura outro Local que tenha semelhança com Pessoa e Conteudo`

fim se

fim se

fim se

fim se

```

comparaDispositivo(): Analisa a situação do dispositivo (percentual de bateria e
velocidade da conexão) e sua adequação ao contexto para executar a visualização do
conteúdo.
}
calculaSemelhanca() { Calcula através de média ponderada a semelhança do conteúdo em
relação ao contexto.
    adequacaoFinal[j] = adequacaoFrequencia[j] + adequacaoSituacao[j] +
    adequacaoLocal[j] + adequacaoDispositivo[j];
}
listaUbiqua = MaioresIRU(): Da listaUbiqua seleciona-se os conteúdos mais adequados
ao contexto para compor as suas listas baseadas na ubiquidade.
retorna listaUbiqua: Retorna a lista Ubiqua como resultado.
}

```

Saída: Lista Ubíqua.

Resultado: O resultado deste algoritmo é usado no cálculo da técnica de recomendação: Recomendação Híbrida Ubíqua.

Como o objetivo neste trabalho é prover o conhecimento corretamente contextualizado e no momento certo, estimulando a aprendizagem informal por meio da recomendação de conteúdos, surgiu a necessidade de implementar uma técnica de recomendação que fornecesse conteúdo adequado ao contexto do usuário, ou seja, que provesse conteúdo personalizado em qualquer lugar e a qualquer momento.

Por meio dos dados colhidos da situação do usuário e do dispositivo, é possível recomendar o conteúdo que se adeque ao contexto do usuário alvo.

5.1.5 Recomendação Híbrida Ubíqua

A Recomendação Híbrida Ubíqua (RHU) é executada instantaneamente após a geração da LU para um determinado usuário alvo, e calcula o Índice de Recomendação Híbrida (IRH). A RHU gera a Lista Híbrida Ubíqua (LHU) que é uma lista de conteúdos vinculados aos seus respectivos IRHs, sendo estes resultantes da análise da Lista Colaborativa Ponderada, da Lista Baseada em Conteúdo e da Lista Baseada na Ubiquidade. A RHU representa o quanto um conteúdo é adequado ao contexto atual do usuário alvo, confrontando os dados oriundos da LCP e da LBC, com informações do contexto do usuário, como (i) a

frequência do conteúdo, analisando os histogramas de aceitação, rejeição e visualização do conteúdo em relação ao horário e local; (ii) o histórico de locais do conteúdo, por meio do histórico de relações com locais do conteúdo e sua adequação ao local considerado no contexto do usuário alvo; (iii) a situação do usuário, analisando a adequação do conteúdo em relação à velocidade em que está se locomovendo o usuário alvo; e (iv) a situação do dispositivo (percentual de bateria e velocidade da conexão com a internet), gerando a Lista Híbrida Ubíqua (LHU).

O IRH do conteúdo j para o usuário i considerando seu contexto é calculado como sendo a média ponderada de cada um dos índices das listas descritas anteriormente, de acordo com a Equação 7.

$$IRH_{i,j} = \frac{ICP*P1 + IBC*P2 + IBU*P3}{P1 + P2 + P3} \quad (7)$$

O algoritmo 5 mostra os passos para obter o Índice de Recomendação Híbrida.

Algoritmo 5: Geração do Índice de Recomendação Híbrida.

Entrada: Lista ColaborativaPonderada, Lista Baseada em Conteúdo, Lista Ubíqua

Variáveis: relacaoPessoaConteudo, relacaoHibrida, recomendacaoTemporaria, aparenciaLocais, aparenciaFrequencia, aparenciaSemantica {

lerTodasPessoas(): Realiza a leitura dos metadados de todas as pessoas inseridas no banco de dados.

lerListaColaborativaPonderada(): Contém a lista de Colaboradores e a lista Colaborativa.

lerListaBaseadaConteudo(): Contém a lista de semelhança entre pessoas e conteúdos.

lerListaUbiqua(): Lista de relação PessoaConteudo baseado no contexto.

calculaIndiceHibrido() { Obtém, através de pesos, o resultado de uma recomendação quanto ao tipo (Colaborativa, Baseada em Conteúdo e Ubíqua).

recomendacaoTemporaria = listaColaborativaPonderada(I1)*P1() +

ListaBaseadaConteudo(I2)*P2() +

listaUbiqua(I3)*P3()/recomendacaoTemporaria.Pessoa(P1) +

recomendacaoTemporaria.Pessoa(P2) + recomendacaoTemporaria.Pessoa(P3);

}

listaHibrida = MaioresIRH(): Os maiores são vinculados aos seus respectivos pares, usuário e conteúdo, são armazenados na LHU de tamanho n de um usuário.

retorna listaHibrida: Resultado da lista que contém os conteúdos mais adequados.

}

Saída: Lista Híbrida Ubíqua

Resultado: O resultado deste algoritmo é usado no cálculo da técnica de recomendação: Recomendação Conjunta.

Os n maiores resultados de IRH, vinculados aos seus respectivos pares, usuário e conteúdo, são armazenados na LHU de tamanho n de um usuário. De acordo com os valores dos pesos $P1$, $P2$ e $P3$, determinamos o quanto a recomendação é mais colaborativa, baseada em conteúdo ou sensível ao contexto (ubíqua). Os valores desses pesos não são fixos e variam de acordo com as ações do usuário (aceitação ou rejeição) em relação a cada recomendação.

Considerando que o propósito deste trabalho é recomendar conteúdo personalizado no intuito de fornecer o conhecimento corretamente contextualizado e no momento certo e proporcionar a aprendizagem informal aos usuários, esta técnica contém os atributos necessários para prover conteúdos de forma flexível e ubíqua. Deste modo, justifica-se a implementação da técnica híbrida ubíqua, uma vez que através de sua execução é conhecido o quanto um conteúdo é adequado ao contexto atual do usuário alvo, confrontando os dados (de pessoa e de conteúdo) oriundos da LCP e da LBC, com informações do contexto do usuário.

5.1.5.1 Ajustes nos pesos das recomendações

Na seção 4.2 foi mencionada a importância dos índices (resultado do processamento do SES) para a execução das técnicas de recomendação. Então, com base nesta explanação, destacamos que no SRPC as ações do usuário em relação ao conteúdo recomendado modificam suas preferências e impactam diretamente na seleção do conteúdo para a próxima recomendação.

No entanto, mesmo tendo índices de retorno do SES, é necessário definir, na primeira recomendação de um usuário, um valor para seus respectivos pesos, desta forma ficou definido o valor igual a 5,0. Após a primeira ação do usuário no ambiente MobiLEHealth, e em seguida a execução do enriquecimento semântico, os pesos para as próximas recomendações sofrerão alterações.

Com relação ao cálculo que é realizado nos índices retornados, foi definido que o número de recomendações respondidas pelo usuário, denominado aqui de NR, também é armazenado e serve para o cálculo da adequação dos pesos, que ocorre de acordo com as Equações 8, 9 e 10.

$$P1 = \frac{P1 * NR+k * ICP}{NR+1} \quad (8)$$

$$P2 = \frac{P2 * NR+k * IBC}{NR+1} \quad (9)$$

$$P3 = \frac{P3 * NR+k * IBU}{NR+1} \quad (10)$$

O valor de k é igual a 1 se a recomendação for aceita e k é igual a -1 se a recomendação for rejeitada. Após a ação de aceitação ou rejeição, por parte do usuário alvo, o valor de NR é incrementado em 1. Assim, os pesos se ajustam automaticamente às preferências de cada usuário, personalizando assim as futuras recomendações para os mesmos.

