



Programa Interdisciplinar de Pós-Graduação em
Computação Aplicada
Mestrado Acadêmico

André Filipe Aloise

**UM SISTEMA DE RECOMENDAÇÃO PARA PROFESSORES E
COORDENADORES DE CURSO UTILIZANDO PREDIÇÃO DE
REPROVAÇÃO NA MODALIDADE DE EDUCAÇÃO A DISTÂNCIA**

São Leopoldo
2016

UNIVERSIDADE DO VALE DO RIO DOS SINOS - UNISINOS
UNIDADE ACADÊMICA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA INTERDISCIPLINAR DE PÓS-GRADUAÇÃO
EM COMPUTAÇÃO APLICADA
NÍVEL MESTRADO

ANDRÉ FILIPE ALOISE

**UM SISTEMA DE RECOMENDAÇÃO PARA PROFESSORES E
COORDENADORES DE CURSO UTILIZANDO PREDIÇÃO DE
REPROVAÇÃO NA MODALIDADE DE EDUCAÇÃO A DISTÂNCIA**

São Leopoldo
2016

André Filipe Aloise

**UM SISTEMA DE RECOMENDAÇÃO PARA PROFESSORES E
COORDENADORES DE CURSO UTILIZANDO PREDIÇÃO DE
REPROVAÇÃO NA MODALIDADE DE EDUCAÇÃO A DISTÂNCIA**

Dissertação apresentada como requisito parcial para a
obtenção do título de Mestre, pelo Programa
Interdisciplinar de Pós-Graduação em Computação
Aplicada da Universidade do Vale do Rio dos Sinos
– UNISINOS

Orientador: Dr. Jorge Luis Victoria Barbosa

Coorientador: Dr. Sando José Rigo

São Leopoldo

2016

Ficha Catalográfica

A453u Aloise, André Filipe
Um Sistema de Recomendação para professores e coordenadores de curso utilizando predição de reprovação na modalidade de Educação a Distância / André Filipe Aloise. – São Leopoldo, 2016.
94 f.: il. color.

Dissertação (Mestrado em Computação Aplicada) – Universidade do Vale do Rio dos Sinos, 2016.
Orientador: Prof. Dr. Jorge Luis Victoria Barbosa.
Coorientador: Prof. Dr. Sandro José Rigo.

1. Sistema de Recomendação Educacional 2. Ferramenta computacional 3. Educação a Distância 4. CRM I. Barbosa, Jorge Luis Victoria II. Rigo, Sandro José III. Universidade do Vale do Rio dos Sinos IV. Título.

CDD 005.12

André Filipe Aloise

“UM SISTEMA DE RECOMENDAÇÃO PARA PROFESSORES E COORDENADORES DE CURSO UTILIZANDO PREDIÇÃO DE REPROVAÇÃO NA MODALIDADE DE EDUCAÇÃO A DISTÂNCIA”

Dissertação apresentada à Universidade do Vale do Rio dos Sinos – Unisinos, como requisito parcial para obtenção do título de Mestre em Computação Aplicada.

Aprovado em 24 de fevereiro de 2016

BANCA EXAMINADORA

Prof. Dr. Jorge Luis Victória Barbosa - UNISINOS

Prof. Dr. Sandro José Rigo – UNISINOS

Prof. Dr. João Carlos Gluz - UNISINOS

Prof. Dr. Sílvio Cesar Cazella – UFCSPA

Prof. Dr. Jorge Luis Victória Barbosa (Orientador)

Prof. Dr. Sandro José Rigo (Coorientador)

Visto e permitida a impressão

São Leopoldo,

Prof. Dr. Sandro José Rigo

Coordenador PPG em Computação Aplicada

AGRADECIMENTOS

Agradeço em primeiro lugar a Deus, que me proporcionou a oportunidade de buscar o título de mestre e que me deu condições de não desistir, fortalecendo-me nos momentos de dificuldade, cumprindo em mim aquilo que registrou o apóstolo Paulo na Bíblia Sagrada: *“E disse-me: A minha graça te basta, porque o meu poder se aperfeiçoa na fraqueza. De boa vontade, pois, me gloriarei nas minhas fraquezas, para que em mim habite o poder de Cristo. Por isso sinto prazer nas fraquezas, nas injúrias, nas necessidades, nas perseguições, nas angústias por amor de Cristo. Porque quando estou fraco então sou forte.”* 2 Coríntios 12:9,10.

Agradeço à minha esposa, Alessandra Aloise, que me apoiou sempre nessa jornada. Pelo amor, pela paciência, pela compreensão, pela torcida, pelo incentivo e pelo ânimo nos momentos em que o mesmo me faltou. Sem ela, não teria conseguido.

Ao meu amigo João Luiz Cavalcante Ferreira, que encarou este desafio junto comigo. Nossos momentos árduos de estudo no curso evidenciou a importância do companheirismo e do trabalho em equipe.

Aos meus pais, Pedro Aloise e Inara Brasil, os quais acreditaram na minha capacidade, mesmo quando duvidei de mim mesmo.

Ao Diretor-Geral do Campus Coari do IFAM, Jurandy Moreira Maciel Aires da Silva, cujo convite para fazer parte do seleto grupo que buscaria a titulação de mestrado fez com que esse sonho se tornasse possível.

Ao meu orientador, Prof. Doutor Jorge Luis Victória Barbosa, e ao meu coorientador Prof. Doutor Sandro José Rigo, pelo auxílio acadêmico, pela cobrança do meu avanço, pelo exercício da virtude da paciência e por terem visto potencial neste trabalho.

RESUMO

Este texto propõe um modelo de Sistema de Recomendação Educacional (SRE) para professores e coordenadores de curso que utiliza a predição de reprovação de aprendizes em disciplinas na modalidade de Educação a distância. Considerando o papel da educação na formação do indivíduo, torna-se importante manter o aprendiz até a conclusão do curso buscando também propiciar um bom coeficiente de rendimento. A EaD veio para ampliar as opções das pessoas que buscam uma qualificação, porém para o sucesso dessa modalidade os números, ao término dos cursos, precisam mostrar um aproveitamento positivo. Sistemas de Recomendação Educacional têm sido desenvolvidos para explorar os perfis de aprendizes com o objetivo de detectar suas dificuldades e lhes fazer uma sugestão, a qual pode ser um objeto de aprendizagem, uma revisão de literatura, ou ainda um estudo colaborativo com outros aprendizes. O objetivo desta dissertação é propor o modelo M-SRECP, um modelo de Sistema de Recomendação Educacional que tem como público-alvo professores e coordenadores de curso, os quais recebem dados estatísticos de possibilidade de reprovação de aprendizes em uma disciplina a partir de um sistema de predição e faz recomendações a este público-alvo, a fim de que os mesmos efetuem ações pedagógicas visando reduzir o número de aprendizes reprovados. Técnicas como classificação de perfis de usuários, para delinear a entrega de recomendação, sensibilidade a contextos e *Customer Relationship Management (CRM)* foram utilizadas neste trabalho, com o intuito de viabilizar um diferencial quanto à recomendação ao público-alvo (professor e coordenador de curso), colocando-o como principal foco do processo (CRM), ao longo de uma disciplina (sensibilidade a contextos). A atuação do público-alvo visa atenuar o quantitativo de aprendizes reprovados em disciplinas na modalidade EaD, oferecendo a estes uma oportunidade de melhorar o seu coeficiente de rendimento, reduzir o tempo matriculado no curso e, conseqüentemente, acelerar sua certificação. Um protótipo do modelo foi elaborado para a realização do experimento no Instituto Federal de Educação, Ciência e Tecnologia do Amazonas, no programa Universidade Aberta do Brasil, curso de Filosofia da educação, disciplina de Linguagem Brasileira de Sinais, em 2015/2. Coletou-se através de um questionário, os perfis de 30 professores, o que permitiu a classificação do perfil de professor utilizando árvore de decisão com a ferramenta *RapidMiner*. O perfil do professor da disciplina de Libras também foi coletado, no entanto o mesmo foi submetido à classificação para definir se, além dele, haveria a necessidade da coordenação do curso de Filosofia da Educação receber também a recomendação semanal dos aprendizes com risco de reprovação na disciplina. O protótipo também foi apresentado a um conjunto de 12 professores para que os mesmos realizassem uma avaliação de facilidade de uso percebida e de percepção de utilidade através do *Technology Acceptance Model (TAM)*. Chegou-se à conclusão que o M-SRECP é uma ferramenta computacional que pode auxiliar o professor e o coordenador do curso a resgatar os aprendizes antes que a reprovação ocorra, auxiliando na melhora do desempenho do aprendiz na disciplina ainda em andamento.

Palavras-Chave: EaD; disciplina; CRM.

ABSTRACT

This text proposes an Educational Recommendation System (ERS) model for teachers and course coordinators based on prediction of apprentices failure in e-learning courses. Considering the role of education in shaping the individual, it is important to keep the apprentice in the course until it's completion, seeking to provide a good GPA. E-learning has expanded the options of people seeking a qualification, but for it's success the numbers, at the end of the course, need to show a positive performance. Educational Recommender Systems have been developed to explore the profiles of learners in order to detect their problems and to make them a suggestion, which can be a learning object, a literature review, or a collaborative study with other learners. The aim of this work is to propose M-SRECP, an educational recommender system model whose target audience is course coordinators and teachers, who receives statistics of possibility of failure of apprentices in a discipline, from a prediction system, and makes recommendations to this target audience, so they can make pedagogical actions aiming to reduce the number of failed apprentices. Techniques such as user profiles classification that guide the delivery of the recommendation, context awareness and Customer Relationship Manager were used in this work, in order to provide a differential on the recommendation to the target audience (teacher and course coordinator), putting them in the main focus of the process (CRM), over a discipline (context awareness). The actions of the target audience aims at reducing the failed apprentices in e-learning mode disciplines, offering them an opportunity to improve their GPA, reduction of the time enrolled in the course and thus accelerating their certification. A prototype of the model was developed for an experiment at the Federal Institute of Education, Science and Technology of Amazonas, in the Open University of Brazil program, in the Philosophy of Education course, in discipline Brazilian Language of Signs in 2015/2. It was collected through a questionnaire, 30 teachers profiles, which allowed the classification of teacher's profile using Decision Tree with RapidMiner. The discipline Libras teacher's profile was also collected, however it has been subjected to classification to determine whether, besides him, there would be the need for the coordination's course of Philosophy of Education also receive weekly recommendation of apprentices with failure risk in the discipline. The prototype was also presented to a set of 12 teachers so that they could make an evaluation of perceived ease of use and utility perception through the Technology Acceptance Model (TAM). It was concluded that M-SRECP is a computational tool that can help teachers and course coordinators to rescue apprentices before the failure to occur, helping to improve the learner's performance in a discipline still in progress.

Keywords: E-learning; discipline, CRM.

LISTA DE FIGURAS

Figura 1 - Fórmula de utilidade de item	20
Figura 2 – Arquitetura do modelo	23
Figura 3 - Arquitetura do Ubigroup.....	24
Figura 4 – Apresentação do sistema PenSAE	25
Figura 5 - Arquitetura do MobiLE	26
Figura 6- Arquitetura do modelo e-LORS.....	28
Figura 7 - Arquitetura do AICAPA	30
Figura 8 - Modelo RECoaComp.....	31
Figura 9 - Visão geral do sistema	32
Figura 10 - Ontologia do Otilia	35
Figura 11 - Apresentação dos tópicos (contextos)	40
Figura 12 - Arquitetura do M-SRECP.....	41
Figura 13 - Metamodelo do Coordenador do curso.....	42
Figura 14 - Metamodelo do Professor	43
Figura 15 - Módulo de consulta.....	45
Figura 16- Módulo de análise de dados.....	47
Figura 17 - Módulo de notificação	48
Figura 18- Módulo administrativo com CRM.....	49
Figura 19 - Processo de classificação do perfil	50
Figura 20 - Operadores <i>Retrieve</i> utilizados no processo	51
Figura 21- Operadores <i>Set Role</i> utilizados no processo	52
Figura 22 - Operador <i>Decision Tree</i> utilizado no processo.....	52
Figura 23 - Regras da Árvore de decisão	53
Figura 24 - Exportação do processo de classificação	54
Figura 25 - Código de importação do processo.....	54
Figura 26 - Tratamento do arquivo CSV	55
Figura 27 - Cadastrar nova tarefa	56
Figura 28 - Cadastrar usuário	56
Figura 29 - Questionário para obter o perfil do Professor.....	58
Figura 30 - Questionário de perfil do Professor (formas de notificação).....	59
Figura 31 - Acurácia da árvore de decisão	60
Figura 32 - Perfil do professor classificado.....	60
Figura 33 - Árvore de decisão (Perfil do professor).....	61

Figura 34 - Meios tecnológicos de notificação.....	62
Figura 35 - Notificação (<i>WhatsApp</i>).....	63
Figura 36 - Notificação (E-mail)	63
Figura 37 - Fluxograma do experimento	64
Figura 38 - Gráfico Facilidade de uso percebida.....	69
Figura 39 - Percepção de utilidade	69
Figura 40 - Questionário de perfil do professor (texto introdutório).....	82
Figura 41 - Questionário de perfil do professor (Geral - parte 1).....	83
Figura 42 - Questionário de perfil do professor (Geral - parte 2).....	84
Figura 43 - Questionário de perfil do professor (Geral - parte 3).....	85
Figura 44 - Questionário de perfil do professor (tipos de notificações semanais)	86

LISTA DE TABELAS

Tabela 1- Comparação de trabalhos	36
Tabela 2 - Itens do questionário do experimento	68
Tabela 3 – Comparação entre os trabalhos relacionados e o M-SRECP.....	73
Tabela 4 - Grupo de risco (semana 1). Origem: MD-PREAD	87
Tabela 5 - Grupo de risco (semana 2). Origem: MD-PREAD	90
Tabela 6 - Grupo de risco (semana 3). Origem: MD-PREAD	91
Tabela 7 - Grupo de risco (semana 4). Origem: MD-PREAD	93

LISTA DE SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
API	<i>Application Programming Interface</i>
CRM	<i>Customer Relationship Management</i>
CSS	<i>Cascading Style Sheets</i>
CSV	<i>Comma-separated values</i>
EAD	Educação a distância
IDE	<i>Integrated Development Environment</i>
IFAM	Instituto Federal do Amazonas
JSON	<i>JavaScript Object Notation</i>
NoSQL	<i>Not Only SQL</i>
OA	Objetos de Aprendizagem
PIPCA	Programa Interdisciplinar de Pós-Graduação em Computação Aplicada
REST	<i>Representational State Transfer</i>
SRE	Sistema de Recomendação Educacional
TAM	<i>Technology Acceptance Model</i>
UAB	Universidade Aberta do Brasil
UML	<i>Unified Modeling Language</i>
UNISINOS	Universidade do Vale do Rio dos Sinos
XML	<i>eXtensible Markup Language</i>

SUMÁRIO

1 INTRODUÇÃO	13
1.1 Motivação	14
1.2 Problema	15
1.3 Questões de Pesquisa	15
1.4 Objetivos	16
1.5 Metodologia	16
1.6 Organização da dissertação.....	17
2 FUNDAMENTAÇÃO TEÓRICA	18
2.1 Educação a distância.....	18
2.2 Sistemas de Recomendação.....	19
2.3 Sistemas de Recomendação Sensíveis a contexto.....	20
2.4 Sistemas de Recomendação Educacionais	21
3 TRABALHOS RELACIONADOS	22
3.1 Modelo para geração proativa de recomendações sensíveis a contextos em sistemas de e-Learning	22
3.2 Ubigroup.....	23
3.3 Assistente de Recomendação baseado na Metodologia da Problematização	25
3.4 MobiLE.....	26
3.5 e-LORS	27
3.6 AICAPA.....	29
3.7 RECoaComp.....	30
3.8 Auxílio Personalizado a Alunos em Ambiente Virtual de Aprendizagem Utilizando Agentes	32
3.9 Otilia.....	33
3.10 Comparação.....	35
4 MODELO M-SRECP	39
4.1 Visão geral	39
4.2 Arquitetura	40
4.3 Perfil do Coordenador	42
4.4 Perfil do Professor	43
4.5 Módulo de consulta.....	45
4.6 Módulo de análise de dados	46
4.7 Módulo de notificação	47
4.8 Módulo administrativo com CRM	48
5 ASPECTOS DE IMPLEMENTAÇÃO	50
6 ASPECTOS DE AVALIAÇÃO	57
6.1 Avaliação de funcionalidade.....	57
6.2 Avaliação de usabilidade.....	67
7 CONSIDERAÇÕES FINAIS	71
7.1 Resumo e Conclusões.....	71
7.2 Contribuições	72
7.3 Trabalhos futuros.....	74
REFERÊNCIAS	76
APÊNDICE - INFORMAÇÕES COMPLEMENTARES	82

1 INTRODUÇÃO

Educação é um dos pilares da sociedade. É ela que fornece ao cidadão o conhecimento, científico ou profissional, necessário para seu bem viver; é o alicerce capaz de fazer do indivíduo alguém próspero, capacitado com as ferramentas necessárias para lidar com situações do cotidiano. Várias formas de educar foram usadas ao longo do tempo, e isso se deu muito graças às novas formas de comunicação e pela revolução tecnológica, conforme explica (GOTARDO; CEREDA; JUNIOR, 2013). Uma modalidade que surgiu com esses avanços é a Educação a distância (EAD), a qual vem tendo cada vez mais aceitação, muito por conta da necessidade de alcançar o indivíduo que, por vias normais, teria dificuldade de ingresso em um meio educacional ou em alguns casos, jamais teria uma oportunidade. Portanto pode-se entender que um dos objetivos da EaD é a inclusão social.

Segundo (GOTARDO; CEREDA; JUNIOR, 2013) a EAD, juntamente do e-Learning, também conhecido como ensino eletrônico, são abordagens combinadas em forma de sistemas que utilizam recursos e ferramentas existentes na Web; tais sistemas são chamados de Sistemas Educacionais Baseados na Web (*Webbased Education – WBE*). Ainda de acordo com (GOTARDO; CEREDA; JUNIOR, 2013), esse tipo de educação vem sendo bastante explorada nas metodologias dos ensinamentos presenciais e à distância. Dentro dos Sistemas Educacionais Baseados na Web, encontram-se os Sistemas de Recomendação Educacionais (SRE's). Os SRE's trabalham em prol da tomada de decisões recomendando algo para alguém, através de benefícios obtidos pela Mineração de Dados Educacionais (*Educational Data Mining – EDM*), com uso de inteligência artificial e aprendizado de máquina.

Em conjunto com a EDM há a *Learning Analytics* (LA) e a *Learning Design*. O conceito de LA seria a análise do aprendizado ao buscar medir, coletar e avaliar dados sobre aprendizes e seus contextos com o objetivo melhorar o aprendizado assim como o ambiente em que ocorre (BROWN, 2012). A *Learning Design*, ou ainda, a *IMS Learning Design (IMSLD)* é uma especificação padrão que permite modelar o processo de aprendizagem e estruturar o conteúdo inerente a este processo, sendo mantida pelo *IMS Global Learning Consortium* de acordo com (JÚNIOR; SILVA; FERNANDES, 2013) e (IMS GLOBAL LEARNING CONSORT, 2015).