5.1.6 Recomendação Conjunta

A Recomendação Conjunta (RC) é o resultado de todo o sistema de recomendação e fornece ao usuário opções de conteúdo de forma:

- (i) a expandir o conhecimento do usuário;
- (ii) detectar os tipos de conteúdos de seu interesse (vídeo, texto longo, texto curto, artigo científico); e
- (iii) identificar o interesse do usuário pelo conteúdo.

Desta maneira, a Recomendação Conjunta utiliza-se de técnicas de formação de grupos, priorizando assim que elementos da recomendação final não disputem pelas mesmas características do usuário. Para isso, temos que analisar todas as possibilidades de combinações na lista de recomendação híbrida. Contendo uma Lista Híbrida Ubíqua que possui n conteúdos e se deseja fazer uma recomendação de p conteúdos, o número N de combinações a ser analisado é calculado como apresentado na Equação 11.

$$N = \frac{n!}{p!(n-p)!} \quad (11)$$

O caráter fatorial de N inviabiliza a possibilidade de retornarmos essa análise em tempo real, considerado como o tempo de resposta em que não se altera o contexto da recomendação para um usuário alvo. A complexidade da análise de todas as possibilidades cresce de forma fatorial, o que justifica o uso de uma técnica aproximativa, no caso Algoritmo Genético (AG), para escolha da melhor recomendação conjunta.

Na recomendação híbrida ubíqua o ideal é recomendar um único conteúdo, entretanto, como o propósito neste trabalho é realizar uma recomendação em conjunto de 3 conteúdos, não podemos simplesmente selecionar os melhores candidatos da LRH, pois estes podem competir nas mesmas características.

Para um melhor entendimento sobre este problema, é apresentado na

Figura 6 um exemplo contendo uma lista de 10 conteúdos do domínio “Diabetes”, ordenados pelo valor do Índice de Recomendação Híbrido (IRH):

	SINTOMAS			INSULINA			ALIMENTAÇÃO			
Conteúdo	1	2	3	4	5	6	7	8	9	10
IRH	9,80	9,75	9,48	8,90	8,57	8,50	8,23	8,15	7,80	7,65

Figura 6 – Lista de Conteúdos Resultantes da Recomendação Híbrida Ubíqua

Fonte: Autoria Própria

Na Recomendação Conjunta de 03 (três) sugestões, se escolhêssemos por ordem do IRH, recomendaríamos os 03 primeiros, que consequentemente seriam 03 (três) conteúdos sobre sintomas, conforme pode ser observado na Figura 7. No entanto, seria interessante o usuário receber também conteúdos sobre aplicação de insulina e dicas de alimentação.

Conteúdo	1	2	3
IRH	9,80	9,75	9,48

Figura 7 – Recomendação Conjunta dos 03 melhores conteúdos considerando o IRH

Fonte: Autoria Própria

5.2 FUNÇÃO *FITNESS*

Considerando os critérios utilizados para a realização da recomendação, a função *fitness* pode ser expressa da seguinte maneira, conforme Equação 12:

$$Favaliacao = 0,6(fatorTempo) + 0,4(fatorTipo+fatorAutor+fatorIgualdade) \quad (12)$$

Onde:

- fatorTempo: Representa a quantidade de genes que atendem ao requisito tempo, na relação usuário x conteúdo;
- fatorTipo: Refere-se a quantidade de genes com tipo de conteúdo não repetido;
- fatorAutor: Representa a quantidade de genes com autor do conteúdo não repetido; e
- fatorIgualdade: Retorna a quantidade de genes que não são iguais.

A seguir na Figura 8 é apresentado o trecho do AG que contempla Avaliação da População e Cálculo da Função *Fitness*.

```

47 private void avaliarPopulacao(){
48
49     avaliacao = new double[tamPopulacao];
50
51     //Percorre todos os individuos da população e os avalia
52     for(int i = 0; i < tamPopulacao; i++){
53
54         int fatorTempo = 0;
55         int fatorTipo = 0;
56         int fatorAutor = 0;
57         int fatorIgualdade = 0;
58
59         int auxTipo = 0;
60         int auxAutor = 0;
61         int auxIgualdade = 0;
62
63         //Verifica quantos genes do cromossomo atendem ao fator tempo (relação usuário x conteúdo)
64         for(int j = 0; j < tamCromossomo; j++) {
65             if(populacao.get(i).get(j).getRatePerson() >= populacao.get(i).get(j).getContent().getSecondsOnline()) {
66                 fatorTempo++;
67             }
68         }
69         //Verifica quantos genes do cromossomo atendem ao fator tipo e autor (relação conteúdo x conteúdo)
70         for(int j = 0; j < tamCromossomo-1; j++) {
71             for(int k = j; k < tamCromossomo; k++) {
72                 // Verifica se existe tipos de conteúdos iguais.
73                 if(populacao.get(i).get(j).getContent().getSubtype() == populacao.get(i).get(k).getContent().getSubtype()){
74                     auxTipo++;
75                 }
76                 // Verifica se existem autores iguais
77                 if(populacao.get(i).get(j).getContent().getAuthor() == populacao.get(i).get(k).getContent().getAuthor()){
78                     auxAutor++;
79                 }
80                 // Verifica se existem conteúdos iguais
81                 if (populacao.get(i).get(j).getContent().getId() == populacao.get(i).get(k).getContent().getId()) {
82                     auxIgualdade++;
83                 }
84             }
85         }
86
87         // Calcula os fatores baseado na quantidade de repeticoes de cada fator
88         fatorTipo = tamCromossomo - auxTipo;
89         fatorAutor = tamCromossomo - auxAutor;
90         fatorIgualdade = tamCromossomo - auxIgualdade;
91
92         // Função Fitness
93         avaliacao[i] = 0.6 * (fatorTempo) + 0.4 * (fatorTipo + fatorAutor + fatorIgualdade);
94
95         // Armazena o melhor individuo até o momento
96         if(avaliacao[i] > melhorAvaliacao){
97             melhorAvaliacao = avaliacao[i];
98             melhorRepresentacao = populacao.get(i);
99         }
100     }
101 }

```

Figura 8 – Código-fonte da Avaliação da População e da Função Fitness

Fonte: Autoria Própria

Conforme código acima, após a realização do cálculo da Função *Fitness*, é feita a avaliação sobre o melhor indivíduo escolhido. Desta forma, fica sendo representado como o melhor conteúdo a ser recomendado.

5.3 REPRESENTAÇÃO DO CROMOSSOMO

Nos cromossomos de uma população, os genes podem ser representados de várias formas, porém as mais comuns são representações com números binários, inteiros ou reais (ROTHLAUF, 2006). Devido às características do problema proposto neste projeto, optou-se por utilizar uma classe com a representação do cromossomo definida com tamanho = 3 (conteúdos), pois desta forma pôde-se obter uma solução mais próxima da ótima, proporcionando, assim, que o AG continue evoluindo em termos de função *fitness*. Já o critério de parada definido foi o número de gerações, onde se adotou 1000 gerações.

5.4 MODELO DO AG UTILIZADO

A justificativa para a utilização do AG se deu pelo fato de ser uma técnica heurística e para solucionar o problema da recomendação de conteúdos que tenham as mesmas características ou subtipo. Visando solucionar esse problema, é utilizado o AG para selecionar o conjunto de conteúdos que se adeque às necessidades do usuário, de modo que atinja uma solução aceitável dentro de um tempo hábil. Neste sentido, a abordagem proposta neste trabalho é recomendar ao usuário um conjunto com três conteúdos diversificados.

A abordagem de um cromossomo (conjunto) contendo três conteúdos foi utilizada porque, no final da execução do AG, será indicado um cromossomo como o indivíduo mais apto, ou seja, como a melhor solução levando-se em consideração os critérios da função *fitness*. Portanto, não seria interessante recomendar apenas um conteúdo, mas sim um

conjunto dentre o qual o usuário portador de doença crônica pudesse escolher aquele que lhe fosse mais conveniente.

Diante do contexto apresentado, o modelo de AG foi desenvolvido com as seguintes características:

(a) **Gene:** Cada gene é representado por uma recomendação de conteúdo para o usuário alvo, escolhidos a partir da LHU;

(b) **Cromossomo (indivíduo):** É um conjunto de genes que representam uma possível recomendação conjunta;

(c) **População Inicial:** É gerada a partir da LHU, escolhendo-se aleatoriamente recomendações de conteúdo que serão os genes que formarão cada indivíduo;

(d) **Função *Fitness*:** Avalia um cromossomo ou indivíduo, considerando os critérios de IRH, evitando as características conflitantes (subtipo, autor, tempo), e reduzindo a avaliação dos cromossomos com defeitos genéticos (genes repetidos);

(e) **Cruzamento:** Para melhorar o processo, foi utilizado o conceito de dominância entre os genes, onde um gene (recomendação) com maior *rating* será dominante sobre um de menor;

(f) **Seleção:** Os critérios de seleção foram estabelecidos com base em Estado Estacionário e Elitismo, onde metade da população (melhor avaliada) sobrevive e gera mais uma metade de população nova (nova geração);

(g) **Mutação:** A mutação se dá pela troca de posições de genes de um mesmo cromossomo, evitando assim a amarração em falsos máximo da função *fitness*.

5.5 TECNOLOGIAS UTILIZADAS

Para desenvolver, modelar e documentar o SRPC foram utilizadas as seguintes ferramentas e tecnologias:

Eclipse⁴: É um IDE - *Integrated Development Environment* (Ambiente de Desenvolvimento Integrado) - para desenvolvimento Java, porém que suporta outras linguagens a partir de *plugins* como C/C++, PHP (*Hypertext Preprocessor*), entre outras. Ele foi feito em Java e segue o modelo *open source* de desenvolvimento de software.

⁴ <https://eclipse.org/ide/>

Java⁵: É uma linguagem de programação e plataforma computacional lançada pela primeira vez pela Sun Microsystems em 1995.

PostgreSQL (versão 9.3)⁶: É um sistema de gerenciamento de banco de dados objeto-relacional (ORDBMS) com base em POSTGRES, Versão 4.2 , desenvolvido na Universidade da Califórnia em Berkeley Computer Departamento de Ciência. POSTGRES é pioneira em muitos conceitos que só se tornaram disponíveis em alguns sistemas de banco de dados comerciais muito mais tarde.

Subversion (SVN)⁷: É destinado a integrar o *Subversion* sistema (SVN) de controle de versão com a plataforma Eclipse. Usando o plug-in *Subversive*, você pode trabalhar com projetos armazenados em repositórios *Subversion* diretamente a partir do trabalho do Eclipse de uma forma similar de trabalhar com outros provedores de controle de versão do Eclipse, como CVS e Git.

Oracle Java Persistence API (ou simplesmente JPA)⁸: O Java Persistence API (*Application Programming Interface*) fornece um modelo de persistência POJO para mapeamento objeto-relacional. A API Java Persistence foi desenvolvido pelo grupo de peritos software EJB 3.0 como parte do JSR 220, mas seu uso não se limita aos componentes de software EJB. Ele também pode ser usado diretamente por aplicações Web e clientes de aplicativos, e até mesmo fora da plataforma Java EE, por exemplo, em aplicações Java SE.

Microsoft Visio⁹: É um aplicativo gráfico e de desenho que ajuda você a visualizar, explorar e comunicar informações complexas. Com o Visio, é possível transformar textos e tabelas complicados e de difícil entendimento em diagramas do Visio que comunicam rapidamente as informações. Além disso, ele fornece formas e modelos modernos para um conjunto diverso de necessidades de criação de diagramas, incluindo gerenciamento de TI, modelagem de processos, construção e arquitetura, design de interface do usuário, gestão de recursos humanos, gerenciamento de projetos e muito mais.

Mendeley¹⁰: Mendeley é um gerenciador de referência livre e rede acadêmica social. Além disso, ele é construído para trabalhar no desktop, Web e seu dispositivo iOS, o que lhe permite sincronizar através de dispositivos e acessar sua biblioteca onde você estiver.

⁵ https://www.java.com/pt_BR/download/faq/whatis_java.xml

⁶ <http://www.postgresql.org/docs/9.3/static/intro-what.html>

⁷ <http://eclipse.org/subversive/>

⁸ <http://www.oracle.com/technetwork/java/javaee/tech/persistence-jsp-140049.html>

⁹ https://support.office.com/pt-br/article/Tarefas-b%C3%A1sicas-no-Visio-2010-2bfdf03f-4cb1-4dc5-a2a4-c0494f37e544#__toc254806997

¹⁰ <http://www.mendeley.com/>

6 VALIDAÇÃO DO SRPC

Esta pesquisa teve seus experimentos validados e os resultados obtidos se mostraram condizentes com o que se propõe até o momento. Nas próximas subseções, serão apresentados os experimentos realizados em um ambiente simulado, a validação e os resultados da execução do SRPC desenvolvido.

6.1 ESTRUTURAÇÃO DOS EXPERIMENTOS

Nos experimentos, após a realização da recomendação híbrida ubíqua, o resultado obtido foi processado pela recomendação conjunta, na busca por relações entre os seus itens e o interesse do usuário, gerando um conjunto de conteúdos finais a serem recomendados ao usuário. O referido conjunto é formado com o objetivo de buscar a diversidade da recomendação. Desta forma, com base na lista híbrida ubíqua, pode-se obter o número de recomendações possíveis através de um cálculo fatorial, conforme já foi mostrado na Equação 11 da Subseção 5.1.6. Nos experimentos obteve-se uma Lista Híbrida Ubíqua, onde resultou $n = 120$ (quantidade de conteúdos a serem recomendados).

Tabela 2 – Resultado da Lista Híbrida Ubíqua

Conteúdo	1	2	3	4	5	...	120
IRH (Índice de Recomendação Híbrida)	9,80	9,75	9,68	9,60	9,57	...	5,90

Fonte: Autoria Própria.

De posse dos conteúdos da lista Híbrida Ubíqua, realizou-se uma recomendação conjunta de conteúdos de tamanho $p = 3$, onde p representa o cromossomo melhor avaliado pela função *fitness*, ou seja, em p temos a seleção dos 3 (três) melhores conteúdos avaliados, conforme pode-se observar na tabela a seguir.

Tabela 3 – Recomendação Conjunta (cromossomo melhor avaliado pela função *fitness*)

Conteúdo	5	76	1
IRH (Índice de Recomendação Híbrida)	9,57	9,38	9,80

Fonte: Autoria Própria.

O resultado da recomendação conjunta, mostrado na Tabela 3, teve como critérios a soma dos tempos, repetições de autores, subtipo, e defeitos genéticos (conteúdos repetidos). Estes critérios foram definidos na função *fitness* que prioriza principalmente a diversidade, evitando assim que na lista final apareçam autores repetidos, ou apenas um subtipo de conteúdo (vídeo, texto ou áudio) ou mesmo que a soma dos tempos totais ultrapassem a quantidade do que é característico do usuário aceitar em um determinado intervalo de tempo. Dessa forma, objetivou-se alcançar uma maior aceitação das recomendações realizadas.