Muitas abordagens de Sistemas de Recomendação têm sido usadas no âmbito da educação, sendo esses sistemas amplamente utilizados hoje em dia, de acordo com (SILVA, LUIZ CLÁUDIO; MENDES NETO; JÁCOME JÚNIOR, 2013). Esses sistemas podem, por exemplo, ajudar aprendizes sugerindo-lhes atividades, textos, áudios, vídeos ou outros recursos que são costumeiramente utilizados na EAD, dentro dos Ambientes Virtuais de Aprendizagem (AVA), segundo afirmam (RIBEIRO; FONSECA; FREITAS, 2013) e (MORAIS; FRANCO, 2012). No que tange os profissionais de educação os SRE's podem prover *feedback* das tarefas, analisar o comportamento dos estudantes, criar grupos de alunos com características afins, descobrir padrões irregulares ou indesejáveis e determinar atividades mais efetivas nos cursos, conforme (SILVA, LUIZ CLÁUDIO NOGUEIRA DA; NETO; JÚNIOR, 2011), (FERRO *et al.*, 2011) e (GOTARDO; CEREDA; JUNIOR, 2013). Há SRE's que recomendam conteúdo educacional para grupos de aprendizes utilizando uma abordagem ubíqua (FERREIRA *et al.*, 2015).

1.1 Motivação

Considerando o papel da educação na formação do indivíduo, torna-se importante manter o aprendiz até a conclusão do curso buscando também propicia-lo um bom coeficiente de rendimento. A EaD é uma modalidade de ensino que surgiu com o intuito de ampliar as opções das pessoas que buscam uma qualificação, porém para seu sucesso os números, ao término dos cursos, precisam demonstrar um aproveitamento positivo.

A Universidade Aberta do Brasil – UAB é um programa de educação a distância, vinculado à Capes, que busca ampliar e interiorizar a oferta de cursos e programas de educação superior, conforme *site* institucional do programa no portal do Ministério da Educação (MEC, 2013). A UAB está presente em diversas instituições de nível superior, sejam elas públicas ou privadas, nas esferas estadual e federal, visando o maior alcance possível da interiorização a que se propõe o programa.

Quando essa interiorização de oferta de cursos alcança localidades em que o acesso à internet é precário, como nos casos das instituições de ensino superior do norte do país, a educação a distância passa a enfrentar um obstáculo a mais considerando que hoje em dia, a internet está no rol das ferramentas estratégicas mais utilizadas para fomento e manutenção de cursos a distância. Dependendo do município a situação torna-se ainda mais agravante, se forem analisadas as deficiências do sinal de telefonia móvel.

Sistemas de recomendação educacional necessitam desse acesso à internet, independente de qual seja o seu público-alvo. Atualmente existem muitos SRE's focados na sugestão ao aprendiz, como o e-Lors (ZAINA *et al.*, 2012) que faz recomendação de conteúdo eletrônico baseada no relacionamento entre perfis e objetos de aprendizagem, e AICAPA (MENEZES; VALE; CRUZ, 2014) o qual tem por objetivo apoiar a revisão da literatura, através de técnicas de Recomendação e de Recuperação da Informação. Porém esses sistemas não levam em consideração a condição do acesso à internet.

Criar ou utilizar sistemas de recomendação educacional que não logrem êxito em entregar a sugestão ao seu destinatário, torna-se pouco produtivo, pois nenhuma mudança no desempenho do aprendiz, em uma ou mais disciplinas, será detectada. Assim pode-se entender que o sistema de recomendação a ser desenvolvido, e utilizado, necessita atender a demanda que originou seu desenvolvimento.

Pesquisas têm sido feitas na área de sistemas de recomendação educacional, porém a maioria volta-se para recomendar a aprendizes, pouco considerando informações contextuais como localidades, tempo ou atividades. No entanto, estudos sobre *Context-aware recommender systems* (CARS), ou sistemas de recomendação sensíveis ao contexto, têm sido desenvolvidos, mostrando que é possível gerar informações mais relevantes ao se abordar uma situação específica de contexto, o que pode ser utilizado no tratamento com outros usuários na área educacional, como professores e coordenadores de curso. De acordo com a definição de (DEY, 2001), contexto é qualquer informação relevante que possa ser utilizada para caracterizar entidades de uma interação usuário-computador, e que um sistema só pode ser considerado como sensível ao contexto se ele conseguir prover ao usuário essas informações e/ou serviços classificados como importantes.

Trabalhos que tratam de gerenciamento de perfis também se mostram relevantes como, por exemplo, o modelo *eProfile* (WAGNER, 2013) o qual propõe o uso de trilhas para geração de perfis dinâmicos, os quais são adaptados automaticamente e continuamente. O principal benefício dessa abordagem é permitir registros de ações de indivíduos, por parte de sistemas computacionais, em trilhas que representam o histórico de contextos visitados por um usuário

a fim de permitir a eficácia na adaptação de um sistema sensível a contexto a esse usuário (SILVA, JADER M. *et al.*, 2010).

Este trabalho propõe o M-SRECP, um modelo de sistema de recomendação educacional, cujo foco das recomendações são professores e coordenadores de curso ao invés de recomendar para aprendizes, sendo considerada essa a principal contribuição. O propósito das recomendações é informar público-alvo quais aprendizes estão propensos à reprovação em uma disciplina em andamento, para que os mesmos atuem a fim de buscar reverter a situação de insucesso. Ainda, o M-SRECP apresenta como contexto cada momento, ou intervalo de tempo, que existe dentro da disciplina, os quais podem ser interpretados como subdivisões que abordam conteúdos variados, chamados de tópicos, até a consolidação do término da disciplina. Será também explorada a entrega da recomendação educacional de acordo com os metamodelos de perfis de professores e coordenadores de curso, que passam por uma classificação. Por fim são estudados conceitos de CRM para uma gestão da relação entre os professores e os coordenadores de curso, objetivando acompanhar os aprendizes ao longo da disciplina.

1.2 Problema

Sistemas de Recomendação têm sido desenvolvidos com o objetivo de detectar dificuldades do aprendiz, e fazer alguma sugestão que permita um melhor desempenho. Há sistemas que recomendam objetos de aprendizagem para aprendizes, como (RIBEIRO; FONSECA; FREITAS, 2013), (ZAINA *et al.*, 2012), (SILVA, LUIZ CLÁUDIO NOGUEIRA DA; NETO; JÚNIOR, 2011) e (FERRO *et al.*, 2011); outros uma revisão de literatura (MENEZES; VALE; CRUZ, 2014); outros ainda sugerem estudos colaborativos entre os aprendizes (MORAIS; FRANCO, 2012) e (FERREIRA *et al.*, 2015); existem ainda sistemas de recomendações para professores (COSTA; AGUIAR; MAGALHÃES, 2013); e também sistemas de recomendação sensíveis ao contexto (GOMINHO; TEDESCO; BELIAN, 2014) e (GALLEGO *et al.*, 2012). Porém sistemas de recomendação educacional, sensíveis a contextos, tendo como usuários coordenadores de curso e professores, que busquem tratar da mitigação de reprovação, não foram encontrados.

Este trabalho propõe um modelo que permita gerenciar recomendações para professores e coordenadores de cursos a distância, utilizando conceitos de sistemas de recomendação (BOBADILLA *et al.*, 2013), perfis (BONHARD; SASSE, 2006) e sensibilidade a contextos (ADOMAVICIUS, GEDIMINAS; TUZHILIN, 2011). O modelo usa dados obtidos de um sistema de predição de reprovação de aprendizes em disciplinas e faz sugestões ao coordenador de um curso e/ou ao professor da disciplina em andamento, com uma lógica de entrega de recomendações de acordo com os perfis dos mesmos.

1.3 Questões de Pesquisa

Quais os benefícios de um modelo computacional de sistema de recomendação educacional para professores e coordenadores de curso, que auxilie na redução de reprovação de aprendizes em disciplinas, por meio de classificação de perfis desse público-alvo, com entrega de recomendações sensíveis a contextos e utilizando conceitos de CRM?

1.4 Objetivos

O objetivo geral deste trabalho é a modelagem, implementação e avaliação de um modelo de sistema de recomendação educacional com foco em coordenadores de curso e professores, denominado M-SRECP. As principais características do M-SRECP são: (i) o gerenciamento de entrega de recomendação considerando os diversos tipos de perfis de usuário (coordenadores de curso e professores) (WAGNER, 2013), (ii) obter registros relacionados às tendências e os motivos de reprovação de aprendizes, os quais proveem de um sistema de predição, (iii) envio de recomendações através de APIs que facilitem a comunicação em tempo real, (iv) sensibilidade a contextos, considerando como contextos os tópicos ou unidades que podem ser compreendidas como fragmentos da disciplina a distância em execução.

Abaixo são listados os objetivos específicos deste trabalho:

- definir os perfis de usuários;
- estabelecer regras de entrega das recomendações;
- modelar o M-SRECP;
- delinear um cenário de aplicação do M-SRECP;
- desenvolver um protótipo;
- avaliar o modelo a partir do protótipo.

1.5 Metodologia

A exequibilidade dos objetivos propostos por este trabalho se deu mediante aplicação de uma metodologia que teve, como primeira etapa, um estudo geral sobre sistemas de recomendação educacional, gerenciamento de perfis e sensibilidade a contextos.

A segunda etapa consistiu no estudo de modelos previamente propostos para os sistemas de recomendação educacional, ou seja, trabalhos relacionados ao assunto. O objetivo desta etapa foi analisar a forma como outros modelos lidam com recomendações e também elaborar um estudo comparativo entre eles.

A terceira etapa tratou da modelagem do M-SRECP, indicando sua arquitetura e discutindo cada um de seus principais artefatos. Seu propósito foi definir quais artefatos seriam primordiais para o modelo e como se daria a interatividade entre eles.

Na quarta etapa foi definido um cenário de uma aplicação a ser desenvolvida utilizando os recursos do M-SRECP. O objetivo dessa etapa foi colocar em prática a proposta do modelo e averiguar sua usabilidade.

Na quinta e última etapa consta o desenvolvimento de um protótipo com todos os recursos necessários para a execução do cenário, o que proporcionou uma avaliação do modelo, utilizando TAM (YOON; KIM, 2007).

1.6 Organização da dissertação

A presente dissertação está organizada da seguinte forma. O capítulo 2 descreve fundamentações teóricas sobre Educação a distância, Sistemas de Recomendação, Sistemas de Recomendação Educacionais e Sensibilidade a Contexto. O capítulo 3 apresenta os trabalhos relacionados à pesquisa de Sistema de Recomendação Educacional baseado na predição de desempenho de aprendizes, sensível a um contexto e também é realizada uma comparação entre os trabalhos. O capítulo 4 apresenta o modelo proposto e detalha cada um de seus componentes. No capítulo 5 são explanados os pormenores relacionados aos aspectos de implementação do protótipo. Os aspectos de avaliação são apreciados no capítulo 6 e as considerações finais serão apresentadas no capítulo 7, em conjunto dos trabalhos futuros.

No apêndice, são apresentadas informações complementares a este trabalho, quais sejam: questionário do perfil do professor e resultados das consultas realizadas ao sistema de predição durante o período do experimento.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo é oferecida uma visão geral da área de Educação a distância e sistemas de recomendação. Na primeira seção é abordada a modalidade Educação a distância e na segunda seção são apresentados os sistemas de recomendação. Na terceira seção é analisada a vertente de sistemas de recomendação sensíveis a contextos. A quarta e última seção aborda a junção da Educação a distância com os sistemas de recomendação, chamados de sistemas de recomendação educacionais (SRE's).

2.1 Educação a distância

Educação a distância é uma modalidade de educação mediada por tecnologias em que discentes e docentes estão separados espacial e/ou temporalmente, ou seja, não estão fisicamente presentes em um ambiente presencial de ensino/aprendizagem. Esta modalidade de educação é efetivada através do intenso uso de tecnologias de informação e comunicação, podendo ou não apresentar momentos presenciais (MORAN, 2013) e (ALVES, 2011).

A Educação a distância constitui uma opção a mais para atender contingentes de alunos, buscando manter a qualidade dos serviços oferecidos em decorrência da ampliação da clientela atendida (NUNES, 1994). Isso é possibilitado pelas novas tecnologias nas áreas de informação e comunicação que estão abrindo novas possibilidades para os processos de ensino-aprendizagem à distância. De acordo com (ALVES, 2011), novas abordagens têm surgido em decorrência da utilização crescente de multimídias e ferramentas de interação a distância no processo de produção de cursos, pois com o avanço das mídias digitais e da expansão da Internet, torna-se possível o acesso a um grande número de informações, permitindo a interação e a colaboração entre pessoas distantes geograficamente ou inseridas em contextos diferenciados.

Somando-se a isso, a Educação a distância possui uma relevância social importante, pois possibilita o acesso ao sistema àqueles que vêm sendo excluídos do processo educacional superior da esfera pública por morarem longe das universidades ou por indisponibilidade de tempo nos horários tradicionais de aula, uma vez que a modalidade de Educação a distância contribui para a formação de profissionais sem deslocá-los de seus municípios. Segundo (PRETI, 1996), a crescente demanda por educação, devida não somente à expansão populacional como, sobretudo às lutas das classes trabalhadoras por acesso à educação, ao saber socialmente produzido, concomitantemente com a evolução dos conhecimentos científicos e tecnológicos está exigindo mudanças em nível da função e da estrutura da escola e da universidade.

O desenvolvimento desta modalidade de ensino serviu para implementar os projetos educacionais mais diversos e para as mais complexas situações, tais como: cursos profissionalizantes, capacitação para o trabalho ou divulgação científica, campanhas de alfabetização e também estudos formais em todos os níveis e campos do sistema educacional (LITWIN, 2001).

De acordo com (MAIA; MATTAR, 2007), a Educação a distância atualmente é praticada nos mais variados setores. Ela é usada na Educação Básica, no Ensino Superior, em universidades abertas, universidades virtuais, treinamento governamentais, cursos abertos, livres etc.

O conceito de Educação a distância no Brasil é definido oficialmente no Decreto nº 5.622 de 19 de dezembro de 2005 (BRASIL, 2005): "Art. 1º Para os fins deste Decreto caracteriza-se a Educação a distância como modalidade educacional na qual a mediação

didático-pedagógica nos processos de ensino e aprendizagem ocorre com a utilização de meios e tecnologias de informação e comunicação, com estudantes e professores desenvolvendo atividades educativas em lugares ou tempos diversos”.

Essa definição da Educação a distância complementa-se com o primeiro parágrafo do mesmo artigo, onde é ressaltado que esta deve ter obrigatoriamente momentos presenciais. Esse mesmo artigo indica que a Educação a distância se organiza segundo metodologia, gestão e avaliação peculiares, para as quais deverá estar prevista a obrigatoriedade de momentos presenciais para: (i) avaliações de estudantes; (ii) estágios obrigatórios, quando previstos na legislação pertinente; (iii) defesa de trabalhos de conclusão de curso, quando previstos na legislação pertinente e; (iv) atividades relacionadas a laboratórios de ensino, quando for o caso.

É crescente o número de instituições e empresas que desenvolvem programas de treinamento de recursos humanos, através da Educação a distância (ALVES, 2011). As universidades a distância têm incorporado, em seu desenvolvimento histórico, as novas tecnologias de informática e de telecomunicação.

Globalmente, é crescente a oferta de cursos formais e informais através da modalidade de Educação a distância. As experiências brasileiras nessa modalidade de educação, governamentais e privadas, foram muitas e representaram, nas últimas décadas, a mobilização de grandes contingentes de recursos. Porém, embora avanços importantes tenham acontecido nos últimos anos, ainda há um caminho a percorrer para que a Educação a distância possa ocupar um espaço de destaque no meio educacional, em todos os níveis, vencendo, inclusive, o preconceito de que os cursos oferecidos na educação a distância não possuem controle de aprendizado e não têm regulamentação adequada. O governo federal criou leis e estabeleceu normas para a Educação a distância no Brasil (VIRTUAL, [S.d.]) e até os cursos superiores da Educação a distância apresentam diplomas com equivalência aos dos cursos oferecidos pelas instituições de ensino superior que utilizam a modalidade presencial.

2.2 Sistemas de Recomendação

Um sistema de recomendação é uma abordagem que visa ajudar usuários a encontrarem informações relevantes (GOTARDO; CEREDA; JUNIOR, 2013). Ele combina várias técnicas computacionais para selecionar itens personalizados com base nos interesses dos usuários e conforme o contexto no qual estão inseridos (RICCI; ROKACH; SHAPIRA, 2011). Tais itens podem assumir formas variadas como, por exemplo, livros, filmes, notícias, música, vídeos, anúncios, links patrocinados, páginas de internet, produtos de uma loja virtual, etc. Empresas como *Amazon*, *Netflix*, *Google* e *Facebook* são reconhecidas pelo uso intensivo de sistemas de recomendação com os quais obtêm grande vantagem. O sistema de recomendação, em síntese, tem o objetivo de fornecer uma resposta de relevância/utilidade para o usuário alvo (GOTARDO; CEREDA; JUNIOR, 2013).

Formalmente (ADOMAVICIUS, G.; TUZHILIN, 2005) define que o problema de recomendação pode ser formulado como sendo A o conjunto de todos os usuários do sistema e I o conjunto de itens que podem ser recomendados (GOTARDO; CEREDA; JUNIOR, 2013). Considerando uma função de utilidade u que mede quão útil o item i é para o usuário:

$u: A \times I \rightarrow R$, onde R é um conjunto limitado e conhecido.

O que o sistema precisa é encontrar e escolher o item $i' \in I$ com maior utilidade para o usuário, conforme apresentado pela Figura 1.

Figura 1 - Fórmula de utilidade de item

$$\forall a \in A, i'_a = \arg \max_{i \in I} u(a, i)$$

Fonte: (GOTARDO; CEREDA; JUNIOR, 2013)

Em geral, nos sistemas de recomendação, esta função de utilidade é um *rating* (avaliador) que indica como um usuário em particular gostou de um determinado item. Os *ratings* referem-se às avaliações anteriormente feitas pelos usuários e, por isto, é necessário calcular a estimativa de um *rating* para um item que o usuário não viu para que as recomendações possam ser feitas. As formas de se estimar (ou predizer) os valores de *rating* são basicamente três: (i) Recomendações baseadas em conteúdo; (ii) Recomendação baseadas em colaboração; (iii) Abordagem Híbrida. Com o passar dos anos as técnicas de recomendação foram se aprimorando, conforme explicado no trabalho de (RICCI; ROKACH; SHAPIRA, 2011), classificando os tipos de recomendação da seguinte forma: (i) Baseado em Conteúdo: visa recomendar itens similares a outros que o usuário gostou no passado; (ii) Filtragem Colaborativa: visa recomendar itens de acordo com preferências de usuários similares ou de itens similares; (iii) Baseado em Conhecimento: tipicamente baseados em casos anteriores; (iv) Baseado em Comunidade: visa utilizar informações sobre relações entre os usuários; (v) Híbridos: reúne mais de uma das técnicas apresentadas.

2.3 Sistemas de Recomendação Sensíveis a contexto

Segundo (VERBERT *et al.*, 2012), sistemas de recomendação têm sido pesquisados extensivamente pela comunidade de tecnologia de aprendizagem aprimorada, do inglês *Technology Enhanced Learning* (TEL), durante os últimos anos. Ainda segundo (VERBERT *et al.*, 2012), a aprendizagem está ocorrendo em ambientes extremamente diversos e ricos, o que permite que haja a incorporação de informações contextuais sobre o usuário no processo de recomendação. Essa contextualização é pesquisada como um paradigma para a construção de sistemas inteligentes que possam prever e antecipar as necessidades dos usuários, e agirem de forma mais eficiente, em resposta ao seu comportamento.