6.2 SIMULAÇÃO

Para a validação dos experimentos foram definidos dois domínios (Diabetes e Esclerose Lateral Amiotrófica - ELA) e realizada a criação de dados fictícios da instância da classe *Person*. Em relação à classe *Location* foram utilizados nomes de cidades reais e sobre a classe *Content* foram utilizados conteúdos (sites) sobre os domínios citados e sobre assuntos diversos. A lista destes sites pode ser consultada no Apêndice A. Os dados das relações e históricos das classes básicas 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, preenchendo alguns de seus campos e servindo para outros cálculos. O gerador funciona aleatoriamente, mas com algumas variáveis direcionadas, garantindo as características desejadas nos históricos das instâncias das classes básicas.

Na representação da amostragem, foram inseridos dados instanciando-se as classes básicas (*person*, *content* e *location*) de forma que 1/3 (um terço) de cada uma delas assumissem características importantes de um dos domínios. Também instanciou-se 1/3 (um terço) com instâncias sem domínio definido, totalizando assim três segmentos instanciados.

Nas simulações e nas análises dos dados em cada caso, manipulou-se as classes *Person*, e as escolhas de *Content* e *Location* da seguinte forma:

a) *Person*: As instâncias desta classe foram alteradas para mostrar as características desejadas quanto à idade e ao sexo. Através dos dados do Instituto Brasileiro de Geografia e Estatística (IBGE), definiu-se as distribuições das características da classe *Person*. Desta forma, as Tabelas 4 e 5 apresentam estes atributos.

Tabela 4 – Distribuição do atributo idade

Faixa de Idade	Percentual
10-24 anos	17,80%
25-39 anos	32,51%
55-69 anos	30,55%
55-69 anos	21,91%
70 acima	5,03%
Total	100%

Fonte: Autoria Própria.

Tabela 5 – Distribuição do atributo sexo

Sexo	Percentual
Masculino	47,90%
Feminino	52,10%
Total	100%

Fonte: Autoria Própria.

b) *Content e Location*: Tiveram suas características definidas para se adequar igualmente aos domínios (segmentos) selecionados, sendo assim a

Tabela 6 apresenta a divisão dos segmentos.

Tabela 6 – Distribuição dos segmentos

Domínios (Segmentos)	Divisão
Diabetes	1/3
Esclerose Lateral Amiotrófica	1/3
Sem definição ou Diversos	1/3

Fonte: Autoria Própria.

c) *Relation*: As relações *RelationPersonPerson*, *RelationPersonContent*, *RelationPersonLocation* e *RelationContentLocations* foram definidas no intuito de simular todas as possibilidades de disparo de contexto (área da saúde) com base nas proporções. Estas distribuições estão apresentadas nas Tabelas 7, 8, 9 e 10.

Tabela 7 – Distribuição das relações entre usuários

Relação	Status	Percentual	Número de Relações
<i>RelationPersonPerson</i>	Início de Amizade	60%	12-25
	Solicitações de Amizade	10%	2-5
	Rejeições de Amizade	20%	5-10
	Exclusões de Amizade	10%	5-10

Fonte: Autoria Própria.

Tabela 8 – Distribuição das relações entre usuário e conteúdo

Relação	Status	Percentual	Número de Relações
<i>RelationPersonContent</i>	Adicionou aos Favoritos	25%	5-10
	Visualização de Conteúdo	70%	15-30
	Rejeição de Conteúdo	5%	5-10
	Avaliação de Conteúdo	10%	5-10

Fonte: Autoria Própria.

Tabela 9 – Distribuição das relações entre usuário e local

Relação	Status	Percentual	Número de Relações
<i>RelationPersonLocation</i>	Adicionou aos Favoritos	20%	5-10
	Presença no Local	60%	15-30
	Avaliação de Local	20%	10-20

Fonte: Autoria Própria.

Tabela 10 – Distribuição das relações entre conteúdo e local

Relação	Status	Percentual	Número de Relações
<i>RelationContentLocation</i>	Sobre o Local	10%	2-5
	Cita o Local	20%	7-15
	Relacionado ao Local	70%	15-30

Fonte: Autoria Própria.

Objetivando não comprometer o resultado das recomendações, apenas estes parâmetros foram alterados no intuito de simular uma situação real nas recomendações.

6.3 ANÁLISE DOS RESULTADOS DA SIMULAÇÃO

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 (REIS, 2012). Neste sentido, foi possível obter o número de ocorrências enquadradas nas categorias vinculadas à aceitação e rejeição, utilizando para isso conteúdos considerados Verdadeiro-Positivo (VP), referentes a conteúdos “recomendados” e “preferidos” pelos usuários, e Falso-Positivo (FP), considerados como “recomendados” e “não preferidos”.

Na análise dos resultados foi utilizada a aplicação da métrica *Precision*, que tem a tarefa de medir a probabilidade de um item recomendado ser relevante (REIS, 2012). A referida métrica é calculada através da Equação 13:

$$Precision = \frac{n^{\circ} \text{ de VP}}{n^{\circ} \text{ de VP} + n^{\circ} \text{ de FP}} \quad (13)$$

A *Precision* foi escolhida com base em suas características, pois atendem ao que se propõe no sistema de recomendação personalizada. Conforme se observa na Equação 13, não há possibilidade de se fazer análise em conteúdos considerados Negativos (Verdadeiros ou Falsos). No SRPC, o número de conteúdos Verdadeiros e Falsos é bem maior que o tamanho da recomendação final e isso faz o número de Negativos ser alto também. Diante disso, justifica-se a escolha da métrica *Precision*, que não utiliza conteúdos Negativos, descartando-se *False Positive Rate* e *Recall*. Estas são outras métricas encontradas em (REIS, 2012). A análise dos resultados através da métrica *Precision* foi realizada em dois cenários, conforme apresentado nas Tabelas 11 e 12.

a) Em um contexto neutro, foram solicitadas pelo sistema recomendações para usuários que têm históricos voltados a cada um dos dois domínios instalados no sistema.

Tabela 11 – Resultado da simulação com contexto neutro e usuário de perfil definido.

Número de Recomendações	Quantidade de Conteúdos	Verdadeiros Positivos (VP)	Falsos Positivos (FP)
40	21	738	102

Fonte: Aatoria Própria.

Aplicando a métrica *Precision*, temos:

$$Precision = \frac{n^{\circ} \text{ de VP}}{n^{\circ} \text{ de VP} + n^{\circ} \text{ de FP}} = \frac{738}{738 + 102} = 0,8785 \text{ ou } 87,85\%$$

b) Em contextos voltados a cada um dos dois domínios instalados no sistema, foram solicitadas pelo sistema recomendações para usuários que têm um histórico sem domínio definido.

Tabela 12 – Resultado da simulação com contexto definido e usuário de perfil neutro.

Número de Recomendações	Quantidade de Conteúdos	Verdadeiros Positivos (VP)	Falsos Positivos (FP)
40	21	834	06

Fonte: Aatoria Própria.

Aplicando a métrica *Precision*, temos:

$$Precision = \frac{n^{\circ} \text{ de VP}}{n^{\circ} \text{ de VP} + n^{\circ} \text{ de FP}} = \frac{834}{834 + 06} = 0,9928 \text{ ou } 99,28\%$$

Visando analisar a eficiência da recomendação por camada, que foi a forma desenvolvida para se chegar ao propósito do trabalho, é necessário verificar os dados das recomendações intermediárias através da utilização da métrica *Precision*. Abaixo são apresentados os resultados:

a) Lista de Colaboradores: Com 1200 recomendações obteve-se: 1200 Verdadeiro-Positivo (VP) e “zero” Falso-Positivo (FP), resultando em um percentual de 100%.

b) Lista Colaborativa Ponderada: Com 1200 recomendações obteve-se: 965 Verdadeiro-Positivo (VP) e 235 Falso-Positivo (FP), resultando em um percentual de 80,42%.

c) Lista Baseada em Conteúdo: Com 1200 recomendações obteve-se: 1200 Verdadeiro-Positivo (VP) e “zero” Falso-Positivo (FP), resultando em um percentual de 100%.

d) Lista Ubíqua: Com 3600 recomendações obteve-se: 3365 Verdadeiro-Positivo (VP) e 235 Falso-Positivo (FP), resultando assim em um percentual de 93,47%.

Embora os experimentos tenham sido realizados em uma base de dados simulados, a validação, através da métrica *Precision*, apresentou resultados satisfatórios, superiores a 80%. Como a pesquisa e o desenvolvimento deste trabalho vêm sendo realizado de forma incremental, os percentuais apresentados podem ser melhorados se aplicados em um ambiente com um maior número de relações e validados com usuários reais. Desta forma pode-se aplicar outras métricas a fim de assegurar o funcionamento e a qualidade do sistema de recomendação proposto.

7 CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS

Neste trabalho foi apresentado um mecanismo de recomendação personalizada de conteúdos apoiado por um modelo para aplicação de aprendizagem informal no contexto da Saúde 2.0. O MobiLEHealth contempla a recomendação personalizada de conteúdos de saúde, voltados para usuários portadores de doenças crônicas, colocando o usuário como agente ativo e responsável pelo seu tratamento e cuidados relacionados à sua saúde.

Através do uso de tecnologias ubíquas, o sistema implementado para apoiar o ambiente MobiLEHealth permite o monitoramento do dia-a-dia do indivíduo, integrando dados coletados a partir de sua interação com ferramentas da Web 2.0 com dados fornecidos diretamente pelos usuários.

Como contribuição principal deste trabalho pode-se destacar o desenvolvimento de um mecanismo de recomendação que tem como propósito prover conteúdos relevantes às pessoas portadoras de doenças crônicas considerando o perfil dos usuários, a sensibilidade ao contexto e a ubiquidade.

Outro ponto a ser destacado neste trabalho é que foi possível verificar a melhoria nas taxas de acertos na recomendação, confirmando a Hipótese H0, apresentada na Seção 1.3. O problema foi solucionado por meio do mecanismo de recomendação personalizada de conteúdo, que apresenta em sua arquitetura a combinação de diferentes técnicas de recomendação e um algoritmo genético, permitindo, desta forma, recomendar de forma eficaz conteúdos de saúde em consonância com os perfis dos usuários.

7.1 TRABALHOS FUTUROS

Embora se tenha alcançado contribuições significativas com o desenvolvimento deste trabalho, destacam-se como trabalhos futuros, os seguintes pontos:

- Realizar, por meio do ambiente de aprendizagem MobiLEHealth, 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.

- Aplicar outras métricas: Através da 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 nesta dissertação.

REFERÊNCIAS

- ACOSTA, O. C.; REATEGUI, E. B. Recomendação de Conteúdo em Ambientes de Aprendizagem Baseados em Questionamento. *Revista Novas Tecnologias na Educação - RENOTE*, v. 10, n. 1, p. 1–9, 2012.
- ÁVILA, C. M. O. Um Sistema de Recuperação de Artigos Científicos Baseado em Consultas por Exemplo. [s.l.] UNIVERSIDADE CATÓLICA DE PELOTAS, 2008.
- BARCELLOS, C. D. et al. Sistema de Recomendação Acadêmico para Apoio a Aprendizagem. *RENOTE – Revista Novas Tecnologias na Educação*, v. 5, n. 2, 2007.
- CAZELLA, S. C.; NUNES, M.; REATEGUI, E. A Ciência da Opinião: Estado da arte em Sistemas de Recomendação. *XXX Congresso da SBC Jornada de Atualização de Informática*, p. 161–216, 2010.
- CHILDS, S. Developing health website quality assessment guidelines for the voluntary sector: outcomes from the Judge Project. *Health information and libraries journal*, v. 21, p. 14–26, out. 2004.
- COELLO, J. M. A.; YUMING, Y.; TOBAR, C. M. A Memory-based Collaborative Filtering Algorithm for Recommending Semantic Web Services. *Latin America Transactions, IEEE (Revista IEEE America Latina)*, v. 11, n. 2, p. 795–801, 2013.
- COSTA, A. A. L. et al. Recomendação personalizada de conteúdo para apoiar a aprendizagem informal no contexto da saúde. *Revista Novas Tecnologias na Educação - RENOTE*, v. 12, n. 1, 2014a.
- COSTA, A. A. L. et al. Componente de recomendação conjunta baseado em algoritmo genético para apoio a um sistema de recomendação personalizada de conteúdo. *Proceedings XLVI Simpósio Brasileiro de Pesquisa Operacional (SPBO)*, 2014b.
- COSTA, F. S. D. *PerSon: Um Modelo Semântico para Personalização no Âmbito das Redes Sociais*. Mossoró-RN: Universidade do Estado do Rio Grande do Norte - UERN, 2013.
- CROSS, J. Informal Learning in a Nutshell. Disponível em: <<http://www.jaycross.com/wp/2012/02/informal-learning-in-a-nutshell/>>. Acesso em: 9 jan. 2015.
- DELLA MEA, V. What is e-health (2): the death of telemedicine? *Journal of medical Internet research*, v. 3, n. 2, p. E22, 22 jan. 2001.
- DESPOTAKIS, D. et al. Capturing the semantics of individual viewpoints on social signals in interpersonal communication. *Journal of Web Semantics, Special Issue on Personal and Social Semantic Web*, 2011.
- DEY, A. K.; ABOWD, G. D. Towards a Better Understanding of Context and Context-Awareness. *Handheld and ubiquitous computing*. Springer Berlin Heidelberg, v. 40, n. 3, p. 304–307, 1999.

EISEN, A. Amyotrophic lateral sclerosis: A 40-year personal perspective. *Journal of clinical neuroscience : official journal of the Neurosurgical Society of Australasia*, v. 16, n. 4, p. 505–512, 2009.

FERNANDEZ-LUQUE, L. et al. Personalized health applications in the Web 2.0: the emergence of a new approach. *Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. Anais...Buenos Aires, Argentina: IEEE, 2010. Disponível em:
<<http://ieeexplore.ieee.org/ielx5/5608545/5625939/05628087.pdf?tp=&arnumber=5628087&isnumber=5625939>>

FERREIRA, V. H.; RAABE, A. L. LORSys - Um Sistema de Recomendação de Objetos de Aprendizagem SCORM. *RENOTE - Revista Novas Tecnologias na Educação*, v. 8, n. 2, p. 9, 2010.

GOLDBERG, D. E.; HOLLAND, J. H. *Genetic Algorithms and Machine Learning*. Machine Learning, Springer, Lecture Notes in Computer Science. v. 3, n. 2, p. 95–99, 1988.

HERLOCKER, J. L. *Understanding and improving automated collaborative filtering systems*. Minnesota: University of Minnesota, 2000.

HOLLAND, J. H. *Adaptation in Natural and Artificial Systems: An introductory analysis with applications to biology, control, and artificial intelligence*. Oxford, England: U Michigan Press, 1975. v. Ann Arbor. 1–228

HUGHES, B.; JOSHI, I.; WAREHAM, J. Health 2.0 and Medicine 2.0: tensions and controversies in the field. *Journal of medical Internet research*, v. 10, n. 3, 6 jan. 2008.