Do ponto de vista operacional dos sistemas de recomendação sensíveis a contextos, ou *Context-Aware Recommender Systems* (CARS), o contexto é muitas vezes definido como um agregado de diferentes categorias que descrevem a configuração em que um recomendador é implantado, tal como a localização, a atividade atual, e a disponibilidade de tempo. Um exemplo de um sistema de recomendação sensível a contextos, voltado para a aprendizagem, de acordo com (CUI; BULL, 2005), considera a localização do usuário e o nível de ruído neste local como base para sugerir recursos de aprendizagem.

Segundo (LONSDALE *et al.*, 2005), outro exemplo de CARS, voltado para o ensino, considera a proximidade entre aprendizes para apoiar a aprendizagem colaborativa. Se um recomendador de contextos é capaz de detectar pessoas que estão trabalhando próximas umas das outras em atividades de aprendizagem semelhantes, o sistema pode sugerir aos aprendizes sobre os pares adequados para colaborar.

Por fim, um terceiro exemplo de (VERBERT *et al.*, 2010) considera o tipo de dispositivo que um aprendiz está usando. Se a um aprendiz está sendo recomendado o material para estudar determinado assunto de seu interesse, enquanto faz um percurso do trabalho para a escola usando um *smartphone*, algum material de tamanho curto, um recurso audiovisual que se enquadre na tela do *smartphone* deve ser mais relevante do que um documento longo, que só tenha textos.

2.4 Sistemas de Recomendação Educacionais

Os Sistemas de Recomendação Educacionais (SRE's) são sistemas de recomendação específicos para a área acadêmica. Os SRE's são, de uma forma geral, ferramentas de apoio ao docente, ao discente, ou a algum membro do corpo diretivo. O surgimento e o impulso dos SRE's muito se devem ao avanço da EAD, a qual tem obstáculos, como a evasão e a alta reprovação em disciplinas. Nesse sentido, é interessante, ou essencial, que sistemas de recomendação auxiliem na mitigação desses problemas.

Da mesma forma que um sistema de recomendação sugere itens de compra em *sites* de e-commerce como a *Amazon*, sites relacionados como o *Google*, vídeos como o *Netflix* e amigos no caso do *Facebook*, na educação a recomendação pode ser um objeto de aprendizagem, o qual pode ser um artigo científico, informações sobre estudantes, conteúdos do ambiente virtual analisado, além de vídeos, imagens e sons (AGUIAR *et al.*, 2014). É comum também a prática de recomendar usuários, para incentivar um estudo colaborativo, por exemplo, onde um estudante tem domínio maior sobre um assunto e que pode auxiliar outro.

Segundo (AGUIAR *et al.*, 2014), as abordagens de técnicas de filtragem de informações usadas em SRE's mais conhecidas são: (i) Filtragem Baseada em Conteúdo (FBC), que recomenda itens ao usuário, cujo conteúdo é similar ao que o usuário tenha visto ou selecionado recentemente (ZAINA *et al.*, 2012); (ii) Filtragem Colaborativa (FC), a qual faz recomendações baseadas nas avaliações dos itens realizadas por um grupo de usuários, cujos perfis de avaliações são similares aos do usuário alvo (REATEGUI; RIBEIRO; BOFF, 2008); (iii) Filtragem Híbrida, que contempla os princípios das duas técnicas citadas anteriormente (MENEZES; VALE; CRUZ, 2014). Além dessas há também: (iv) Filtragem Baseada em Conhecimento (CAZELLA *et al.*, 2012); (v) Filtragem Baseada em Competências (BREMIGARTNER; NETTO, 2012); (vi) Filtragem Demográfica (GOTARDO; CEREDA; JUNIOR, 2013); (vii) Baseadas em Técnicas de Contexto (FERREIRA *et al.*, 2015); (viii) e Uso de Algoritmos Genéticos (SILVA, LUIZ CLÁUDIO; MENDES NETO; JÁCOME JÚNIOR, 2013).

O principal objetivo dos SRE's é incentivar a interação, a qual pode ser entre usuário e o próprio ambiente de aprendizagem e seus recursos; entre usuários, sendo uma abordagem com colegas de classe, tutor ou professor; ou ainda entre o usuário e outros sistemas. É muito comum a falta de estímulo de aprendizes de EaD justamente pela pouca ou falta de envolvimento, gerando uma sensação de abandono ao mesmo. Quando isso acontece o aprendiz não se sente estimulado para continuar a disciplina, o que o leva à reprovação. Em casos mais graves ocorre a evasão do curso.

3 TRABALHOS RELACIONADOS

Este capítulo tem como meta apresentar os trabalhos relacionados na área de Sistemas de Recomendação Educacional, sendo alguns deles sensíveis a contextos, levando em consideração trabalhos acadêmicos nacionais e internacionais. A busca pelos trabalhos relacionados ao tema foi feita de maneira que fosse possível encontrar pesquisas mais próximas daquilo a que se propõe o M-SRECP. A seguir são apresentados os principais aspectos de cada um dos trabalhos encontrados e, ao final, uma tabela comparativa realçando os quesitos considerados mais relevantes para o estudo. Alguns trabalhos não abordam integralmente os assuntos Sistema de Recomendação Educacional e Sensibilidade a Contextos, no entanto sua análise foi considerada relevante no escopo da dissertação.

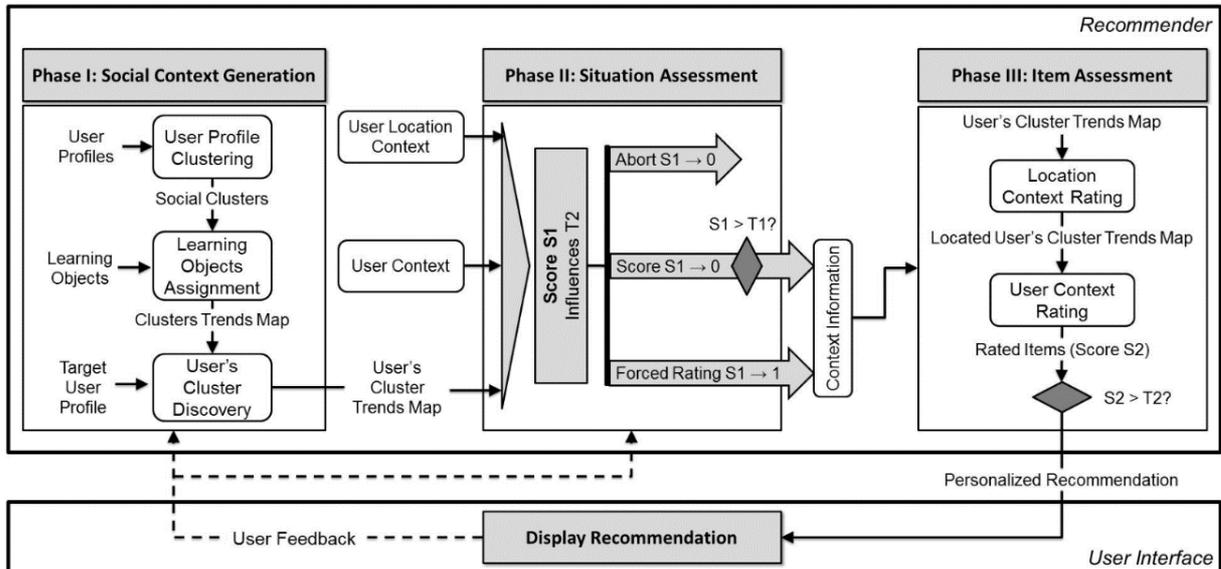
3.1 Modelo para geração proativa de recomendações sensíveis a contextos em sistemas de e-Learning

Este trabalho propõe um sistema de recomendação proativo que entrega recomendações para o usuário quando a situação atual parece adequada, sem que tenha ocorrido um pedido explícito por parte do usuário. É um modelo que se baseia em modelagem de contexto dependente de domínio em várias categorias (a localização do usuário e do contexto social) para gerar recomendações personalizadas para professores e pesquisadores que irão produzir objetos de aprendizagem aos alunos (GALLEGO *et al.*, 2012). Dessa forma, conteúdos pedagógicos simples como, vídeos, slides ou imagens e atividades complexas, por exemplo, excursões virtuais ou *flashcards* podem ser recomendados, bem como outros usuários registrados na plataforma que podem ser interessantes para o usuário-alvo.

O modelo usa como referência o *ViSH (Virtual Science Hub)*, uma plataforma desenvolvida para uma jornada científica chamada *GLOBAL* (“Global Excursions”, 2011). O propósito do *ViSH* é hospedar todas as atividades realizadas pelos professores e pesquisadores no projeto e promover colaboração entre eles. Segundo (GALLEGO *et al.*, 2012), *ViSH* é uma rede social, onde cada usuário será capaz de seguir um outro usuário e também para ser seguido por outros usuários interessados em suas atividades.

Para a geração de recomendações positivas de sistemas de e-Learning, o modelo incorpora informações contextuais para avaliar se a recomendação é adequada para uma dada situação. Ele também avalia quais objetos de aprendizagem de *ViSH* são interessantes para o usuário que está sendo recomendado. A Figura 2 apresenta a arquitetura do modelo, organizada em três fases denominadas de *Social Context Generation*, *Situation Assessment* e *Item Assessment*. O modelo é ainda composto por uma interface que entrega uma recomendação personalizada ao usuário e permite que este dê *feedback* sobre a recomendação fornecida, a fim de que o sistema possa levar em consideração essa informação em recomendações futuras.

Figura 2 – Arquitetura do modelo



Fonte: (GALLEGO *et al.*, 2012)

Para gerar recomendações proativas, foram utilizadas as seguintes categorias de contextos:

- Contexto social: as ligações (por exemplo, interesses comuns e perfis relacionados) entre os usuários na plataforma *ViSH* que permitem agrupá-los por similaridade;
- Contexto de localização: temporal (por exemplo, horário atual) e de informação geográfica (por exemplo, nacionalidade ou língua);
- Contexto do usuário: a atividade atual do usuário (por exemplo, se está consultando a plataforma *ViSH* através de um dispositivo móvel ou de um computador de mesa).

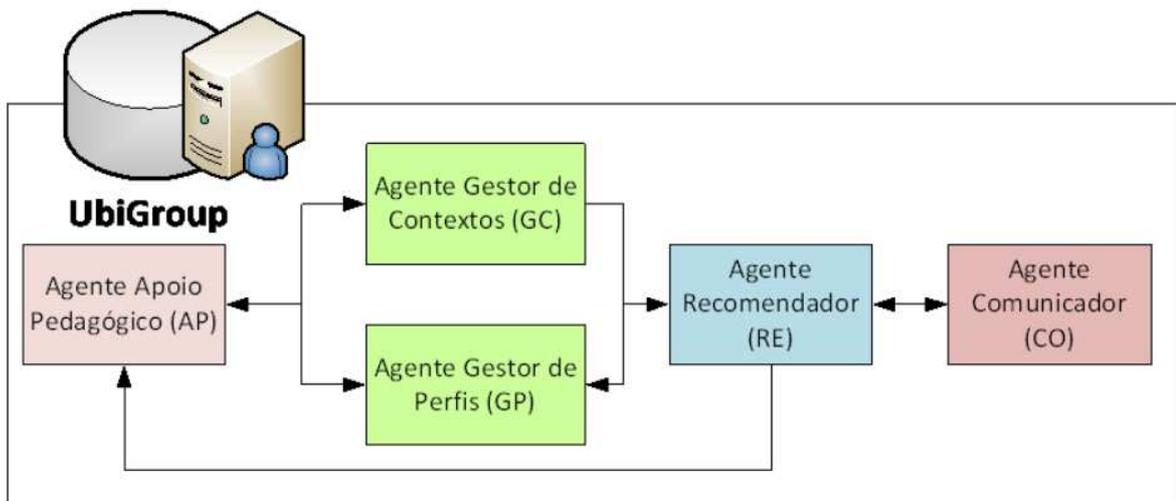
3.2 Ubigroup

Segundo (FERREIRA *et al.*, 2015), o Ubigroup se propõe a ser um modelo de recomendação ubíqua de conteúdo educacional para grupos de aprendizes, que visa auxiliar o professor no processo de busca e seleção de materiais educacionais levando em conta os perfis dos alunos e o contexto onde eles estão inseridos. Para alcançar o objetivo de recomendar Objetos de Aprendizagem, foi feita a integração entre os perfis dos aprendizes e o contexto onde eles estão inseridos.

No modelo foi levado em consideração a problemática de busca de materiais pedagógicos adequados ao plano de ensino dos professores. Por conta de existir uma vasta quantidade de material disponível, pode ser dispendioso encontrá-los e, quando encontrados, seria necessário avaliar se além de alinhado ao plano de ensino, eles também seriam apropriados ao perfil de aprendizado do aluno e se consideram aonde o aprendizado acontece. Maior complexidade ocorre quando a atenção se estende para uma turma, ou grupo, de aprendizes.

A arquitetura do Ubigroup se divide em cinco agentes de software, conforme apresentado na Figura 3. Esses agentes são assim nomeados: Agente Apoio Pedagógico (AP), o responsável por obter as informações do aprendiz e de informá-lo sobre novas recomendações; Agente Gestor de Perfis (AG) tem como finalidade manter atualizados os perfis dos aprendizes e gerar a similaridade entre eles; Agente Gestor de Contextos (GC) é quem gerencia os contextos; Agente Recomendador (RE) mantém as regras de recomendação; e Agente Comunicador (CO) que efetua a comunicação com os repositórios de OA's.

Figura 3 - Arquitetura do Ubigroup



Fonte: (FERREIRA *et al.*, 2015)

Para melhor compreensão do funcionamento dos agentes, os mesmos são descritos da seguinte forma:

- Agente Apoio Pedagógico (AP): seu papel é monitorar as movimentações do aluno e enviar esta informação para o agente GC. Se o agente GC identificar que o aluno está inserido em um contexto, notifica o agente AP que, por sua vez, avisa o aluno que ele se encontra em um determinado contexto;
- Agente Gestor de Perfis (GP): mantém os perfis dos aprendizes atualizados, através de um cálculo de similaridade entre eles. Realiza o envio credenciais de acesso ao aprendiz e o retorna se as credenciais foram autorizadas. Foi utilizada uma ontologia para representar o perfil do aprendiz;
- Agente Gestor de Contexto: preserva os contextos utilizados pelo UbiGroup e informa o agente RE sobre alterações ocorridas em relação a entrada ou saída de membros do contexto. Também se usou uma ontologia para representar a informação de contexto;
- Agente Recomendador: conserva as regras e realiza as etapas necessárias para preparar, executar e encaminhar a recomendação. Uma regra de recomendação é definida como um conjunto de relações entre o perfil do aprendiz, o contexto e os metadados dos OA's;

- Agente Comunicador: efetua, com o uso de Webservices, a comunicação com os repositórios de OA's. A partir de uma solicitação do agente RE, é efetuado o acesso ao(s) repositório(s) cadastrado(s) retornando as informações solicitadas.

3.3 Assistente de Recomendação baseado na Metodologia da Problematização

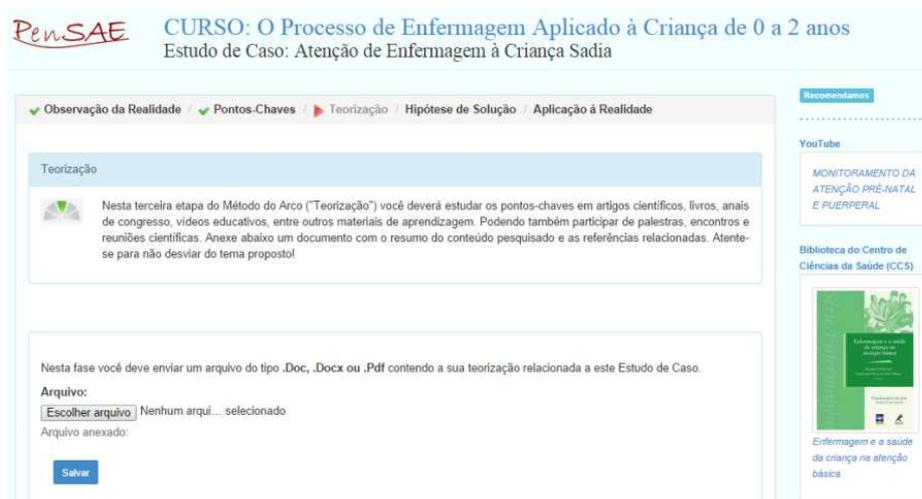
Neste trabalho é proposto um assistente de recomendação sensível ao contexto integrado a um ambiente educacional baseado na Metodologia da Problematização e operacionalizado pelo Arco de Maguerz (GOMINHO; TEDESCO; BELIAN, 2014). O assistente foi desenvolvido para realizar recomendação de recursos de aprendizagem (objetos de aprendizagem, artigos e livros).

O projeto foi concebido com base no ambiente de aprendizagem PenSAE (GOMES; BELIAN; LIMA, 2014), o qual utiliza o método do Arco de Maguerz com foco na aquisição de competências e habilidades necessárias à prática do processo de Enfermagem. A intenção de usar o PenSAE como referência, foi a possibilidade de que ele pudesse ser usado, com adaptações, em qualquer área de conhecimento e não apenas à área de Enfermagem. Criou-se uma instância do assistente de recomendação integrado ao ambiente de aprendizagem, a qual foi denominada PenSAE+.

Para projetar o PenSAE foi utilizada a documentação do PenSAE como entrada para o framework CEManTIKA (VIEIRA; SANTOS, 2008), que tem como objetivo apoiar o projeto de sistemas sensíveis ao contexto em diferentes domínios, o qual é composto por quatro elementos principais: (i) uma arquitetura genérica para sistemas sensíveis ao contexto; (ii) um metamodelo de contexto independente de domínio; (iii) um conjunto de perfis UML (*Unified Modeling Language*); (iv) e um processo que direciona a execução de atividades relacionadas à especificação do contexto e ao projeto de sistemas sensíveis ao contexto.

O trabalho utilizou a linguagem de programação *Ruby* e seu *framework* popular conhecido como *Rails*, além de utilizar o *PostgreSQL* como sistema gerenciador de banco de dados. Com isso foram percorridas as cinco etapas do Arco de Maguerz para o propósito do estudo de caso. Na Figura 4 é apresentada a interface do PenSAE.

Figura 4 – Apresentação do sistema PenSAE



No protótipo desenvolvido para o trabalho, as recomendações se baseiam nas preferências do tipo de material no qual o aluno prefere estudar e no domínio do estudante nos idiomas português, inglês e espanhol.

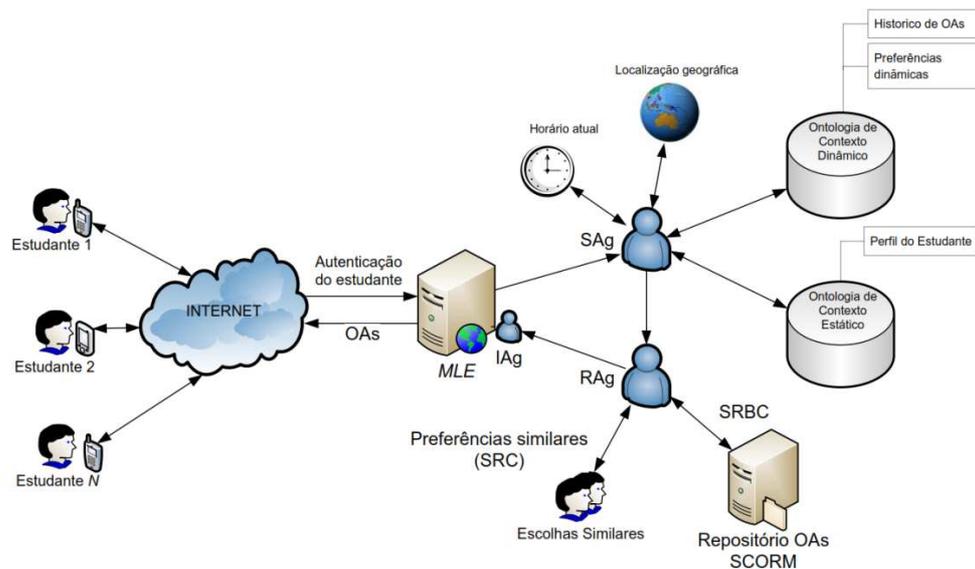
3.4 MobiLE

MobiLE é um trabalho com uma abordagem baseada em agentes para recomendação sensível ao contexto de Objetos de Aprendizagem, com o intuito de aperfeiçoar o processo de ensino na aprendizagem móvel (SILVA, LUIZ CLÁUDIO NOGUEIRA DA; NETO; JÚNIOR, 2011). Levou em consideração que uma das formas de se prover a Educação a distância é através do uso de dispositivos móveis, modalidade que também é conhecida como Aprendizagem Móvel, do inglês *Mobile Learning* ou *m-learning*.

Para elaboração do MobiLE, determinados fatores foram adotados almejando a melhora da eficácia da absorção de conhecimento por parte dos estudantes na aprendizagem móvel. Características particulares de cada estudante e a provisão de conteúdos de forma adequada, considerando as características cognitivas do estudante, são alguns deles. Dessa forma foi adotado o conceito de ambientes sensíveis ao contexto (*context-aware environments*), pois este tipo de ambiente se adequa ao perfil do usuário e também considera informações fornecidas pelo próprio usuário, além das que dinamicamente são absorvidas a partir da interação com os dispositivos computacionais (MOORE *et al.*, 2009).

O trabalho aglutinou temas como sistemas multiagentes, objetos de aprendizagem, sistemas de recomendação e ambientes sensíveis ao contexto. A arquitetura do ambiente proposto é apresentada na Figura 5. Nela foram implementados três tipos de agentes de software: Agente Estudante (SAg - *Student Agent*), Agente Recomendador (RAg - *Recommender Agent*) e Agente de Interface (IAg - *Interface Agent*). A Figura 5 apresenta a arquitetura do MobiLE.

Figura 5 - Arquitetura do MobiLE



Fonte: (SILVA, LUIZ CLÁUDIO NOGUEIRA DA; NETO; JÚNIOR, 2011)

- SAg - Student Agent: agente responsável por monitorar as atividades dos estudantes e recuperar as preferências de aprendizagem que compõem os perfis dos estudantes e os seus respectivos históricos de escolha de OA's. Com base no histórico de escolha, o SAg encontra outros estudantes que possuem escolhas similares. Realizam também a captura das informações do contexto dinâmico do estudante, além de sua localização geográfica e o horário atual. Todas as informações são enviadas para o RAg;
- RAg - Recommender Agent: agente que tem o intuito de detectar OA's adequados ao contexto do estudante, de acordo com as informações providas pelos SAGs e as informações obtidas dos OA's disponíveis no repositório. Após identificar OA's adequados, o RAg informa ao IAg quais são os possíveis OA's a serem sugeridos;
- IAg – Interface Agent: agente responsável por verificar a adequação do OA a ser recomendado às características do dispositivo móvel do estudante e adequar a apresentação do conteúdo ao dispositivo móvel, quando apropriado. Tem também a responsabilidade de informar ao instrutor o conteúdo que foi sugerido.

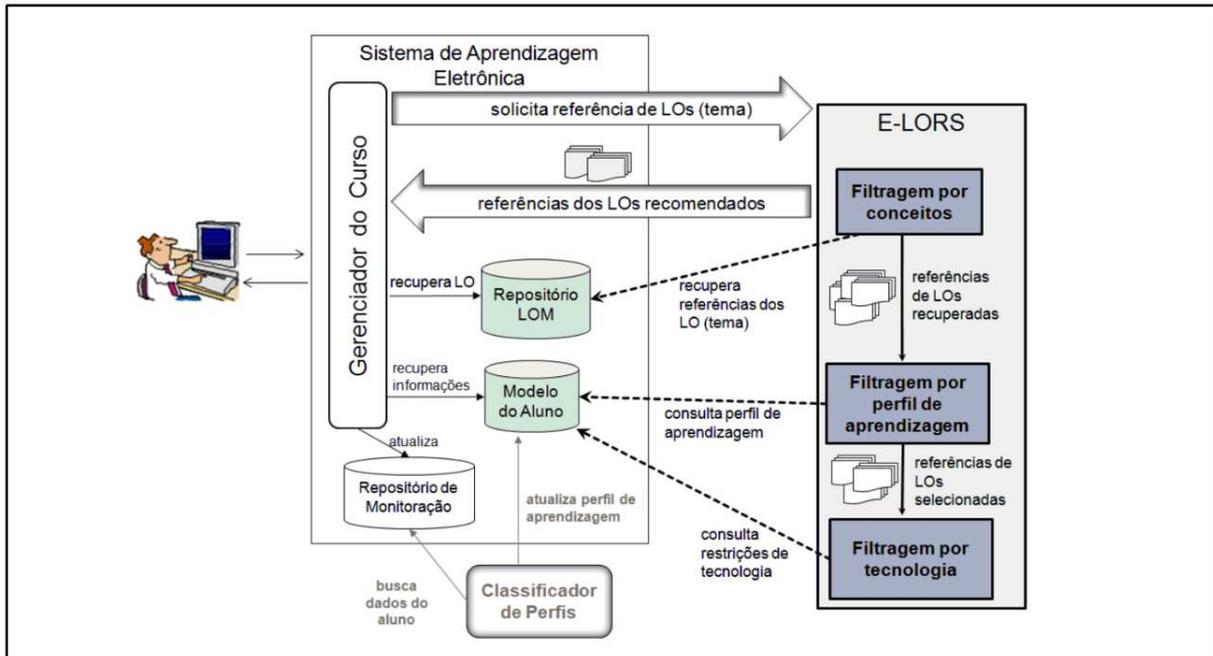
Os agentes descritos no MobiLE foram desenvolvidos utilizando o JADE (*Java Agent Development Framework*), uma plataforma para desenvolvimento e execução de sistemas multiagente (JADE, 2011). Também foi utilizado o framework de desenvolvimento de aplicações MLE (*Mobile Learning Engine*) (MLE, 2011) para a construção do ambiente. O sistema de recomendação implementado foi baseado em conceitos de SRH (Sistema de Recomendação Híbrido), visto que considera não apenas o conteúdo dos OA's em relação ao perfil do estudante (SRBC - Sistema de Recomendação Baseada em Conteúdo), como também a comparação de estudantes com preferências semelhantes (SRC - Sistema de Recomendação Colaborativo).

3.5 e-LORS

O trabalho e-LORS (*e-Learning Object Recommendation System*), segundo (ZAINA *et al.*, 2012), é uma abordagem para a recomendação de conteúdo eletrônico baseada no relacionamento entre perfis e objetos de aprendizagem. Em sua metodologia, perfis de aprendizagem são descritos por dimensões discretas de maneira a atender diferentes perspectivas de preferência do estudante. Quanto à metodologia de recomendação, estas dimensões são usadas para filtrar os objetos de aprendizagem mais adequados ao estudante.

O modelo proposto se baseia nos conceitos empregados nos sistemas de recomendação, utilizando um algoritmo de filtragem da informação baseada em conteúdo. A arquitetura e-LORS foi especificada de maneira que possa ser utilizada por diferentes sistemas de aprendizagem eletrônica. A recomendação de objetos é realizada confrontando-se as informações do tema de estudo a ser apresentado ao aluno, o perfil de aprendizagem do aluno, e as possíveis restrições tecnológicas que caracterizam o ambiente eletrônico em que o aluno interage. A Figura 6 apresenta a arquitetura e-LORS e sua integração com um sistema de aprendizagem eletrônica.

Figura 6- Arquitetura do modelo e-LORS



Fonte: (ZAINA *et al.*, 2012)

No trabalho foi identificada a necessidade de haver uma confrontação de informações particulares sobre um determinado aluno, com os requisitos necessários para a recomendação de conteúdo. Para este propósito é importante ter um modelo de aluno bem definido, contendo informações diversas. Esse modelo de aluno deve ser construído de acordo com as necessidades que um determinado sistema tem para automatizar suas tarefas.

O modelo do aluno adotado nesse trabalho divide as preferências do estudante em dimensões que são baseadas na proposta de Felder e Silverman (FELDER; SILVERMAN, 1988). As dimensões utilizadas pelo e-LORS são: Percepção, Formato-Apresentação e Participação do Aluno. Para ao modelo não foi adotada a dimensão Sequência. Além das dimensões de Felder e Silverman, o modelo apresenta informações pessoais do aluno, e características tecnológicas relacionadas ao acesso do aluno.

O e-LORS foi elaborado para ser adotado em diferentes arquiteturas de sistemas de aprendizagem eletrônica. Para que isso seja possível, alguns requisitos devem ser atendidos: (i) armazenagem e o gerenciamento dos objetos de aprendizagem utilizando o padrão LOM (“Draft Standard for Learning Object Metadata”, 2002); (ii) adoção de um modelo do aluno que descreva o perfil de aprendizagem usando dimensões de preferências baseadas em Felder e Silverman; (iii) determinação de preferências de aprendizagem através de, por exemplo, uso de questionários respondidos diretamente pelo aluno, o qual irá expressar suas preferências de acordo com cada dimensão; e (iv) utilização do item que descreve a tecnologia no modelo do aluno, porém esta característica é opcional.

3.6 AICAPA

O modelo AICAPA é um ambiente inteligente e colaborativo para apoio à produção acadêmica (MENEZES; VALE; CRUZ, 2014). Mais especificamente, é um ambiente colaborativo na web, que tem por objetivo apoiar a revisão da literatura, atividade fundamental para dar suporte a todo trabalho acadêmico, através de técnicas de Recomendação e de Recuperação da Informação baseada em conhecimentos sobre o contexto do problema de pesquisa. O trabalho considera que o crescimento exponencial na quantidade de informações na web tem tornado a busca de documentos uma tarefa problemática, pois o grande volume e diversidade de conteúdo disponível na web trazem dificuldades na busca e seleção de material interessante.

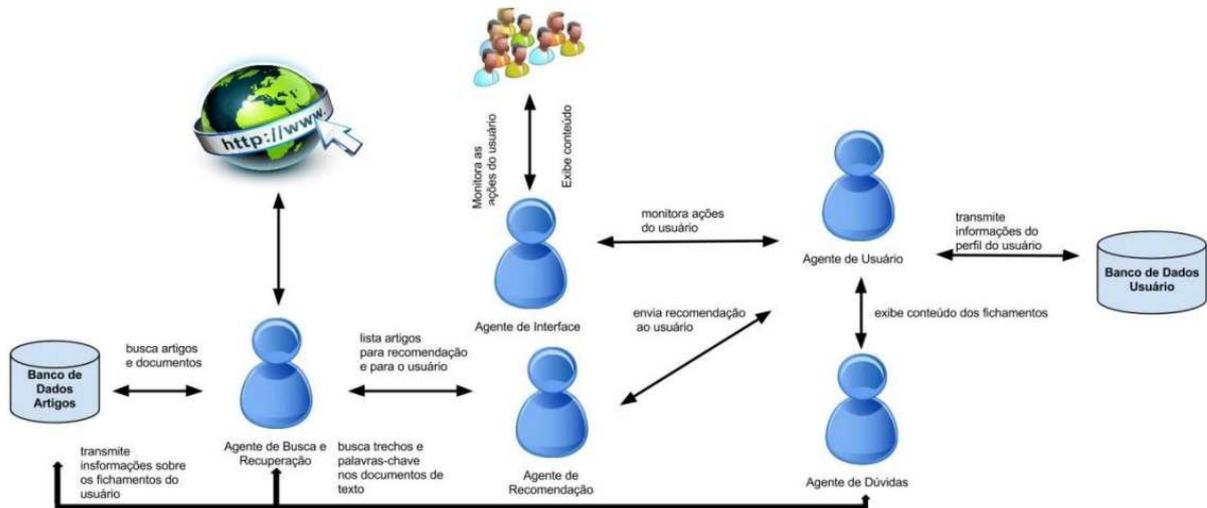
O AICAPA tem como objetivo principal fornecer uma ferramenta colaborativa que automatize o processo de busca e seleção de artigos relevantes na web para reduzir os esforços realizados no processo de revisão da literatura. Além disso, a ferramenta conta com apoio de diversas outras funcionalidades que contribuirão significativamente no tempo gasto utilizado na elaboração de trabalhos acadêmicos, através do uso de técnicas de recomendação, recuperação de artigos e de esclarecimento de dúvidas.

O ambiente funciona coletando dados do usuário através do seu cadastramento, para que o sistema possa construir um perfil inicial de interesses e recomendar grupos, pessoas e artigos com os dados do seu perfil. A ferramenta permite que usuários compartilhem e colaborem com diversas pessoas, sendo possível a formação de grupos: públicos e privados, através dos quais o usuário pode compartilhar documentos. Para que haja recomendação será preciso que cada usuário e grupo tenham seus perfis de interesse.

Conforme apresentado pela Figura 7, a arquitetura do AICAPA é composta por cinco agentes:

- Agente de Interface: exibe o conteúdo ao usuário, coleta toda a interação do usuário no ambiente que considere relevante e encaminha ao Agente de Usuário para que a base de perfis seja atualizada;
- Agente de Usuário: atualiza a Base de Dados do usuário e emite os dados do usuário ao Agente Recomendador para que seja encaminhado ao Agente de Busca e Recuperação, a fim de buscar artigos na web e armazená-los na base de dados local. É responsável por garantir que o conjunto de perfis reflita os interesses dos usuários;
- Agente de Busca e Recuperação: responsável por invocar mecanismos de busca e recuperação de artigos existentes na web, obter seus resultados e armazená-los numa base de dados local. Faz a função de recuperação de informação;
- Agente de Recomendação: sugere documentos, pessoas e grupos semelhantes aos perfis dos usuários. Ele recebe os dados alterados do perfil do usuário pelo Agente de Usuário, realiza cálculos de similaridade e solicita ao Agente de Busca e Recuperação para localizar documentos, pessoas e grupos adequados àquele usuário;
- Agente de Dúvidas: responsável por identificar as dúvidas do usuário, comparar as palavras-chaves contidas nestes questionamentos e palavras-chave em artigos relacionados ao tema explorado; realiza extração de trechos de texto de artigos da base de dados a partir das palavras-chaves comparadas; e também encaminha dúvidas para usuários especialistas na área.

Figura 7 - Arquitetura do AICAPA



Fonte: (MENEZES; VALE; CRUZ, 2014)

Para elaboração do ambiente colaborativo foi proposta a utilização dos seguintes recursos tecnológicos: linguagem de programação PHP5, servidor *web Apache*, banco de dados *MySQL* e a ferramenta *Protegé* para implementação de ontologias.

3.7 RECoaComp

Neste trabalho é descrito um relato de experiência de desenvolvimento e validação de um Sistema para Recomendação de Objetos de Aprendizagem baseado em competências (CAZELLA *et al.*, 2012). O trabalho levou em consideração o avanço tecnológico, que trouxe novas concepções de ensino e aprendizagem, assim como diferentes possibilidades de desenvolver conteúdos por meio de OA's. Identificou que, assim como outros trabalhos, os repositórios que são construídos para os OA's acabam apresentar muitos conteúdos sem relevância.

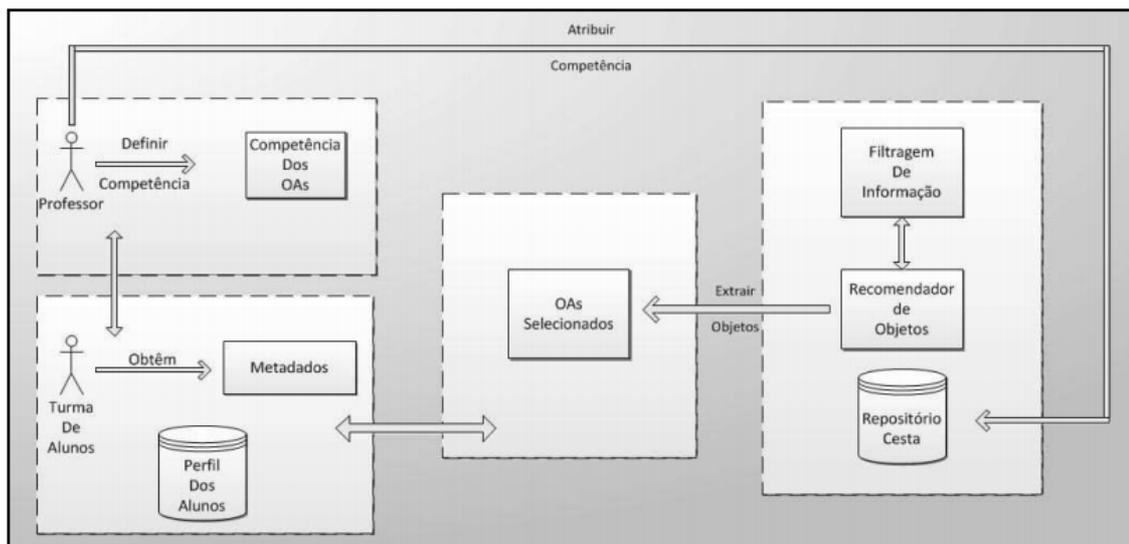
O trabalho tem o objetivo de filtrar os objetos de aprendizagem de acordo com as competências a serem construídas e que foram sinalizadas nos perfis dos usuários. Usou o entendimento de que a competência é composta de Conhecimentos, Habilidades e Atitudes, conhecido como CHA, que podem ser construídos com o apoio de tecnologias digitais.

O RECoaComp é, portanto, um modelo recomendador de objetos de aprendizagem baseado em competências. Na Figura 8 é apresentada a visão macro do modelo, e seu funcionamento é composto por três etapas:

- Seleção dos objetos de aprendizagem por parte do professor da disciplina, visando a construção de competências específicas. Ele atribui às competências que esses objetos podem ajudar a suprir. Um OA pode atender mais de uma competência específica;

- Respostas dos alunos a um questionário acerca das competências relevantes para a disciplina, definidas pelo professor, realizando uma auto avaliação, viabilizando a recomendação de OA's;
- Filtragem de informação, selecionando e recomendando Objetos de Aprendizagem aos alunos. Estes objetos são selecionados diretamente do repositório escolhido, relacionando o objeto e os dados do perfil, especialmente quanto às competências.

Figura 8 - Modelo RECoaComp



Fonte: (CAZELLA *et al.*, 2012)

Para verificação e avaliação do protótipo do sistema de recomendação desenvolvido a partir do modelo RECoaComp, o mesmo foi aplicado a uma turma composta por alunos de dois Programas de Pós-Graduação durante o 2º semestre de 2011. O grupo formado por 25 alunos foi convidado a participar do primeiro experimento que teve como objetivo validar e avaliar o sistema, enquanto no segundo experimento 32 alunos foram convidados.