IBGE. *Indicadores Sociodemográficos e de Saúde no Brasil*. Pesquisa, no 25. Rio de Janeiro: Instituto Brasileiro de Geografia e Estatística. Disponível em:
http://www.ibge.gov.br/home/estatistica/populacao/indic_sociosaude/2009/indicsaude.pdf. 2009.

ISTEPANIAN, R. S. H.; LAXMINARAYAN, S.; PATTICHIS, C. S. *M-Health: Emerging Mobile Health Systems*. New Jersey: Springer Verlag NY, edition 2006 (16-november-2005), 2006. p. 654

JIUGEN, Y.; RUONAN, X.; XIAOQIANG, H. Constructing informal learning mode based on social software. *6th International Conference on Computer Science & Education (ICCSE)*, IEEE., p. 1227–1230, 2011.

KARANASIOS, S. et al. Making sense of digital traces: An activity theory driven ontological approach. *Journal of the American Society for Information Science and Technology*, v. 64, n. 12, p. 2452–2467, 2013.

LI, M. et al. Personalization in Context-aware Ubiquitous Learning-Log System. *Seventh International Conference on Wireless, Mobile and Ubiquitous Technology in Education*. Anais...Takamatsu, Kagawa, Japan: IEEE, mar. 2012. Disponível em:
<<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6185078>>. Acesso em: 23 maio. 2014

LICHTNOW, D.; OLIVEIRA, J. P. M. DE. Relato e considerações sobre o desenvolvimento de uma ontologia para avaliação de sites da área de saúde. *Cadernos de Informática - UFRGS*, v. 4, n. 1, p. 7–46, 2009.

LINDEN, R. Algoritmos Genéticos - Uma importante ferramenta da Inteligência Computacional. 2^a. ed. Rio de Janeiro: Brasport, 2008.

LUSTOSA, M. A.; ALCAIRES, J.; COSTA, J. C. DA. Adesão do paciente ao tratamento no Hospital Geral. *Revista SBPH, Sociedade Brasileira de Psicologia Hospitalar.*, v. 14, n. 2, p. 27–49, 2011.

MACÁRIO FILHO, V. e-Recommendier : Sistema Inteligente de Recomendação para Comércio Eletrônico. Universidade de Pernambuco, p. 47, 2006.

MARTINS JÚNIOR, H. N. et al. Sistema de Recomendação Híbrido para Bibliotecas Digitais que Suportam o Protocolo OAI-PMH. In: XXII Simpósio Brasileiro de Informática na Educação, SBIE, p. 140–149, 2011.

MENDES NETO, F. M. et al. Content's Personalized Recommendation for Implementing Ubiquitous Learning in Health 2.0. *Revista IEEE América Latina*, v. 12, n. 8, 2014a.

MENDES NETO, F. M. et al. An approach for recommending personalized contents for homecare users in the context of health 2.0. *Proceedings of the 7th Euro American Conference on Telematics and Information Systems - EATIS. Anais...Valparaíso, Chile: ACM*, 2014b

MOHAMMED, S.; FIAIDHI, J. Ubiquitous Health and Medical Informatics: O Ubiquity 2.0 Trend and Beyond. First ed. Hershey PA: Medical Information Science Reference, 2010. p. 1–728

MOODLE. Site oficial do Moodle, 2012. Disponível em: <http://docs.moodle.org/21/en/About_Moodle>. Acesso em: 8 jan. 2015.

MOORE, P. et al. Intelligent Context for Personalised M-Learning. *Complex, Intelligent and Software Intensive Systems*, 2009. *CISIS '09. International Conference on*, p. 247 – 254, 2009.

MOORE, P.; HU, B. “Intelligent Context” for Personalized Mobile Learning. In: CABALLÉ, S. et al. (Eds.). . *Architectures for Distributed and Complex M-Learning Systems: Applying Intelligent Technologies*. Open University of Catalonia, Spain: IGI Global, 2010. p. 236–238.

MOORE, P.; HU, B.; WAN, J. Smart-Context: A Context Ontology for Pervasive Mobile Computing. *The Computer Journal*. Oxford University Press on behalf of The British Computer Society, v. 53, n. 2, p. 191–207, 4 mar. 2008.

MORAES NETO, M. A. DE. Estratégia Híbrida para Recomendação Personalizada Utilizando o Guia de Programação Eletrônico. Fortaleza-CE: Universidade Estadual do Ceará – UECE, 2011.

MOREIRA, J. D. C. et al. Um sistema de enriquecimento semântico de perfil de usuário baseado em traços digitais para apoio à aprendizagem informal no contexto da saúde. *Revista Novas Tecnologias na Educação - RENOTE*, v. 12, n. 1, 2014.

MOREIRA, J. D. C. Enriquecimento semântico de perfil de usuário para apoio a um modelo de aprendizagem informal no contexto da saúde. Mossoró-RN: Universidade do Estado do Rio Grande do Norte - UERN e Universidade Federal Rural do Semi-Árido-UFERSA, 2014.

OLIVEIRA, J. P. M. DE; FLEISCHMANN, A. M. P. Relato sobre o desenvolvimento de modelos para obtenção automática do conteúdo de sites sobre saúde. *Cadernos de Informática*, 2009. Disponível em: <<http://seer.ufrgs.br/cadernosdeinformatica/article/view/5v4n1p47-104>>. Acesso em: 31 maio. 2013

PETROLI NETO, S. Computação Evolutiva: desvendando os algoritmos genéticos. *Revista Ubiquidade*, v. 1, n. 1, p. 34–45, 2011.

REATEGUI, E.; CAZELLA, S. C. Sistemas de Recomendação. XXV Congresso da Sociedade Brasileira de Computação A Universalidade da Computação Um Agente de Inovação e Conhecimento, p. 306–348, 2005.

REIS, L. F. M. DOS. Sistema de Recomendação Baseado em Conhecimento. Dissertação de Mestrado, p. 110, 2012.

ROCHA, T. M. DA. Hybrid Rec - Protótipo de um Sistema de Recomendação utilizando Filtragem Híbrida. Canoas-RS: Universidade Luterana do Brasil, 2007.

ROTHLAUF, F. Representations for Genetic and Evolutionary Algorithms. 2. ed. Berlin Heidelberg: Springer, 2006. p. 334

SACCOL, A.; SCHLEMMER, E.; BARBOSA, J. m-learning e u-learning - Novas perspectivas da aprendizagem móvel e ubíqua. Person ed. São Paulo: [s.n.].

SANOU. ICTFactsFigures. Disponível em: <<http://www.itu.int/en/ITU-D/Statistics/Documents/facts/ICTFactsFigures2013.pdf>>. Acesso em: 1 ago. 2013.

SCORM. ADL SCORM. Site Oficial do SCORM, 2013. Disponível em: <<http://www.adlnet.gov/capabilities/scorm>>. Acesso em: 8 jan. 2015.

SILVA, L. C. N. MobiLE–Um Ambiente Multiagente de Aprendizagem Móvel para Apoiar a Recomendação Ubíqua de Objetos de Aprendizagem. Mossoró-RN: Universidade do Estado do Rio Grande do Norte - UERN e Universidade Federal Rural do Semi-Árido-UFERSA, 2012.

STUMME, G. Using ontologies and formal concept analysis for organizing business knowledge. In: *Wissensmanagement mit Referenzmodellen*. Berlin, Heidelberg: Springer, 2002. p. 163–174.

SU, C.-J.; WU, C.-Y. JADE implemented mobile multi-agent based, distributed information platform for pervasive health care monitoring. *Applied Soft Computing*, v. 11, n. 1, p. 315–325, jan. 2011.

THAKKER, D.; DESPOTAKIS, D.; DIMITROVA, V. Taming digital traces for informal learning: a semantic-driven approach. *Proceedings of the 7th European Conference on Technology Enhanced Learning*, p. 348–362, 2012.

TORRES, R. *Personalização na Internet: como descobrir os hábitos de consumo de seus clientes, fidelizá-los e aumentar o lucro de seu negócio*. São Paulo: Novatec, 2004. p. 159

VIEIRA, F.; NUNES, M. DICA: Sistema de Recomendação de Objetos de Aprendizagem Baseado em Conteúdo. *Scientia Plena*, v. 8, p. 1–10, 2012.

WEITZEL, L.; PALAZZO, J.; OLIVEIRA, M. DE. Sistemas de recomendação de informação em saúde baseado no perfil do usuário. *Journal of Health Informatics*, p. 1–7, 2010.

WHO, W. H. O. Diabetes. Disponível em:
<<http://www.who.int/mediacentre/factsheets/fs312/es/>>. Acesso em: 28 ago. 2014.

WORLD HEALTH ORGANIZATION. Preventing chronic diseases: a vital investment. Disponível em:
<<http://scholar.google.com/scholar?hl=en&btnG=Search&q=intitle:Preventing+Chronic+Diseases:+A+Vital+Investment#3>>. Acesso em: 10 set. 2014.

YAMANAKA, K. et al. Astrocytes as determinants of disease progression in inherited amyotrophic lateral sclerosis. *Nature neuroscience*, v. 11, n. 3, p. 251–253, 2008.

YAU, J. Y. K.; JOY, M. A context-aware personalized m-learning application based on m-learning preferences 6th IEEE International Conference on Wireless, Mobile and Ubiquitous Technologies in Education (WMUTE). *Anais...Reino Unido: IEEE Computer Society*, 2010

YORK, A. M.; NORDENGREN, F. R. *Cases on Formal and Informal E-Learning Environments*. Hershey PA: IGI Global, 2013. p. 292–313

ZINI, E. D. O. C. *Genetic Algorithm Specializing in Troubleshooting and Continuous Variables Highly Restricted*. São Paulo-SP: Universidade Estadual Paulista – UNESP, 2009.

APÊNDICE A – LISTA DE CONTEÚDOS DO SRPC

Lista de Conteúdos (sites de saúde: **Diabetes, ELA e diversos**) usados na simulação do Sistema de Recomendação Personalizada de Conteúdo (SRPC):

Site	URL
01	http://www.minhavidacom.br/saude/temas/esclerose-lateral-amiotrofica#top1
02	http://www.abrela.org.br/
03	http://www.abcdasaude.com.br/artigo.php?184
04	https://www.tudosobreela.com.br/home/index.asp
05	http://academiadadieta.blogspot.com.br/2012/08/terapia-nutricional-na-esclerose.html
06	http://www.cordcell.com.br/noticias/primeiro-caso-sucesso-esclerose-lateral-amiotrofica-com-celulas-tronco
07	http://www.arela-rs.org.br/
08	http://www.todosporela.org.br/mibrela.html
09	http://globoTV.globo.com/rede-globo/bem-estar/v/entenda-como-e-a-evolucao-da-esclerose-lateral-amiotrofica/2681124/
10	http://www.scielo.org/cgi-bin/wxis.exe/applications/scielo-org/iah/?IsisScript=iah/iah.xis&base=article%5Edart.org&nextAction=lnk&lang=p&indexSearch=&exprSearch=ESCLEROSE%20LATERAL%20AMIOTROFICA
11	http://saude.ig.com.br/minhasaude/enciclopedia/esclerose-lateral-amiotrofica/ref1238131523915.html
12	http://www.istoe.com.br/reportagens/81748_O+DRAMATICO+DIAGNOSTICO+DA+ELA
13	http://www.pacemakerusers.com/index.php/category/news/item/181-marca-passo-para-esclerose-lateral-amiotrofica
14	http://www.alterosa.com.br/app/divinopolis/videos/2014/02/17/interna-videos-dv,3264/alo-doutor-parte-1-esclerose-lateral-amiotrofica.shtml#.U0VQVlemXJs
15	http://www.aph.org.br/revista/index.php/aph/article/viewFile/109/177
16	http://revistacorpore.com.br/noticias/medicina/campanha-para-divulgar-informacoes-sobre-a-esclerose-lateral-amiotrofica-
17	http://jcrs.uol.com.br/site/noticia.php?codn=135519
18	http://www.pergamum.univale.br/pergamum/tcc/Sintomatologiaetratamentofisioterapiapeuticaesclerose lateral amiotrofica revisa bibliografica.pdf
19	http://www.radiocoracao.org/multimedia/videos/portador-de-esclerose-lateral-amiotrofica-lanca-livro
20	http://www.actafisiatrica.org.br/detalhe_artigo.asp?id=141
21	http://www.estadao.com.br/noticias/vidae,cientistas-identificam-novo-fator-

	genetico-para-esclerose-lateral-amiotrofica,600951,0.htm
22	http://www.homefisio.com.br/t_esclerose_lateral.html
23	http://api.ning.com/files/BaXT*qq6YEZlhKXLacLdFB7NNYSW1A0SHje9T9Mbk uIRCAnnknyggkzWSqJ5EwiMo7kaaat99fjFO*TbGFMKOeezIOd07NAZ/elaresumo.pdf
24	http://www.ciencia-online.net/2013/09/esclerose-lateral-amiotrofica.html
25	http://falandosobreela.blogspot.com.br/2012/10/atuacao-fonoaudiologica-na-esclerose.html
26	http://www.nutritotal.com.br/perguntas/?acao=bu&id=676&categoria=12target=_blank
27	http://www.revistaneurociencias.com.br/edicoes/2006/RN%2014%20SUPLEMENTO/Pages%20from%20RN%2014%20SUPLEMENTO-10.pdf
28	http://www.vidamaislivre.com.br/noticias/noticia.php?id=679&/site_sobre_esclerose_lateral_amiotrofica_ela_e_lancado
29	http://www.deficienteciente.com.br/2011/11/projeto-clic-destinado-a-pessoa-com-esclerose-lateral-amiotrofica-ela.html
30	http://www.leieordem.com.br/software-permite-a-advogada-com-esclerose-lateral-amiotrofica-escrever-livro.html
31	http://www.ipg.org.br/ipg/project/ipg/public/uploads/2013/09/03/5225d18b48c96uso_de_acionadores_na_ela.pdf
32	http://periodicos.uem.br/ojs/index.php/ActaSciEduc/article/view/14505
33	http://drauziovarella.com.br/letras/e/esclerose-lateral-amiotrofica-ela/
34	http://www.minhavidacom.br/saude/temas/esclerose-lateral-amiotrofica#top1
35	http://fisioterapiahumberto.blogspot.com.br/2009/04/esclerose-lateral-amiotrofica.html
36	http://gerasaude.blogspot.com.br/2011/09/artigo-esclerose-lateral-amiotrofica.html
37	http://jmarcosrs.wordpress.com/2012/03/12/esclerose-lateral-amiotrofica-ela-primeiro-estudo-experimental-com-celulas-tronco-sera-coordenado-por-pesquisadora-do-hcusp-de-ribeirao-preto/
38	http://drcarlosrey.blogspot.com.br/2012/11/esclerose-lateral-amiotrofica-ela.html
39	http://www.aph.org.br/revista/index.php/aph/article/viewFile/109/177
40	http://rafaelfontenelle.blogspot.com.br/2009/09/esclerose-lateral-amiotrofica.html
41	http://www.abcdasaude.com.br/artigo.php?456
42	http://www.diabete.com.br/fadiga-cronica-e-comum-no-diabetes-tipo-1s-diz-novo-estudo/
43	http://www.diabetenet.com.br/conteudocompleto.asp?idconteudo=7938
44	http://www.abcdasaude.com.br/artigo.php?700
45	http://www.abcdasaude.com.br/artigo.php?496
46	http://www.abcdasaude.com.br/artigo.php?248