O primeiro experimento consistia: (i) no cadastro no sistema, com preenchimento de formulário de definição de perfil relacionado às competências; (ii) inserção de objetos desenvolvidos pelo núcleo de pesquisa em um formulário baseado nos metadados de um repositório desenvolvido na Universidade; (iii) avaliação por parte dos os alunos dos grupos se o OA que estava sendo cadastrado permitia construir as competências; (iv) revisão das classificações realizadas para identificação de pequenas distorções e adequação do preenchimento no sistema; (v) avaliação do recomendador que consistia em um feedback dentro de uma escala numérica (*Likert* de 5 pontos, sendo “Péssimo” quando não atendia à necessidade de formação em competências e “Excelente” quando o OA atendia essa necessidade de forma direta).

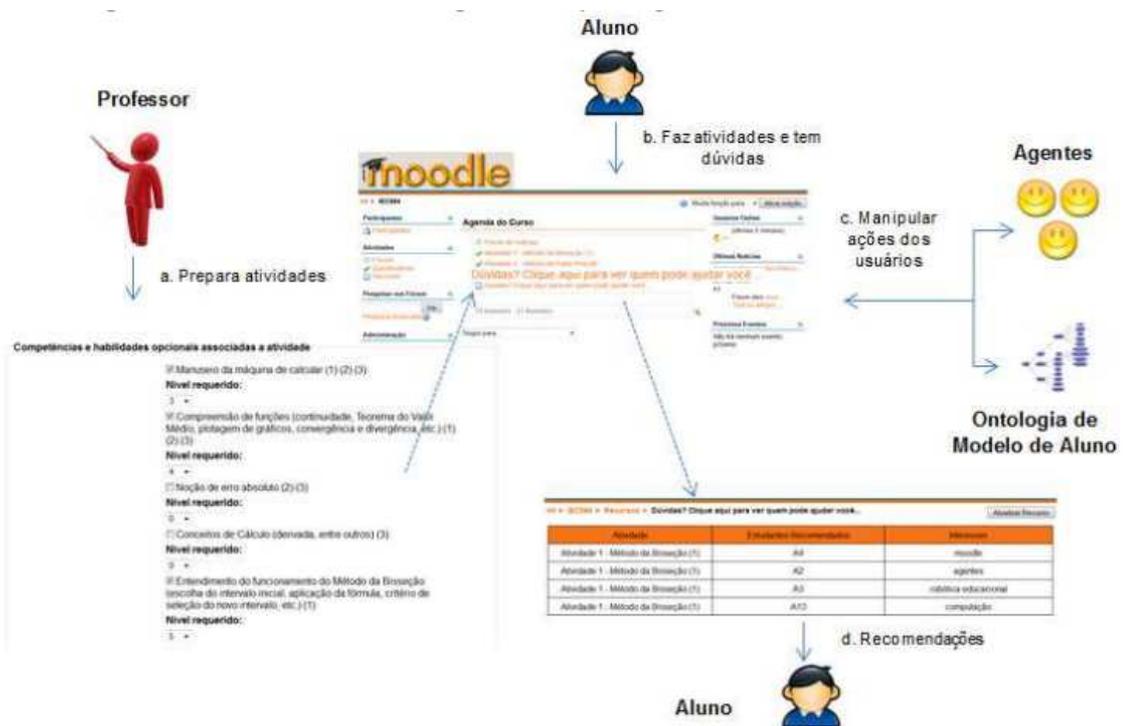
O segundo experimento abrangeu uma melhoria na interface do sistema. Foram utilizadas as seguintes tecnologias: *JavaServer Faces JSF* (na camada de visualização), *PrimeFaces*, *Java Persistence API – JPA* com *Hibernate* (camada de persistência) e *MySQL*. O modelo não sofreu alterações quanto às suas funcionalidades.

3.8 Auxílio Personalizado a Alunos em Ambiente Virtual de Aprendizagem Utilizando Agentes

Este trabalho descreve uma experiência com a oferta na modalidade semipresencial da disciplina Cálculo Numérico no curso de graduação em Matemática na Universidade Federal do Amazonas (BREMARTNER; NETTO, 2012). Trata do auxílio a alunos com dúvidas no Ambiente Virtual de Aprendizagem utilizado, por meio da utilização de agentes de software. Tal auxílio é a recomendação personalizada de colegas aptos para ajudar em função de suas habilidades e competências. O AVA é executado em conjunto com um Sistema Multiagente de apoio às dúvidas que os alunos têm sobre determinado assunto na disciplina.

O trabalho identificou que em um AVA, apesar de haver professores e tutores monitorando um curso, não há um gerenciamento de forma automática e eficaz com relação ao acompanhamento das dúvidas e de seus esclarecimentos que os alunos possuem sobre um determinado assunto. Como proposta de solução ao problema, criou-se uma camada de inteligência formada por um sistema multiagente que foi acoplada ao ambiente educacional, utilizando uma ontologia que descreve o modelo de aluno para auxiliar as atividades dos alunos pela indicação personalizada de algum estudante do mesmo curso. Uma visão geral do sistema é apresentada na Figura 9.

Figura 9 - Visão geral do sistema



Fonte: (BREMARTNER; NETTO, 2012)

O sistema trabalha com as seguintes fases:

- **Prepara atividades:** O professor elabora e solicita as atividades. Para tal, no Moodle foi acrescentado um recurso ao se criar uma nova atividade, permitindo associar competências e habilidades necessárias com as atividades propostas;
- **Faz atividades e tem dúvidas:** Na medida em que os alunos vão interagindo com o ambiente, seus modelos são atualizados no banco de dados do Moodle pelo sistema multiagente composto de sete agentes. O SMA também é responsável, juntamente com a ontologia desenvolvida, por procurar os estudantes com melhores níveis de competências e habilidades específicas capazes de ajudar aquele aluno que estiver com dúvidas em atividades;
- **Manipular ações dos usuários:** os estudantes com perfis adequados encontrados pelo sistema multiagente são recomendados no Moodle para aquele aluno que tem dúvidas;
- **Recomendações:** Processo de recomendação.

Há um total de sete agentes no sistema. Três de atualização (*Initial Skills Agent*, *Update Profile Agent* e *Activity Assessment Agent*), dois de recomendação (*Doubt & Error Profile Agent* e *Recommended Profile Agent*) e dois de tutoria (*Notifier Activity Agent* e *Help Tutor Agent*).

O *Initial Skills Agent*, configura os níveis de habilidades e competências iniciais dos alunos e envia estas informações ao *Update Profile Agent*, responsável por atualizar os dados dos modelos de alunos mediante as interações dos mesmos com o ambiente. O *Activity Assessment Agent*, se responsabiliza pela avaliação das questões respondidas, e envia as pontuações dos alunos ao *Update Profile Agent*.

O *Doubt & Error Profile Agent*, faz a busca por dúvidas e erros dos alunos com base nos resultados das questões respondidas no ambiente e mapeia tais erros em habilidades e competências necessárias para a realização das tarefas. O *Recommended Profile Agent* recebe dados da existência de alunos com dúvidas e erros, e busca por alunos com níveis de habilidades e competências específicas capazes de resolver as questões propostas.

Por fim, o *Notifier Activity Agent*, informa aos estudantes as novas atividades solicitadas pelo professor. O *Help Tutor Agent* é responsável por enviar dois tipos de mensagens. Mensagens para os alunos com dúvidas, enviando um link que eles podem acessar para ver seus colegas recomendados, e mensagens para alunos que não entregaram a tarefa no prazo estabelecido pelo professor.

3.9 Otilia

Otilia (MOTA; DE CARVALHO; REIS, 2014) é um trabalho que propõe um mecanismo de recomendação, apoiado por uma abordagem de modelagem ontológica, para ajudar os professores a preparar atividades de ensino-aprendizagem e melhorar o uso de diferentes técnicas de aprendizagem. O trabalho leva em conta a importância da criação de ferramentas de *design* baseadas em computador para ajudar os professores na elaboração de cenários de aprendizagem, mais precisamente as atividades de ensino-aprendizagem. Considera também que essas ferramentas são mais valiosas se enriquecidas com características especiais,

como, por exemplo, modelos, scripts ou assistentes usados para orientar o professor através do processo de design.

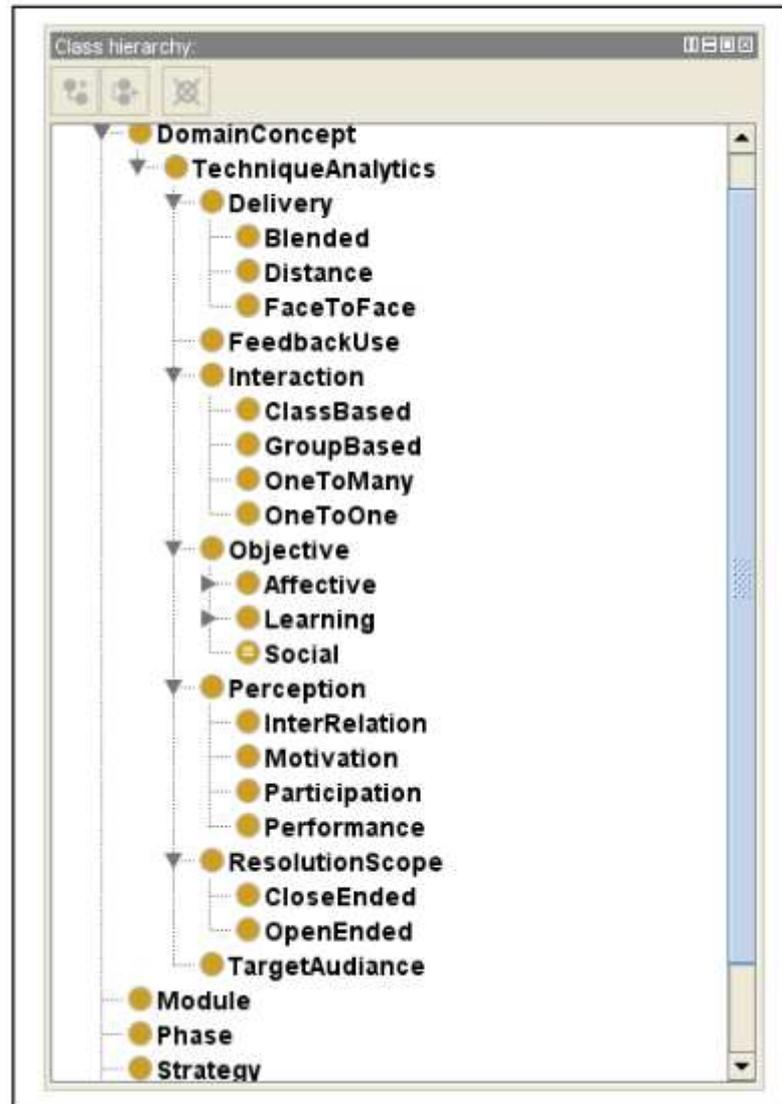
Foi avaliado que o projeto de atividades de ensino-aprendizagem, do inglês *teaching-learning* (TL), é uma questão importante, tanto para professores como para a comunidade científica. Os motivos são uma separação histórica entre a aprendizagem, como sendo o domínio de psicólogos e o ensino, como sendo o domínio de educadores. Também porque não é fácil de compreender, dominar e integrar em um contexto de ensino-aprendizagem, diferentes técnicas de ensino-aprendizagem. Usou-se como exemplo, uma sala de aula onde ensinar para certo número de alunos pode ser uma limitação para a aplicação de algumas técnicas de TL, como, por exemplo, prevenção de uma seleção correta entre técnicas individuais, de colaboração ou de cooperação.

O Otilia trabalha com recomendações e é parte de um trabalho maior denominado de ACEM, este visa auxiliar os educadores no design colaborativo de atividades de aprendizagem, apoiado por uma projeto de ferramenta gráfica.

O principal objetivo do OTILIA é modelar técnicas de TL para fins de recomendação. Foi afirmado no trabalho que este tipo de ferramenta vai ajudar os professores em diversificar as técnicas TL e adaptar atividades de TL para as condições de contexto do ambiente. O processo de descrição do OTILIA pode ser dividido em três seções: (i) questões de domínio e de competência; (ii) descrição de conceitos e; (iii) descrição do processo de recomendação. Na Figura 10 são apresentados os conceitos ontológicos do Otilia.

- Questões de domínio e de competências: Para a descrição da solução ontológica foram definidos o domínio e o escopo, sendo que o domínio está relacionado com técnicas de ensino-aprendizagem, enquanto que o escopo compreende questões de competência. Palavras como “produtividade”, “participação” e atividades “críticas” foram consideradas palavras-chave na busca de respostas para questões que envolviam essas palavras;
- Descrição de conceitos: técnicas de TL formam o principal conceito da ontologia. Essas técnicas foram descritas como um conjunto de tarefas que os estudantes deveriam desenvolver a fim de concluir uma atividade. Trata-se de uma sequência de fases, onde cada fase trata de uma série de aprendizados e tarefas de apoio. Na Figura 10 são apresentados os conceitos de ontologia do OTILIA;
- Descrição do processo de recomendação: Um profissional da área da psicologia educacional é responsável pela definição de regras de aplicabilidade de uma técnica de TL que são então adicionadas à OTILIA pelo engenheiro de ontologias. Os processos cognitivos inerentes a essas regras são comparados com os objetivos de aprendizagem que foram definidos pelo professor durante a inicialização da atividade de TL.

Figura 10 - Ontologia do Otilia



Fonte: (MOTA; DE CARVALHO; REIS, 2014)

3.10 Comparação

Para fins de comparação dos trabalhos pesquisados, foram definidos critérios considerados estratégicos. A Tabela 1 apresenta um comparativo dos trabalhos. A seguir encontram-se os critérios, bem como suas descrições:

- **Objetos de aprendizagem:** informa se ocorre a recomendação de objetos de aprendizagem ao usuário;
- **Sensibilidade a contextos:** identifica se no trabalho foi abordado algum tipo ou conceito de contextos, segundo (DEY, 2001);
- **Utiliza Agentes:** avalia se foi empregado o uso de agentes no trabalho;
- **Utiliza Ontologia:** identifica se houve alguma representação em forma de ontologia;

- Público-alvo: identifica qual o usuário foi focado no trabalho. Para esse critério foram definidos três grupos para tipificar o público-alvo: Aprendizes, Professores e Coordenadores de Curso;
- Utiliza perfis: avalia se houve uso de gerenciamento de perfis no trabalho. Para este critério foram definidos quatro grupos: Perfil de Usuário, Perfil de aprendizado, Perfil de usuário e seus interesses, e Perfil de usuário com abordagem de entrega de aprendizado;
- EAD: informa se houve abordagem na Educação a distância no escopo do trabalho.

Tabela 1- Comparação de trabalhos

Critérios Trabalhos	OA's	Contexto	Agentes	Ontologias	Público-alvo	Perfis	EAD
Geração recomendações sensíveis a contexto (GALLEGO <i>et al.</i> , 2012)	Sim	Social, localização e do usuário	Não	Não	Aprendizes e Professores	Usuário	Sim
Ubigroup (FERREIRA <i>et al.</i> , 2015)	Sim	Momento do aprendizado	Sim	Sim	Aprendizes e Professores	De aprendizado	Não
Recomendação baseado na Problematização (GOMINHO; TEDESCO; BELIAN, 2014)	Sim	Conjunto de dado, informação ou conhecimento	Não	Não	Aprendizes	Usuário	Não
MobiLE (SILVA, LUIZ CLÁUDIO NOGUEIRA DA; NETO; JÚNIOR, 2011)	Sim	Estático, considerando local, dia e horário	Sim	Sim	Aprendizes	Usuário	Não
e-LORS (ZAINA <i>et al.</i> , 2012)	Sim	Ações que o usuário executa	Não	Não	Aprendizes	Usuário	Não
AICAPA (MENEZES; VALE; CRUZ, 2014)	Não	Problema de Pesquisa	Sim	Sim	Professores (pesquisadores)	Usuário (interesses)	Não
RECoaComp (CAZELLA <i>et al.</i> , 2012)	Sim	Desenvolvimento do	Não	Não	Aprendizes e Professores	Usuário	Sim

		aprendizado					
Auxílio Personalizado com Agentes (BREMGGARTNER; NETTO, 2012)	Não	Não	Sim	Sim	Aprendizes e Professores	Usuário	Sim
Otilia (MOTA; DE CARVALHO; REIS, 2014)	Não	Aprendizado (aprendiz) e Criação de cenários (Professor)	Não	Sim	Professores	Usuário, com abordagem de entrega do aprendizado	Sim

Fonte: Próprio autor

No critério OA's percebe-se que diversos trabalhos abordam a recomendação desses objetos para o usuário. Isso se deve ao foco dado pelos trabalhos no aprendiz.

Apenas um dos trabalhos, Auxílio Personalizado com Agentes (BREMGGARTNER; NETTO, 2012), não utiliza sensibilidade a contextos. Todos os demais adotam algum tratamento específico de contextos. É perceptível que, cada trabalho segue uma direção diferente na utilização de sensibilidade a contextos.

No critério de utilização de agentes apenas Ubigroup (FERREIRA *et al.*, 2015), MobiLE (SILVA, LUIZ CLÁUDIO NOGUEIRA DA; NETO; JÚNIOR, 2011), AICAPA (MENEZES; VALE; CRUZ, 2014) e Auxílio Personalizado com Agentes (BREMGGARTNER; NETTO, 2012) o fazem. No restante dos trabalhos não houve a adoção de agentes de software.

No critério de ontologias, os mesmos quatro trabalhos que fazem uso de agentes também abordaram ontologias em seu desenvolvimento. Além deles, Otilia (MOTA; DE CARVALHO; REIS, 2014) também usou ontologia para representação de conhecimento.

Quanto ao público-alvo, nota-se que todos os trabalhos têm algum destinatário da recomendação educacional. Há trabalhos com apenas um público-alvo, Recomendação baseada na Problemática (GOMINHO; TEDESCO; BELIAN, 2014), MobiLE (SILVA, LUIZ CLÁUDIO NOGUEIRA DA; NETO; JÚNIOR, 2011), e-LORS (ZAINA *et al.*, 2012), AICAPA (MENEZES; VALE; CRUZ, 2014) e Otilia (MOTA; DE CARVALHO; REIS, 2014). Os demais recomendam para mais de um público.

Todos os trabalhos fazem abordagem a uso de perfis, em sua grande maioria usando perfis de usuários do sistema de recomendação.

No critério de aplicação na Educação a distância há um equilíbrio. Geração recomendações sensíveis a contexto, RECoaComp (CAZELLA *et al.*, 2012), Auxílio Personalizado com Agentes (BREMGGARTNER; NETTO, 2012) e Otilia (MOTA; DE CARVALHO; REIS, 2014) são os trabalhos que adotaram o escopo da EAD, enquanto que os demais não entraram nesse universo em específico.

Este capítulo apresentou nove trabalhos de sistemas de recomendação educacional e suas principais características. O próximo capítulo apresenta o M-SRECP, um modelo de sistemas de recomendação educacional para coordenadores de curso e professores, que busca:

- contribuir com características da sensibilidade a contextos, chamados de tópicos no modelo. Um maior detalhamento sobre os tópicos se dará na arquitetura do modelo, no capítulo seguinte;
- gerenciar perfis de usuários com base em seus metamodelos;
- gerenciar a entrega com base no perfil de cada usuário, onde os recursos tecnológicos usados na entrega são notificações em tempo real para aplicativos populares em dispositivos móveis, envio de SMS e de *e-mail*;
- utilizar dados provenientes de um sistema de predição de reprovação de alunos em disciplinas.

O M-SRECP gerencia os dados do sistema de predição de forma a recomendar ao coordenador do curso e/ou professor, dependendo do perfil de usuário de cada um, uma listagem de aprendizes com seus respectivos percentuais de risco de reprovação, a fim de estimulá-los a executarem ações pedagógicas, conforme sua área de conhecimento, visando a redução ou o impedimento da reprovação dos aprendizes. Essas recomendações ocorrem mais de uma vez durante o andamento da disciplina.

Diferentemente dos outros trabalhos, o modelo recomenda a coordenadores e professores. As recomendações acontecem repetidamente ao longo da disciplina, visando estimular tomadas de ações contínuas. O modelo também lida com a gerência de entrega da recomendação, conforme os metamodelos dos perfis de usuário.

4 MODELO M-SRECP

Neste capítulo será detalhado um modelo de sistema de recomendação educacional. Esse SRE explora a sensibilidade a contexto, tendo como público-alvo coordenadores de cursos e professores. O modelo tem o intuito de auxiliar na redução da reprovação de aprendizes em disciplinas, e recebe o nome de M-SRECP.

A primeira seção apresenta uma visão geral sobre o modelo e suas principais características. Na segunda seção é abordada a arquitetura do modelo. A terceira e quarta seção tratam, respectivamente, dos metamodelos dos perfis de coordenador de curso e professor. A quinta seção trata do módulo de consulta, que faz consultas sobre os aprendizes com risco de reprovação em disciplinas, em um sistema de predição externo. Na sexta seção é descrito o modelo de análise de dados, o qual vai tratar as informações obtidas pelo módulo de consulta e pelo cadastro feito através do módulo administrativo, a fim de identificar as formas de entrega da recomendação. A sétima seção descreve o funcionamento do módulo de notificação, que realiza a entrega de acordo com os perfis do usuário. Na oitava seção vista é discutido o módulo administrativo com CRM.

4.1 Visão geral

O M-SRECP é um modelo de sistema de recomendação educacional sensível a contextos, para coordenadores de cursos e professores, com foco na reprovação em disciplinas. Suas principais características são:

- Suporte a diversos níveis de EAD: apesar da abordagem a cursos de graduação e pós-graduação neste trabalho, o modelo não restringe o nível de ensino a ser gerenciado;
- Sensibilidade ao contexto: possibilita o gerenciamento de contextos, apontados neste trabalho como os tópicos (divisões) de uma disciplina de EAD;
- Gerenciamento repetitivo de recomendações: permite que durante o andamento de uma disciplina, vários momentos de recomendação possam ocorrer;
- Gerenciamento de perfil do usuário: permite a utilização de perfis de usuários para gerenciamento das recomendações;
- Suporte a gerenciamento de entrega de recomendação: com base no perfil do usuário, gerencia a entrega da recomendação;
- Área de administração: permite cadastrar e controlar as informações dos módulos do modelo;
- Atuação ativa: disponibiliza serviços para que tomadas de decisões sejam construídas e aplicadas utilizando as informações da recomendação, ou seja, qual aluno da disciplina pode vir a reprovar.

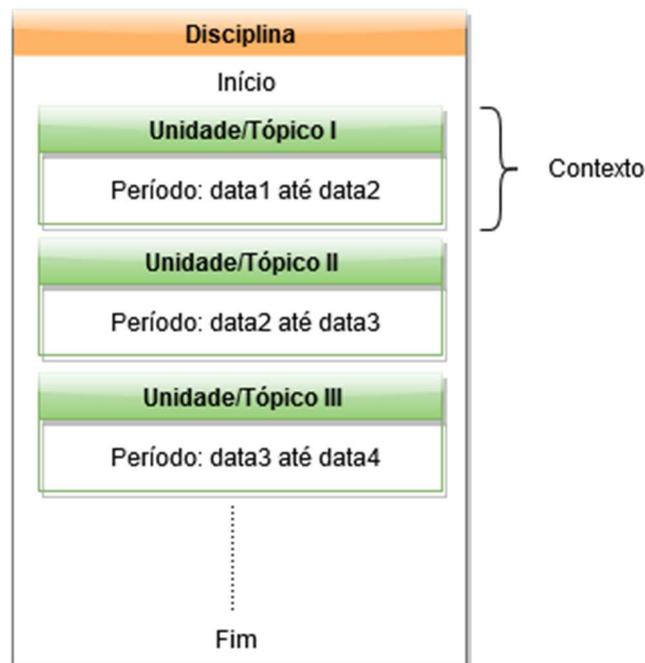
Com base nessas características, através dos seus módulos internos, o modelo permite que seja possível usar as informações de predição de reprovação de aprendizes em disciplinas, para serem realizadas recomendações a coordenadores e professores, com base em seus perfis.

4.2 Arquitetura

O M-SRECP é organizado em quatro componentes, chamados de módulos: Consulta, Análise de Dados, Notificação e Administrativo. O modelo propõe um SRE centrado na disciplina. No decorrer da disciplina, considerando sua divisão em tópicos, ocorre um processo de verificação de possíveis reprovados ao consultar um sistema externo de predição. Após essa etapa, notificações são feitas ao coordenador do curso e/ou ao professor da disciplina, e de acordo com o perfil destes, a entrega da recomendação é realizada. A Figura 11 apresenta a abordagem de tópicos como contextos, segundo o conceito de (DEY, 2001), e a Figura 12 apresenta a arquitetura do M-SRECP.

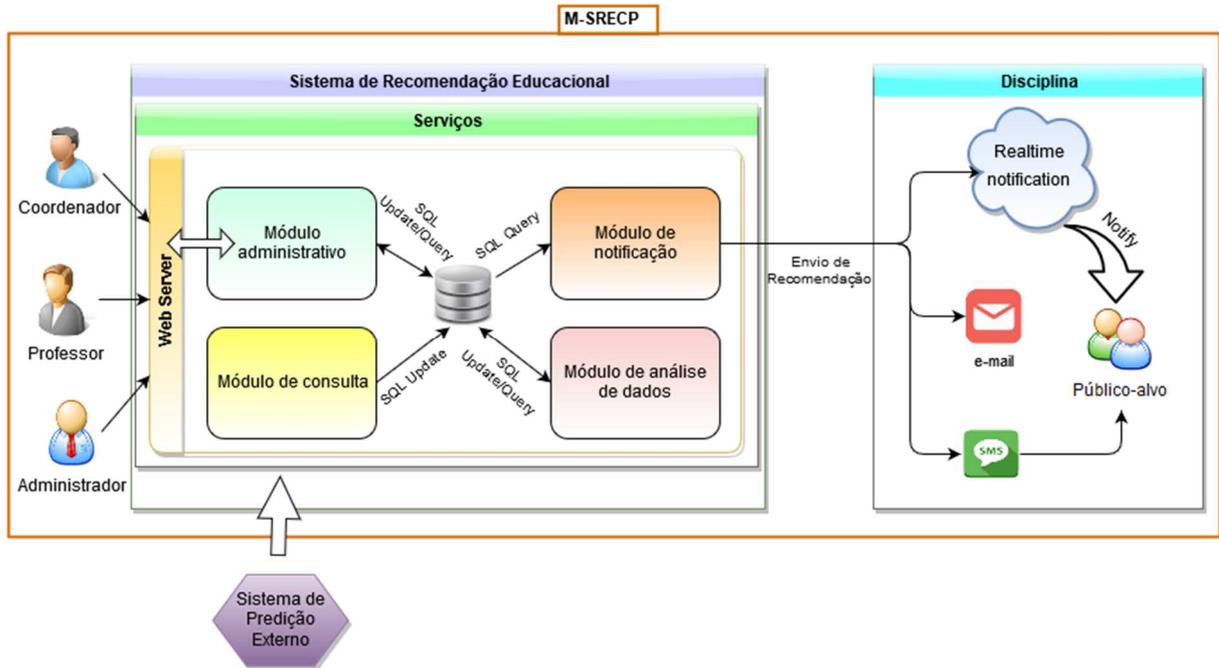
Conforme apresentado pela Figura 11, um tópico pode ser entendido como um período em que assuntos diversos da disciplina são tratados, o que envolve material didático e/ou atividades avaliativas. A disciplina tem um início e logo em seguida são relacionados os tópicos, onde cada um tem datas específicas para começar e acabar. Quando termina o último tópico, termina também a disciplina. Em outras palavras, o tópico envolve um local (por exemplo, um AVA), um intervalo de tempo e abrange atividades, podendo assim ser definido como um contexto segundo a definição de (DEY, 2001).

Figura 11 - Apresentação dos tópicos (contextos)



Fonte: Próprio autor

Figura 12 - Arquitetura do M-SRECP



Fonte: Próprio autor

O módulo de consulta é responsável por importar do sistema externo de predição, uma listagem de aprendizes que podem reprovar em certa disciplina em formato JSON, XML, CSV ou até mesmo XLS.

O módulo de análise de dados tem a responsabilidade de tratar as informações, que vieram do módulo de consulta: nome, matrícula, média das notas das atividades, predição da situação (aprovado ou reprovado) e confiança da predição (variando de 0 a 1), e em conjunto trabalhar com os dados armazenados na própria base de dados do sistema que foram alimentadas pelo módulo administrativo: o nome da disciplina e seus tópicos (com datas de início e fim), o cadastro dos perfis dos usuários envolvidos naquele momento e a forma como se dará a classificação dos perfis, cujo resultado ficará disponível ao módulo de notificação.

O módulo de notificação tem a missão de se comunicar com o coordenador de curso e com o professor, através do envio da recomendação para um dispositivo móvel, em aplicativos populares como *Facebook* e *WhatsApp*, ou até mesmo por *e-mail*. Neste módulo se identifica uma contribuição, pois é nele que ocorre a gerenciamento da entrega usando os perfis para gerenciamento da entrega.

Há também o módulo administrativo que possui o encargo de registrar no banco de dados do modelo, os perfis dos usuários, as regras de entrega e os tópicos das disciplinas. Esse módulo também faz a emissão de um relatório do histórico da situação da disciplina, mostrando em cada momento, quem são os aprendizes que poderiam reprovar a fim de analisar se houve uma redução desse índice.

4.3 Perfil do Coordenador

As informações pertinentes ao perfil do coordenador do curso são armazenadas no banco de dados. Para a criação do metamodelo usou-se como referência o PeLeP (*Pervasive Learning Profile*), um modelo para aperfeiçoamento automático do perfil do aprendiz em ambientes de educação ubíqua (LEVIS *et al.*, 2007). Na Figura 13 são apresentadas as categorias propostas para o perfil de coordenador de curso.

Figura 13 - Metamodelo do Coordenador do curso

Modelo de Coordenador de Curso do M-SRECP			
Identificação	idCoordenador	Perícia	idCoordenador
	Nome		TempoExperiencia
	Endereço		AreaAtuacao
	Email		Qualificacao
	Telefone		Ativo
Curso	idCurso	Representação	idCoordenador
	Descrição		AcaoDemanda
	OfertaInicial		Estilo
	NivelEnsino		Comunicação
Atividades	idAtividade	Segurança	idCoordenador
	Descrição		Login
	Local		Senha
	Contexto		
	DataInicio		
	DataFim		

Fonte: Próprio autor

A categoria “Identificação” é útil na distinção do coordenador em relação aos demais. Ela possui as seguintes informações para sua identificação no sistema: 1) idCoordenador: identificador único do coordenador no sistema; 2) Nome: nome completo; 3) Endereço: endereço residencial completo (rua, número, bairro, cidade); 4) Email: endereço eletrônico; 5) Telefone: telefone de contato (celular).

A categoria “Curso” informa em qual curso o coordenador trabalha. Essa categoria possui os seguintes componentes: 1) idCurso: identificador único do curso; 2) Descrição: nomenclatura usual dada ao curso; 3) OfertaInicial: Ano e semestre em que houve a primeira oferta do curso; 4) NivelEnsino: informa qual o nível de ensino do curso (técnico, superior, graduação).

Na categoria “Atividades” estão as atividades desempenhadas pelo coordenador. Possui: 1) idAtividade: identificador único da atividade; 2) Descrição: assunto de que trata a atividade; 3) Local: ambiente onde esta atividade está sendo desempenhada (cidade, estado, campus); 4) Contexto: informa se a atividade está relacionada com algum contexto (tópico) de alguma disciplina; 5) DataInicio: data do início da atividade; 6) DataFim: data do término da atividade.

A categoria “Perícia” apresenta informações relacionadas à capacidade profissional. Seus atributos são: 1) *idCoordenador*: identificador único do Coordenador; 2) *TempoExperiencia*: tempo de experiência que o coordenador tem em sua área de atuação; 3) *AreaAtuacao*: Área de atuação do coordenador; 4) *Qualificação*: indica o nível de qualificação do coordenador (especialista, mestre, doutor, pós-doutor); 5) *Ativo*: aponta se o coordenador exerce seu trabalho em sala de aula.

A categoria “Representação” aponta os métodos de trabalho do coordenador. Seus elementos são: 1) *idCoordenador*: identificador único do coordenador no sistema; 2) *AcaoDemanda*: assinala a forma como o coordenador lida com uma determinada demanda, se é centralizador ou se tem o costume de delegar; 3) *Estilo*: qual o estilo do coordenador quanto à sua relação em equipe (integrador, decisivo, comunicativo, motivador); 4) *Comunicação*: está relacionado com o tipo tecnológico de comunicação (e-mail, *Facebook*, *WhatsApp*, telefone).

Em “Segurança” estão identificados os componentes referentes ao acesso ao sistema. São eles: 1) *idCoordenador*: identificador do coordenador da credencial; 2) *Login*: nome do usuário para autenticação; 3) *Senha*: senha do usuário.

4.4 Perfil do Professor

Assim como o perfil do coordenador, o perfil do professor é armazenado no banco de dados do modelo e a definição de seu metamodelo foi baseado no PeLeP (LEVIS *et al.*, 2007). Na Figura 14 são apresentadas as categorias desse perfil, logo em seguida elas são explicadas.

Figura 14 - Metamodelo do Professor

Modelo de Professor do M-SRECP			
<u>Identificação</u>	<u>idProfessor</u>	<u>Características</u>	<u>idProfessor</u>
	Nome		<u>idCoordenadoria</u>
	Endereço		<u>DataAdmissao</u>
	Email		<u>AreaAtuacao</u>
	Telefone		<u>Qualificacao</u>
<u>Disciplina</u>	<u>idDisciplina</u>	<u>Habilidades</u>	<u>RegimeTrabalho</u>
	<u>idCoordenadoria</u>		<u>ModalidadeContratacao</u>
	Descrição		<u>Situacao</u>
	DescriçãoCurta		<u>Necessidades</u>
	CargaHoraria		<u>idProfessor</u>
	NivelEnsino		<u>Proatividade</u>
	TipoDisciplina		<u>AfinidadeTecnologia</u>
	Sigla		<u>ConteudoCurricular</u>
<u>Tópicos</u>	<u>idTopico</u>	<u>Segurança</u>	<u>Preocupação</u>
	<u>idDisciplina</u>		<u>Inovador</u>
	Titulo		<u>Paciência</u>
	<u>DataInicio</u>		<u>idProfessor</u>
	<u>DataFim</u>		<u>Login</u>
	<u>Visibilidade</u>		<u>Senha</u>

A categoria “Identificação” é usada na distinção do professor no sistema. Apresenta as seguintes informações: 1) idProfessor: identificador único do professor no sistema; 2) Nome: nome completo; 3) Endereço: endereço residencial completo (rua, número, bairro, cidade); 4) Email: endereço eletrônico; 5) Telefone: telefone de contato (celular).

Em “Disciplina” são apresentados os componentes referentes às disciplinas. São eles: 1) idDisciplina: identificador única da disciplina; 2) idCoordenadoria: identifica à qual coordenadoria pertence a disciplina; 3) Descrição: nome completo da disciplina; 4) DescriçãoCurta: nome abreviado da disciplina; 5) CargaHoraria: carga horaria total da disciplina; 6) NivelEnsino: qual o nível de ensino da disciplina (técnico, graduação, pós-graduação); 7) TipoDisciplina: qualidade da disciplina, se é comum ou especial (artes, educação física); 8) Sigla: sigla da disciplina.

A categoria “Tópicos” indica os atributos da parte que representa o contexto, os tópicos de uma disciplina. Os atributos se dividem em: 1) idTopico: identificação única do tópico; 2) idDisciplina: identifica à qual disciplina o tópico está associado; 3) Titulo: informa o título do tópico, geralmente relacionado a um assunto específico da disciplina; 4) DataInicio: início das atividades de aula do tópico; 5) DataFim: término das atividades de aula do tópico; 6) Visibilidade: informa se o tópico está visível aos aprendizes.

Na categoria chamada “Características” constam os elementos que dizem respeito às características do professor, principalmente dados funcionais. Os elementos são: 1) idProfessor: identificador único do professor no sistema; 2) idCoordenadoria: identifica à qual coordenadoria pertence o professor; 3) DataAdmissao: informa a data em que o professor foi admitido na instituição, caso seja professor com vínculo empregatício; 4) AreaAtuacao: indica a área de atuação do professor; 5) Qualificação: nível de qualificação do coordenador (especialista, mestre, doutor, pós-doutor); 6) RegimeTrabalho: jornada de trabalho (20hs, 40hs, Dedicção Exclusiva); 7) ModalidadeContrataçao: forma utilizada para contratação do professor (efetivo RJU, substituto, horista, temporário, bolsista); 8) Situaçao: situaçao funcional do professor (ativo para docência, inativo); 8) Necessidades: necessidades especiais (visuais, auditivas, suportado, mobilidade).

Em "Habilidades" se analisa os componentes voltados para as habilidades do professor. Os elementos são: 1) idProfessor: identificação única do professor no sistema; 2) Proatividade: professor tem como habilidade ser proativo; 3) AfinidadeTecnologia: professor possui afinidade com recursos tecnológicos como uso de computador, notebook, dispositivos móveis, e-mail, dentre outros; 4) ConteudoCurricular: segue e aplica o conteúdo curricular conforme planejamento pedagógico; 5) Preocupação: é preocupado com o rendimento dos aprendizes, objetivando a absorção de conhecimento; 6) Inovador: busca inovar seus métodos de ensino.

Na categoria "Segurança" estão identificados os elementos referentes ao acesso ao sistema. Compõe os elementos: 1) idProfessor: identificação do professor da credencial; 2) Login: usuário do professor utilizado para a autenticação; 3) Senha: senha do usuário.

4.5 Módulo de consulta

Este é o módulo inicial do processo de verificação de aprendizes propensos à reprovação da disciplina. É realizada uma consulta a um sistema externo de predição. Este então retorna ao sistema o resultado para a consulta em formato JSON, XML, CSV ou XLS, formatações leves de troca de dados. Nessa consulta, os seguintes dados devem ser fornecidos pelo sistema externo de predição para que seja possível identificar os elementos necessários a recomendação:

- Curso: nome do curso ao qual pertence a disciplina. Essa informação é importante para identificar o coordenador que irá receber as recomendações;
- Disciplina: informar a disciplina que se pretende avaliar. Um dado relevante não é tanto a nomenclatura da disciplina, mas a carga horária da mesma que será substancial para determinar a quantidade de unidades em que a disciplina será dividida, o que dará uma noção da quantidade de tópicos;
- Oferta: ano e período em que está ocorrendo a disciplina, afim de não ocorrerem colisões e entrelaçamento de informações, ao coletar equivocadamente dados de ofertas antigas;
- Aprendizes: listagem com os aprendizes que precisam ser observados com maior cautela, pois estes são os que provavelmente, sem qualquer intervenção, irão reprovar na disciplina. É importante que a confiabilidade da análise da reprovação seja apresentada, pois é esta a informação que denota o nível de risco.