47	http://www.abcdasaude.com.br/artigo.php?303
48	http://www.diabete.com.br/mais-cinco-medos-comuns-em-diabetes/
49	http://www.abc.med.br/p/diabetes-mellitus/22360/diabetes+mellitus.htm
50	http://www.anutricionista.com/previna-se-contr-o-diabetes.html
51	http://www.minhavidacom.br/saude/temas/diabetes
52	http://www.anutricionista.com/alimentacao-para-diabeticos.html
53	http://www.anutricionista.com/diet-e-light-entenda-a-diferenca.html
54	http://www.anutricionista.com/suplementacao-com-creatina-no-futebol.html
55	http://www.anutricionista.com/diabetes-mellitus-tipo-1-e-tipo-2-diferencas-e-sintomas.html
56	http://www.diabete.com.br/comer-frutas-e-evitar-sucos-industrializados-ajuda-a-prevenir-diabetes/
57	http://www.anutricionista.com/diabetes-tipo-2-creatina-ajuda-a-controlar.html
58	http://www.mudandodiabetes.com.br/mudandodiabetes/
59	http://www.diabetes.med.br/diabetes.php
60	http://www.abcdasaude.com.br/artigo.php?191
61	http://www.diamundialdodiabetes.org.br/sobre-o-diabetes/
62	http://www.soudiabetico.com.br/noticias/tratamento-precoce-da-diabetes-pode-reduzir-o-risco-de-doencas-cardiacas
63	http://www.soudiabetico.com.br/noticias/cha-preto-pode-reduzir-risco-de-diabetes-tipo-2-diz-estudo
64	http://www.soudiabetico.com.br/noticias/comer-lentamente-poderia-reduzir-o-risco-de-diabetes
65	http://www.soudiabetico.com.br/especiais/teste-de-glicemia-obrigatorio
66	http://www.diabetes.org.br/sala-de-noticias/2374-passo-a-passo-no-pe-diabetico-2013
67	http://www.soudiabetico.com.br/educacional/o-diabetes-e-a-lipodistrofia
68	http://www.soudiabetico.com.br/noticias/mulher-diabetica-gravida
69	http://drauziovarella.com.br/diabetes/diabetes/
70	http://www.tuasaude.com/sintomas-de-diabetes/
71	http://www.soudiabetico.com.br/noticias/software-ajuda-a-diagnosticar-a-cegueira-por-diabetes
72	http://www.corpore.org.br/cws_exibeconteudogeral_4373.asp
73	http://www.idf.org/about-diabetes
74	http://www.ebc.com.br/noticias/saude/galeria/videos/2012/11/tratamento-com-luz-ajuda-pacientes-diabeticos

75	http://www.endocrino.org.br/10-coisas-que-voce-precisa-saber-sobre-diabetes/
76	http://www.mdsaude.com/2011/12/sintomas-diabetes.html
77	http://www.abcdasaude.com.br/artigo.php?127
78	http://www.abcdasaude.com.br/artigo.php?209
79	http://www.abcdasaude.com.br/artigo.php?367
80	http://www.abcdasaude.com.br/artigo.php?381
81	http://www.caelum.com.br/apostila-java-estrutura-dados/vetores/
82	http://www.caelum.com.br/apostila-java-estrutura-dados/listas-ligadas/
83	http://www.caelum.com.br/apostila-java-estrutura-dados/pilhas/
84	http://www.caelum.com.br/apostila-java-estrutura-dados/filas/
85	http://www.caelum.com.br/apostila-java-estrutura-dados/armazenamento-sem-repeticao-com-busca-rapida/
86	http://www.caelum.com.br/apostila-java-estrutura-dados/tabelas-de-espalhamento/
87	http://www.caelum.com.br/apostila-java-estrutura-dados/armazenamento-associativo/
88	http://www.caelum.com.br/apostila-java-estrutura-dados/mapas-com-lista/
89	http://www.caelum.com.br/apostila-java-estrutura-dados/mapas-com-espalhamento/
90	http://www.ime.usp.br/~pf/algoritmos/aulas/pilha.html
91	http://www.inf.ufpr.br/cursos/ci055/apostila.pdf
92	http://www.dca.fee.unicamp.br/cursos/EA876/apostila/HTML/node10.html
93	http://pt.wikibooks.org/wiki/Algoritmos_e_Estruturas_de_Dados/Pilhas
94	http://pt.wikipedia.org/wiki/Estrutura_de_dados
95	http://inf.uri.com.br/neilor/apostila-ED2.pdf
96	http://www.cprogressivo.net/2013/10/Estrutura-de-dados-dinamica-em-C-Listas-Filas-Pilhas-Arvores.html
97	http://www.ufjf.br/jairo_souza/files/2009/12/2-Ordenacao-InsertionSort.pdf
98	http://www.javaprogressivo.net/2012/09/introducao-aos-tipos-de-estrutura-de.html
99	http://imasters.com.br/artigo/7909/linguagens/estudo-sobre-engenharia-de-software/
100	http://inf.unisul.br/~vera/egs/cmm_pro.htm
101	https://programacaodescomplicada.wordpress.com/indice/estrutura-de-dados/
102	http://www.inf.ufsc.br/~ine5384-hp/Estruturas.AlocDinamica.html
103	http://www.inf.ufsc.br/~ine5384-hp/Capitulo4/EstruturasListaEncadeada.html
104	http://www.inf.ufsc.br/~ine5384-hp/Estruturas.ArVBusca.html
105	http://cae.ucb.br/conteudo/programar/algoritmobsi/new_estruturadedadoshomogene

	absi.html
106	http://www.numerofilia.com.br/2011/10/estrutura-de-dados-2-pilha.html
107	http://pt.wikiversity.org/wiki/Introdu%C3%A7%C3%A3o_%C3%A0s_Estruturas_de_Dados/Algoritmos_de_Ordena%C3%A7%C3%A3o
108	http://www.numerofilia.com.br/2011/11/estrutura-de-dados-3-fila.html
109	http://www.numerofilia.com.br/2011/10/estrutura-de-dados-1-lista-encadeada.html
110	http://programando-ads.blogspot.com.br/2012/07/estrutura-de-dados-ponteiros.html
111	http://www.numerofilia.com.br/2011/11/estrutura-de-dados-4-arvore-binaria.html
112	http://forum.programacaobrasil.com/t288-estrutura-de-dados-com-funcao-e-ponteiro
113	http://www.jonathanribas.com/blog/introducao-a-estrutura-de-dados/
114	http://blog.tiagopassos.com/2010/09/30/exemplo-de-pilha-estrutura-de-dados/
115	http://w3.ualg.pt/~hshah/ped/aula%2012/Arvores%20AVL.htm
116	http://w3.ualg.pt/~hshah/ped/Aula%209/index.html
117	http://www.inf.ufsc.br/~ine5384-hp/estrut08.html
118	http://www.linguagemc.xpg.com.br/estrutura.html
119	http://bloginfogeeks.blogspot.com.br/2010/12/conceitos-de-arvores.html
120	http://www.matbra.com/2009/04/28/pilha-com-ponteiros-estrutura-de-dados/