Quando esses elementos são obtidos, torna-se viável a continuidade do processo pelo módulo de análise de dados. Na Figura 15 é apresentada forma como ocorre a consulta ao sistema de predição.

Figura 15 - Módulo de consulta



O sistema de predição exporta seus dados em arquivo de formatos como JSON e XML, ou CSV e XLS. Esse arquivo passa por um processo conhecido como *Unmarshalling*, processo de transformação de um formato de dados compatível para uma representação em memória de um objeto e posteriormente para armazenamento persistente em banco de dados.

4.6 Módulo de análise de dados

Este é o módulo em que os elementos fornecidos pelo módulo de consulta, e inseridos na base de dados pelo módulo administrativo, serão trabalhados. Com a informação do curso, é possível obter o nome do coordenador que é parte do alvo da recomendação, informação esta que foi previamente cadastrada no módulo administrativo. A disciplina será útil para identificar os momentos em que devem acontecer as recomendações, considerando seus tópicos, ou seja, os vários assuntos da disciplina que serão trabalhados individualmente em um determinado intervalo de tempo, e que foram cadastrados através do módulo administrativo.

A oferta é usada para conceber a noção de tempo atual, a fim de demonstrar que não se está trabalhando em uma disciplina anterior. Sempre que um tópico for iniciado, o coordenador e/ou o professor, receberá a informação da situação de risco de cada aluno, n vezes ao longo da disciplina onde n é igual ao número de tópicos daquela disciplina. Isso implica afirmar que as recomendações ocorrerão mais de uma vez durante a vigência da disciplina, criando várias iterações com o sistema externo de predição.

Neste módulo um algoritmo classificador trabalha para moldar o perfil dos professores e dos coordenadores de curso. Através de um treinamento prévio feito com outros perfis, que pode ser compreendido com um conjunto de treinamento que cria regras de classificação, é possível categorizar os perfis que serão alimentados no sistema.

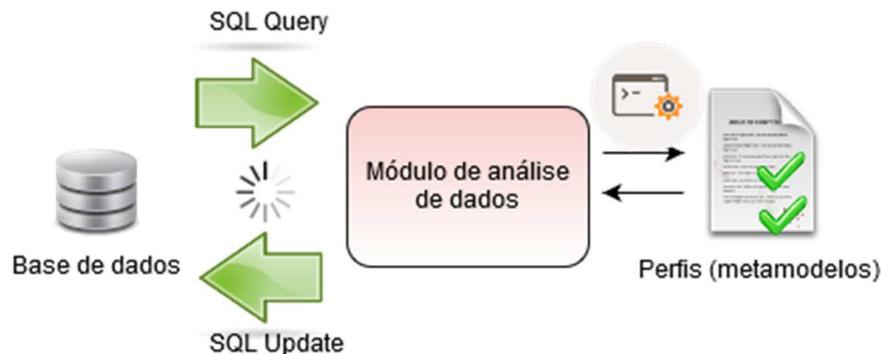
Tanto coordenador como professor deverão ter seus perfis individuais previamente cadastrados na base de dados do sistema de acordo com os atributos descritos nos metamodelos do coordenador e do professor, apresentados nas seções 4.3 e 4.4 respectivamente.

As regras que determinam o método de notificação podem ser diversificadas. O modelo não restringe o tipo de regras que devem ser utilizadas, mas espera que elas sejam informadas ao sistema mediante cadastro feito pelo Administrador do sistema. Isso é possível devido a integração do modelo com APIs de sistemas que forneçam meios de realizar identificações pelo uso de algoritmos classificadores, os quais criam regras de classificação utilizando aprendizado de máquina.

Com isso, se determina a forma de entrega da recomendação, se esta vai ocorrer, por exemplo, através de envio de SMS e/ou a um aplicativo instalado no dispositivo móvel ou, notificação por e-mail, dentre outros. O funcionamento da análise de dados é apresentado pela Figura 16.

O coordenador do curso e o professor atuam juntos buscando a redução das reprovações da disciplina. Ambos sempre serão candidatos a serem notificados.

Figura 16- Módulo de análise de dados



Fonte: Próprio autor

A análise de dados tem o papel de aferição para o módulo de notificação. Este é o componente que vai nortear o método de notificação a ser usado pelo módulo seguinte, baseado nas informações previamente inseridas na base de dados. Na Figura 16 é apresentada a maneira com que o módulo faz uma consulta à base de dados do M-SRECP para fazer uma avaliação das informações que tiveram origem do módulo de consulta, bem como das informações armazenadas na base de dados pelo módulo administrativo. De acordo com o perfil do professor, confrontado com as regras de classificação, apenas este será marcado como destinatário da recomendação, a qual terá como conteúdo todas as ações que já foram tomadas para cada aprendiz com alta probabilidade de reprovação, a fim de auxiliar o professor a não tomar decisões repetitivas e que não surtiram o efeito desejado.

4.7 Módulo de notificação

Componente do modelo que tem a tarefa de fazer a entrega da recomendação. A recomendação é composta da listagem de alunos com seus respectivos índices de confiança relativos ao risco de reprovação. Os tópicos, e os perfis são utilizados para definir essa notificação. Aqui é primordial ressaltar que, diferentemente de outros trabalhos na área de Sistemas de Recomendação Educacional, este trabalho trata o aprendiz não como o alvo da recomendação, ao invés disso ele(s) compõe(m) a própria recomendação. Dessa forma o módulo de notificação trabalha com o envio de avisos advertindo coordenadores de curso e os professores das disciplinas.

A forma de notificação mais comum usada nos dias atuais é o *e-mail*, e esta está presente no modelo. No entanto, limitar-se ao *e-mail* pode significar um risco ao processo como um todo, pois basta o coordenador ou o professor não verificarem suas caixas de entrada no momento da notificação para comprometerem o fluxo, considerando que a disciplina é aplicada de forma contínua, e não semestralmente.

Considerando que se tornou comum o uso de dispositivos móveis para atividades do dia-a-dia, para questões pessoais ou profissionais, no modelo está previsto a adoção de notificações para aplicativos de sistemas populares como *Facebook* e *Whatspp*, além de envio de SMS. Como o modelo trata de recomendações, não faz sentido utilizar uma arquitetura cliente-servidor, pois se assim o fosse, o aplicativo teria que fazer consultas aos serviços do modelo, quando o que se pretende fazer é justamente o inverso.

Assim sendo, optou-se por trabalhar com uma solução de API's com funcionamento semelhante ao de aplicativos que fazem notificações em dispositivos móveis, como *Facebook*, *Twitter* e *WhatsApp*. Essas API's se propõem a fazer notificações em tempo real, opcionalmente através de servidores globais com poderosa infraestrutura, confiabilidade, desempenho e escalabilidade. Conforme apresentado pela Figura 17, é possível entender o funcionamento do módulo de notificação do modelo.

Figura 17 - Módulo de notificação



Fonte: Próprio autor

Conforme apresentado pela Figura 17 pode-se observar que o módulo de notificação consulta ao banco de dados pelos métodos de notificação que irão ocorrer. Nessa consulta o módulo fica inteirado sobre como e para quem entregar a recomendação. A notificação pode ocorrer de uma ou mais formas, como por exemplo, envio de e-mail, de SMS, envio de mensagem por *WhatsApp* ou por *Facebook*.

4.8 Módulo administrativo com CRM

Módulo que tem a atribuição de cadastros diversos, concentrados na mesma base de dados usada pelos módulos anteriores. Este componente do M-SRECP gerencia os perfis dos usuários e as regras de entrega das recomendações. Conceitos de CRM, como gerenciamento de conteúdo e execução de tarefas, são aplicados.

Na área de perfis de usuário é onde ocorre o cadastro de cada usuário do sistema, nele haverá apenas três tipos de usuário: (i) administrador, para gerência geral do sistema; (ii) coordenador de curso; e (iii) professor.

O perfil de administrador tem controle total do sistema, somente os usuários com esse perfil podem controlar questões como a criação de usuários e inserção de regras de

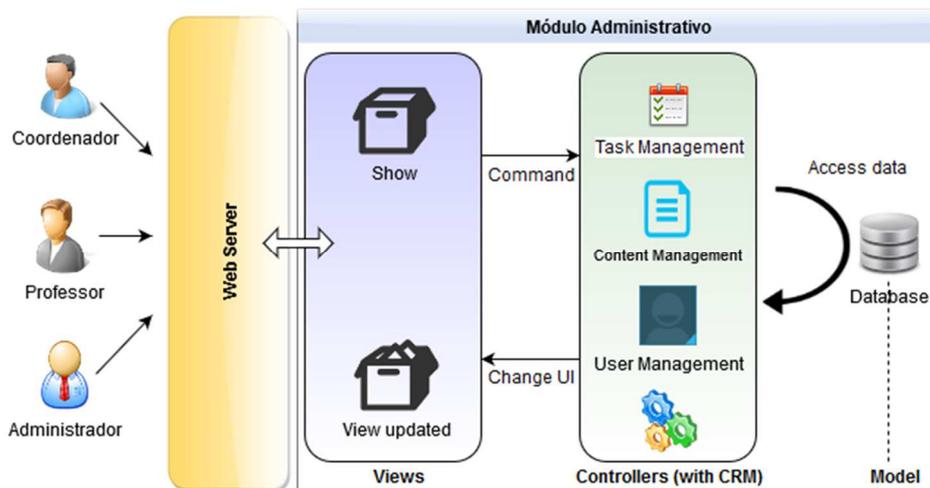
classificação. O perfil de coordenador tem a liberdade de criar tarefas em forma de agendamento, que periodicamente disparam notificações de acordo com as datas informadas para a disciplina. Ele também pode opcionalmente enviar conteúdos midiáticos ao professor, como, por exemplo, listagem dos alunos com risco de reprovação ou informações estatísticas de desempenho dos mesmos.

O perfil do professor tem permissões mais restritas. Os usuários desse perfil podem verificar um histórico das recomendações que receberam do sistema, em cada disciplina, e podem registrar as ações tomadas após o recebimento da notificação com a recomendação que inclui os aprendizes. Essas ações são repassadas ao coordenador do curso.

No que diz respeito às regras de entrega das recomendações, o coordenador do curso preenche os dados de perfil dos seus professores, a fim de nortear a entrega das recomendações. Esses dados do perfil passam por uma avaliação em um algoritmo de classificação pertencente ao módulo de análise de dados. O algoritmo é responsável por classificar o perfil, considerando cada item do perfil que foi preenchido, com o objetivo de categoriza-lo. No cadastro estão disponíveis as informações previstas nos metamodelos dos perfis.

No cadastro de curso ocorre o armazenamento de informações básicas como nome do curso e nome do coordenador. No cadastro de disciplina é informado seu nome, sua carga horária e cada um de seus tópicos, com o assunto do mesmo e com o intervalo de duração de cada um. Esse preenchimento também é feito pelo coordenador do curso. A Figura 18 apresenta o módulo administrativo, o qual segue os conceitos do padrão MVC (*Model-View-Controller*) e alguns conceitos de CRM.

Figura 18- Módulo administrativo com CRM



Fonte: Próprio autor

5 ASPECTOS DE IMPLEMENTAÇÃO

Com o intuito de posteriormente avaliar o M-SRECP, um protótipo foi implementado e se fundamentou na funcionalidade dos seus módulos, objetivando alcançar resultados que propiciassem condições de avaliação do modelo.

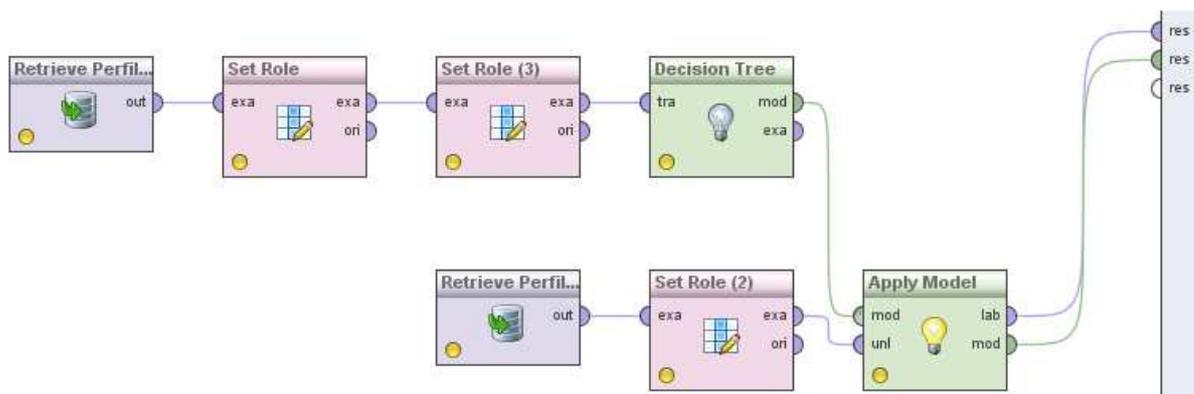
Este capítulo apresenta as técnicas utilizadas para a geração dos módulos do protótipo. Nele são abordados os aspectos de implementação do protótipo, sendo que o intento não é a discussão detalhada de cada componente e suas funcionalidades, e sim mostrar as decisões relevantes ao trabalho.

O protótipo do M-SRECP foi desenvolvido na linguagem *Groovy* (GROOVY PROJECT, 2015), com o *framework Grails* (GRAILS PROJECT, 2015), a IDE (*Integrated Development Environment*) IntelliJ (“IntelliJ IDEA the Java IDE”, 2015), banco de dados MariaDB (“MariaDB.org - Continuity and open collaboration”, 2016), além de utilizar a ferramenta *RapidMiner* para criação de processo de classificação de perfis com um operador de árvore de decisão, e sua API para importação do processo para o código fonte do protótipo. Conceitos de *Customer Relationship Manager* – CRM também foram utilizados. O protótipo pode ser usado em qualquer navegador *web*.

O protótipo do M-SRECP elaborou uma estrutura de classificação e notificação. Quando um perfil é classificado, tem-se a forma de notificação a qual é invocada de forma individual (coordenador ou professor) ou simultânea (coordenador e professor). O processo é dinâmico na medida em que assim como um perfil pode mudar, a forma de notificação também está suscetível a mudança. O agendamento da notificação é um método semelhante a um calendário de eventos, destinado a um usuário, recurso este que confere ao sistema um comportamento de sensibilidade ao contexto.

Utilizou-se a ferramenta de mineração de dados *RapidMiner* para criação do processo de classificação do perfil, bem como para valida-lo. A Figura 19 apresenta o processo de classificação de perfil e todos os operadores envolvidos.

Figura 19 - Processo de classificação do perfil



Fonte: Próprio autor

No *RapidMiner*, um processo é composto por operadores. Conforme apresentado pela Figura 19, pode-se notar a existência de quatro operadores:

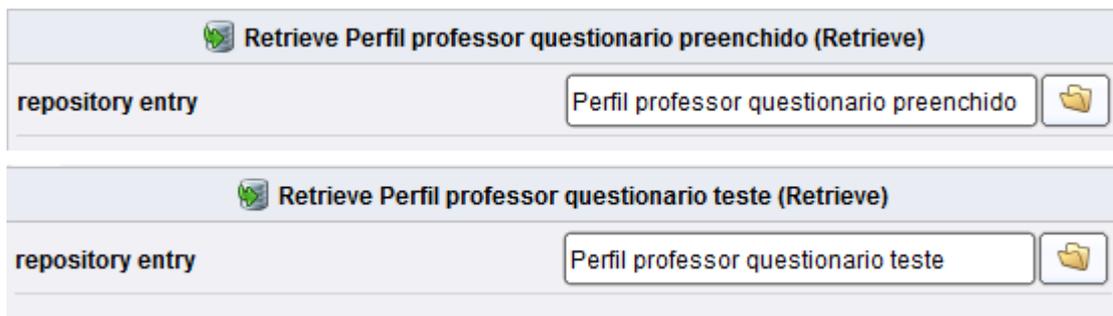
- *Retrieve*: operador responsável por fazer a leitura de um objeto de um repositório de dados, que pode ser um arquivo simples como os de formato .csv, ou uma conexão direta com um banco de dados;
- *Set Role*: operador usado para modificar o papel de um ou mais atributos;
- *Decision Tree*: operador que gera uma árvore de decisão para classificação de dados numéricos e nominais;
- *Apply Model*: este operador aplica um modelo que passou por um aprendizado ou treinamento, em um conjunto de dados.

Percebe-se pela Figura 19 que alguns operadores se repetem no processo de classificação do perfil, é o caso dos operadores *Retrieve* e *Set Role*. O *Retrieve* aparece duas vezes: a da linha superior na imagem representa o repositório de dados que é utilizado para o treinamento na árvore de decisão, contendo uma planilha com o perfil dos professores; o da linha inferior diz respeito aos registros que serão classificados após passar pelo operador *ApplyModel*.

Na linha superior do processo existem dois atributos *Set Role*: o primeiro tem como função mencionar qual atributo da planilha de perfil dos professores será tratado como identificador; o segundo possui o papel de apontar qual atributo será o rótulo da classificação, ou seja, aquele que servirá de parâmetro para classificação. Há ainda um terceiro *Set Role*, dessa vez na linha inferior do processo, que tem função semelhante ao primeiro *Set Role* da linha superior na identificação dos registros.

Na Figura 20 é apresentado o parâmetro utilizado para cada um dos operadores do tipo *Retrieve*. Na Figura 21 se apresenta a configuração dos atributos nos operadores *Set Role*. Na Figura 22 estão apresentados os parâmetros para o operador *Decision Tree*.

Figura 20 - Operadores *Retrieve* utilizados no processo



Fonte: Próprio autor

Figura 21- Operadores *Set Role* utilizados no processo

Set Role	
attribute name	id
target role	id
set additional roles	Edit List (0)...

Set Role (3) (Set Role)	
attribute name	Enviar para coordenador-
target role	label
set additional roles	Edit List (0)...

Fonte: Próprio autor

Figura 22 - Operador *Decision Tree* utilizado no processo

Decision Tree	
criterion	gini_index
maximal depth	20
<input checked="" type="checkbox"/> apply pruning	
confidence	0.25
<input checked="" type="checkbox"/> apply prepruning	
minimal gain	0.1
minimal leaf size	2
minimal size for split	4
number of prepruning alternatives	3

Fonte: Próprio autor

Figura 23 - Regras da Árvore de decisão

```

Tree
Absorção > 2.500
| Inovação > 4.500
| | Tem experiência com Moodle- > 3
| | | Proatividade > 4.500: Sim {Não=0, Sim=20}
| | | Proatividade ≤ 4.500
| | | | Whatsapp > 2.500: Não {Não=2, Sim=2}
| | | | Whatsapp ≤ 2.500: Sim {Não=0, Sim=4}
| | | Tem experiência com Moodle- ≤ 3: Não {Sim=1, Não=3}
| Inovação ≤ 4.500
| | E-mail > 2.500
| | | Tem experiência com editor de texto- > 2.500
| | | | Aplicabilidade > 3.500
| | | | | Tem experiência com editor de texto- > 3.500
| | | | | | Quantas semanas durou a disciplina ministrada pelo professor- > 3.500: Não {Não=2, Sim=1}
| | | | | | Quantas semanas durou a disciplina ministrada pelo professor- ≤ 3.500: Sim {Sim=11, Não=3}
| | | | | Tem experiência com editor de texto- ≤ 3.500: Não {Sim=1, Não=3}
| | | | | Aplicabilidade ≤ 3.500: Sim {Não=0, Sim=6}
| | | | Tem experiência com editor de texto- ≤ 2.500: Não {Não=4, Sim=0}
| | | E-mail ≤ 2.500
| | | | Proatividade > 3.500
| | | | | Aplicabilidade > 4.500
| | | | | | Proatividade > 4.500: Não {Não=6, Sim=0}
| | | | | | Proatividade ≤ 4.500
| | | | | | | Quantas semanas durou a disciplina ministrada pelo professor- > 3.500: Sim {Não=0, Sim=2}
| | | | | | | Quantas semanas durou a disciplina ministrada pelo professor- ≤ 3.500: Não {Não=2, Sim=1}
| | | | | Aplicabilidade ≤ 4.500: Não {Não=14, Sim=0}
| | | | Proatividade ≤ 3.500
| | | | | Whatsapp > 5.500: Sim {Não=0, Sim=2}
| | | | | Whatsapp ≤ 5.500
| | | | | | Tem experiência com Moodle- > 2.500: Não {Não=3, Sim=0}
| | | | | | Tem experiência com Moodle- ≤ 2.500
| | | | | | | SMS > 0.500: Não {Não=3, Sim=0}
| | | | | | | SMS ≤ 0.500
| | | | | | | | Aplicabilidade > 3.500: Sim {Não=0, Sim=3}
| | | | | | | | Aplicabilidade ≤ 3.500: Não {Não=3, Sim=2}
Absorção ≤ 2.500: Sim {Não=0, Sim=16}

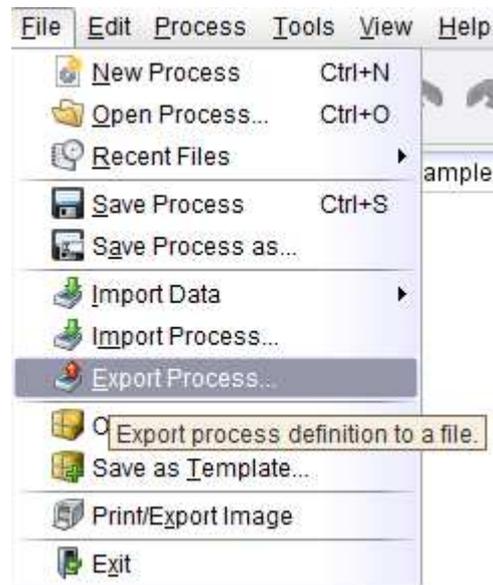
```

Fonte: Próprio autor

Na Figura 23 apresenta-se a visualização de como as regras de classificação foram compostas pela árvore de decisão. Quando o perfil do professor passa pelo processo de classificação, passa por cada nó de decisão que o direciona ao próximo nó até chegar ao nó que corresponde ao resultado final, que neste caso é “Sim” ou “Não” para enviar a recomendação ao coordenador do curso.

Após o processo consolidado, utilizou-se a funcionalidade de exportação do processo em arquivo .rmp (*RapidMiner Process*). O objetivo da exportação foi o de utilizar o processo diretamente no protótipo por meio da importação deste utilizando a API do *RapidMiner*. Na Figura 24 é apresentada a exportação do processo executado pela ferramenta, enquanto na Figura 25 pode ser visto parte do código fonte que realiza a importação do processo.

Figura 24 - Exportação do processo de classificação



Fonte: Próprio autor

Figura 25 - Código de importação do processo

```
try {
    //RapidMiner.setExecutionMode(RapidMiner.ExecutionMode.COMMAND_LINE);
    RapidMiner.init();

    RepositoryLocation loc = new RepositoryLocation("./");
    Process process = new RepositoryProcessLocation(loc).load(null);
    //process.run();

} catch (IOException | XMLException | OperatorException ex) {
    ex.printStackTrace();
}
```

Fonte: Próprio autor

Na Figura 25 é apresentado o processo de classificação foi incorporado ao protótipo. Através da API do *RapidMiner*, realizou-se a leitura do arquivo do processo que se encontra fisicamente no mesmo diretório do arquivo fonte, esse diretório é chamado como “Repositório” pelo *RapidMiner*. Dentro desse repositório estão os arquivos referentes ao processo, ao conjunto de dados de treinamento e ao conjunto de dados a serem classificados.

Para integrar a API do *RapidMiner* com o protótipo, incluiu-se no diretório “/lib” do projeto do protótipo, desenvolvido com o framework *Grails*, bibliotecas Java (.jar) referentes à API. Apesar de o protótipo ter sido desenvolvido em *Groovy*, a integração foi possível porque essa linguagem de programação foi criada para a plataforma JAVA, tornando-a compatível com bibliotecas e códigos Java.

Na obtenção da listagem dos aprendizes com risco de reprovação, o protótipo consulta o sistema de predição e recebe deste um arquivo em formato .csv (*Comma-separated values*), o qual passa por uma biblioteca de análise criando objetos instanciados e por fim inserindo-os

no banco de dados. A biblioteca *opencsv* (“Opencsv”, 2015) foi utilizada para esse fim. A Figura 26 apresenta brevemente o código utilizado para esse processo.

Figura 26 - Tratamento do arquivo CSV

```

CSVReader reader = new CSVReader(new FileReader("grupo_risco.csv"));
ColumnPositionMappingStrategy strat = new ColumnPositionMappingStrategy();
strat.setType(Aprendiz.class);
String[] columns = new String[]
{"matricula", "nome", "media_atividades",
"desv_interacoes", "prediction", "confidence"};

strat.setColumnMapping(columns);

CsvToBean csv = new CsvToBean();
List<Aprendiz> list = csv.parse(strat, reader);
list.each { a->
    a.save();
}

```

Fonte: Próprio autor

O protótipo do M-SRECP incorporou também conceitos de *Customer Relationship Manager* – CRM, podendo ser acessado em qualquer navegador *web*. O intuito de usar funções de CRM foi obter uma gestão do usuário harmonizada para o ensino, visando professores e coordenadores.

O protótipo dispõe de funcionalidades de CRM adaptadas ao escopo do modelo, quais sejam: (i) *Contact Management*: gerenciamento de contatos usado para administração dos perfis; (ii) *Task/Todos List*: lista de tarefas e/ou afazeres para agendamento de notificações; (iii) *Notification*: notificação personalizada de acordo com o perfil; (iv) *Content Management*: gerenciamento de conteúdo, onde o conteúdo pode ser arquivo texto comum, arquivos .doc, PDFs, imagens, dentre outros.

Para auxiliar no uso de CRM para o modelo, utilizou-se *plugins* do *framework Grails* que compõem um conjunto recheado de funcionalidades. Esse conjunto é chamado de GR8 CRM - *Great Customer Relationship Management Plugins for the Grails Web Framework* (EHRSSON, 2015).

Na Figura 27 apresenta-se uma tela de exemplo do agendamento de notificação para o professor da disciplina, nela pode-se informar: (i) nome da tarefa; (ii) início e fim do módulo; (iii) localização da disciplina com o link para o ambiente virtual; (iv) usuário identificando o destinatário; (v) tipo do usuário (administrador, professor ou coordenador); (vi) status da tarefa; (vii) prioridade da tarefa; (viii) notificar (sim ou não); (xi) meios de notificação; (x) descrição contendo a mensagem recebida pelo usuário. Na Figura 28 apresenta-se a tela de cadastro do usuário, informações como nome, sobrenome, e-mail, telefone para SMS, telefone para *WhatsApp* e *Facebook*.

Figura 27 - Cadastrar nova tarefa

Adicionar tarefa

Nome da tarefa <input type="text" value="Filosofia da Educação - Libras - Módulo I"/>	Usuário <input type="text" value="Professor 01"/>	Notificar <input type="text" value="Sim"/>
Início <input type="text" value="05/10/15"/> <input type="text" value="00:00"/>	Tipo <input type="text" value="Professor"/>	<input checked="" type="checkbox"/> E-mail <input type="checkbox"/> Facebook
Fim <input type="text" value="14/10/15"/> <input type="text" value="23:45"/>	Status <input type="text" value="Planejado"/>	<input checked="" type="checkbox"/> Whatsapp <input type="checkbox"/> SMS
Localização <input type="text" value="http://ead.ifam.edu.br/uab/course/view.php?id=861"/>	Prioridade <input type="text" value="Normal"/>	Descrição <p>Prezado prof.,</p> <p>Após análise da primeira semana da turma de Filosofia da Educação, em 2015/2, disciplina LIBRAS, foi constatado o grupo de risco de reprovados.</p> <p>A coordenação do curso também está sendo notificada. A listagem de alunos foi enviada para o e-mail xxxxxxxx@xxxxxxxx para que se possa trabalhar a fim de evitar tais reprovações.</p>
<input type="button" value="Salvar"/>		

Fonte: Próprio autor

Figura 28 - Cadastrar usuário

Criar novo usuário

Dados do usuário		
Nome <input type="text"/>	Telefone (SMS) <input type="text"/>	CPF <input type="text"/>
Sobrenome <input type="text"/>	Telefone (Whatsapp) <input type="text"/>	Data de nascimento <input type="text" value="DD"/> <input type="text" value="MM"/> <input type="text" value="AAAA"/>
Titulação <input type="text"/>	Facebook <input type="text"/>	Tipo <input type="text" value="Coordenador"/>
	Email <input type="text"/>	
<input type="button" value="Salvar"/> <input type="button" value="Cancelar"/>		

Fonte: Próprio autor

A relação entre os módulos ocorreu pelo uso das quatro operações básicas utilizadas em bases de dados relacionais (RDBMS), conhecidas como CRUD (acrônimo de *Create*, *Read*, *Update* e *Delete*, na língua inglesa). O modelo deixa evidente que não há necessidade específica para o tipo de SGBD a ser adotado, basta que o modelo entidade-relacionamento do banco de dados seja bem feito.

6 ASPECTOS DE AVALIAÇÃO

O protótipo foi usado na avaliação do modelo M-SRECP. Foram abordadas principalmente questões de intervenção; em outras palavras, a coordenação do curso e o professor sendo notificados com a listagem dos alunos em vias de reprovação na disciplina em andamento, à medida que a mesma vai avançando nos seus tópicos de forma contínua. Ocorreram dois tipos de avaliação após o experimento, e estão estruturadas da seguinte forma neste capítulo.

A primeira seção chama-se “Avaliação de funcionalidade” e diz respeito à aplicação do protótipo em uma disciplina que teve atuação direta de seu professor, e também da coordenação do curso ao qual essa disciplina pertence.

A segunda seção é denominada “Avaliação de usabilidade”. Ela trata da preparação e aplicação de um questionário seguindo o modelo de aceitação de tecnologia, ou *Technology Acceptance Model* (TAM). Essa avaliação envolveu 12 professores após os mesmos experimentarem o sistema.

Na primeira avaliação usou-se o método quantitativo para obtenção de 30 perfis de um total de 42 possíveis e utilizou-se amostragem por escolha racional, pois se buscou participantes com características específicas: coordenadores de curso que conhecem seus professores. Na avaliação TAM, que também é quantitativa aplicou-se um questionário a 12 de possíveis 15 professores cuja amostragem também foi por escolha racional, pois a característica específica era ter professores que já trabalharam na EaD.

6.1 Avaliação de funcionalidade

No experimento avaliou-se a funcionalidade do sistema na disciplina de Libras do curso de Filosofia da Educação da UAB no IFAM, nos quatro polos (Boa Vista, Caracará, Manaus e Tefé), no período de 05/10/2015 a 30/10/2015. O objetivo foi enviar recomendações semanais ao professor dessa disciplina de acordo com o seu perfil, que foi preenchido pela coordenação do curso, bem como para a própria coordenação. O conteúdo das recomendações, os aprendizes com risco de reprovação na disciplina de Libras provêm do MD-PREAD, um modelo de predição de reprovação de aprendizes em disciplinas, o qual está sendo elaborado em uma dissertação no Programa de Pós-Graduação em Computação Aplicada da Universidade do Vale do Rio dos Sinos.

Buscou-se coletar informações de perfis de professores através da aplicação de um questionário. Há atualmente seis cursos de Pós-Graduação da Universidade Aberta do Brasil no IFAM, são eles: (i) Pós-Graduação Lato Sensu em Educação do Campo; (ii) Pós-Graduação Lato Sensu em Educação Musical; (iii) Pós-Graduação Lato Sensu em Filosofia da Educação: Ética, Política e Epistemologia; (iv) Pós-Graduação Lato Sensu em Gestão Pública; (v) Pós-Graduação Lato Sensu em História, Cultura Africana e Afro-brasileira; e (vi) Pós-Graduação Lato Sensu em Informática na Educação.

Os coordenadores de curso de Pós-Graduação da UAB foram convidados a responder o questionário. Dos seis coordenadores, quatro colaboraram para o preenchimento do questionário. Optou-se por aplicar o questionário aos coordenadores porque no caso da UAB no IFAM, cabe ao coordenador convidar o professor que irá ficar a frente da disciplina, portanto considerou-se mais adequado o coordenador responder por seus docentes, visto que conhece suas qualidades.

Para a elaboração do questionário utilizou-se o sistema *LimeSurvey* (LIMESURVEY, 2015), o qual é um conceituado *software* livre dedicado à aplicação de questionários *online* escrito em PHP (PREPROCESSOR, 2015). A principal vantagem foi permitir publicar e coletar respostas de questionários sem a necessidade de haver um conhecimento amplo em PHP. O questionário possui um total de 38 perguntas, porém nem todas de preenchimento obrigatório, dentre elas: Nome; Data de nascimento; Titulação; *Notebook* (se possuía); *Smartphone* (se possuía); Experiência com editor de texto, planilhas eletrônicas e acesso a internet (todos em escala *Likert*); Proatividade, Afinidade, Aplicabilidade, Absorção, Inovação (todos em escala *Likert*); Quantidade de semanas da disciplina; Formas de notificação semanal; dentre outras. Nas Figuras 29 e 30 é possível visualizar segmentos do questionário.

Figura 29 - Questionário para obter o perfil do Professor

**INSTITUTO FEDERAL
AMAZONAS**

Perfil do professor

Prezado(a) Coordenador(a),

Favor preencha o questionário abaixo considerando as características individuais de cada professor que fez parte do corpo docente de seu curso.
Trata-se de um questionário para fins de pesquisa acadêmica, portanto sua colaboração é muito importante.
As respostas dadas serão usadas para saber se, dependendo do perfil do professor, há necessidade de intervenção semanal pela coordenação do curso.
O objetivo é minimizar a quantidade de reprovações em disciplinas da Pós-Graduação da UAB.

0% 100%

Geral

* **Nome**

Data de nascimento

Formato: dd/mm/aaaa

* **Titulação**
Escolha uma das seguintes respostas:

Especialista

Mestre

Doutor(a)

PhD

? Informe a titulação acadêmica do professor

Fonte: Próprio autor

Enquanto se apresenta parcialmente na Figura 29 as perguntas iniciais do questionário que buscam coletar informações mais pessoais, a Figura 30 apresenta um segmento do questionário que aborda a melhor forma de notificar o professor naquela semana. O meio de notificação semanal ao professor foi informado pelo coordenador, que tinha como opções: *WhatsApp*, *E-mail*, *Facebook*, *SMS* e uma pergunta do tipo Sim/Não: Enviar para coordenador. Esta pergunta demonstra o nível de preocupação e confiança que o coordenador tem com aquele professor em uma interação semanal.

Figura 30 - Questionário de perfil do Professor (formas de notificação)

**INSTITUTO FEDERAL
AMAZONAS**

Perfil do professor

Prezado(a) Coordenador(a),

Favor preencha o questionário abaixo considerando as características individuais de cada professor que fez parte do corpo docente de seu curso.
Trata-se de um questionário para fins de pesquisa acadêmica, portanto sua colaboração é muito importante.
As respostas dadas serão usadas para saber se, dependendo do perfil do professor, há necessidade de intervenção semanal pela coordenação do curso.
O objetivo é minimizar a quantidade de reprovações em disciplinas da Pós-Graduação da UAB.

0% 100%

Semana 1

Responda as questões abaixo quanto aos meios tecnológicos de notificação na 1ª semana da disciplina ministrada pelo professor.

*** Whatsapp**
Apenas números podem ser usados nesse campo.

? Informar quantas vezes nessa 1ª semana, foi considerado importante interagir com o professor através do Whatsapp

*** E-mail**
Apenas números podem ser usados nesse campo.

? Informar quantas vezes nessa 1ª semana, foi considerado importante interagir com o professor através do E-mail

*** Facebook**
Apenas números podem ser usados nesse campo.

? Informar quantas vezes nessa 1ª semana, foi considerado importante interagir com o professor através do Facebook

Fonte: Próprio autor

O questionário foi submetido aos quatro coordenadores de curso, para que a partir das respostas dadas, fosse possível formar o perfil do professor. Até 2015/1, considerando os quatro cursos cujas coordenações se prontificaram a responder o questionário, 42 disciplinas haviam sido prestadas, ou seja, eram esperadas 42 respostas para o questionário. Como os coordenadores responderam o mesmo questionário mais de uma vez, pois um questionário preenchido correspondia a respostas sobre um professor apenas, houve um total de 30 questionários respondidos, ou seja, 30 perfis de professor de um total de 42 possíveis, o que corresponde a 71,43%, índice considerado como satisfatório. Estes perfis foram exportados da ferramenta *LimeSurvey* em formato .xls e importados para o *RapidMiner* (RAPIDMINER, 2015) a fim de serem utilizados em um algoritmo de classificação de árvore de decisão, cuja estrutura classificatória definiu a necessidade de notificar o coordenador do curso ao término de cada semana. Usou-se o método de pesquisa quantitativo através de uma amostragem por escolha racional, pois os participantes possuíam características específicas: coordenadores de curso que conhecem seus professores

Optou-se por utilizar árvore de decisão por ser um modelo de classificação prático e um dos mais usados em inferência indutiva. A árvore de decisão, neste trabalho, foi formada de acordo com um conjunto de treino, conjunto esse que foram os questionários respondidos representando a classificação prévia de perfil de professor.

Na Figura 31 é apresentada a acurácia da árvore, que ficou em 70%, após a mesma ter passado por um processo de validação no *RapidMiner* através do uso de um operador chamado *X-Validation*. Este operador utiliza a técnica validação cruzada, para compensar uma taxa de erro aparente otimista, a fim de estimar o desempenho estatístico de um operador de aprendizagem. O *X-Validation* é usado principalmente para aferir o quão preciso um modelo será na prática. O índice de 70% foi considerado bom, levando em conta o quantitativo de respostas dadas ao questionário. Na Figura 32 se apresenta o perfil do professor de Libras classificado.

O objetivo da árvore de decisão da Figura 33 é classificar o perfil do professor da disciplina. Com o perfil classificado, torna-se possível definir se, ao longo das semanas da disciplina, professor e coordenador do curso serão notificados das possíveis reprovações, ou se a notificação será restrita ao professor. O foco da árvore de decisão é identificar se com base no preenchimento do perfil do professor, por parte do coordenador, ambos sejam notificados.

Figura 31 - Acurácia da árvore de decisão

accuracy: 70.00% +/- 9.28% (mikro: 70.00%)			
	true Não	true Sim	class precision
pred. Não	22	10	68.75%
pred. Sim	26	62	70.45%
class recall	45.83%	86.11%	

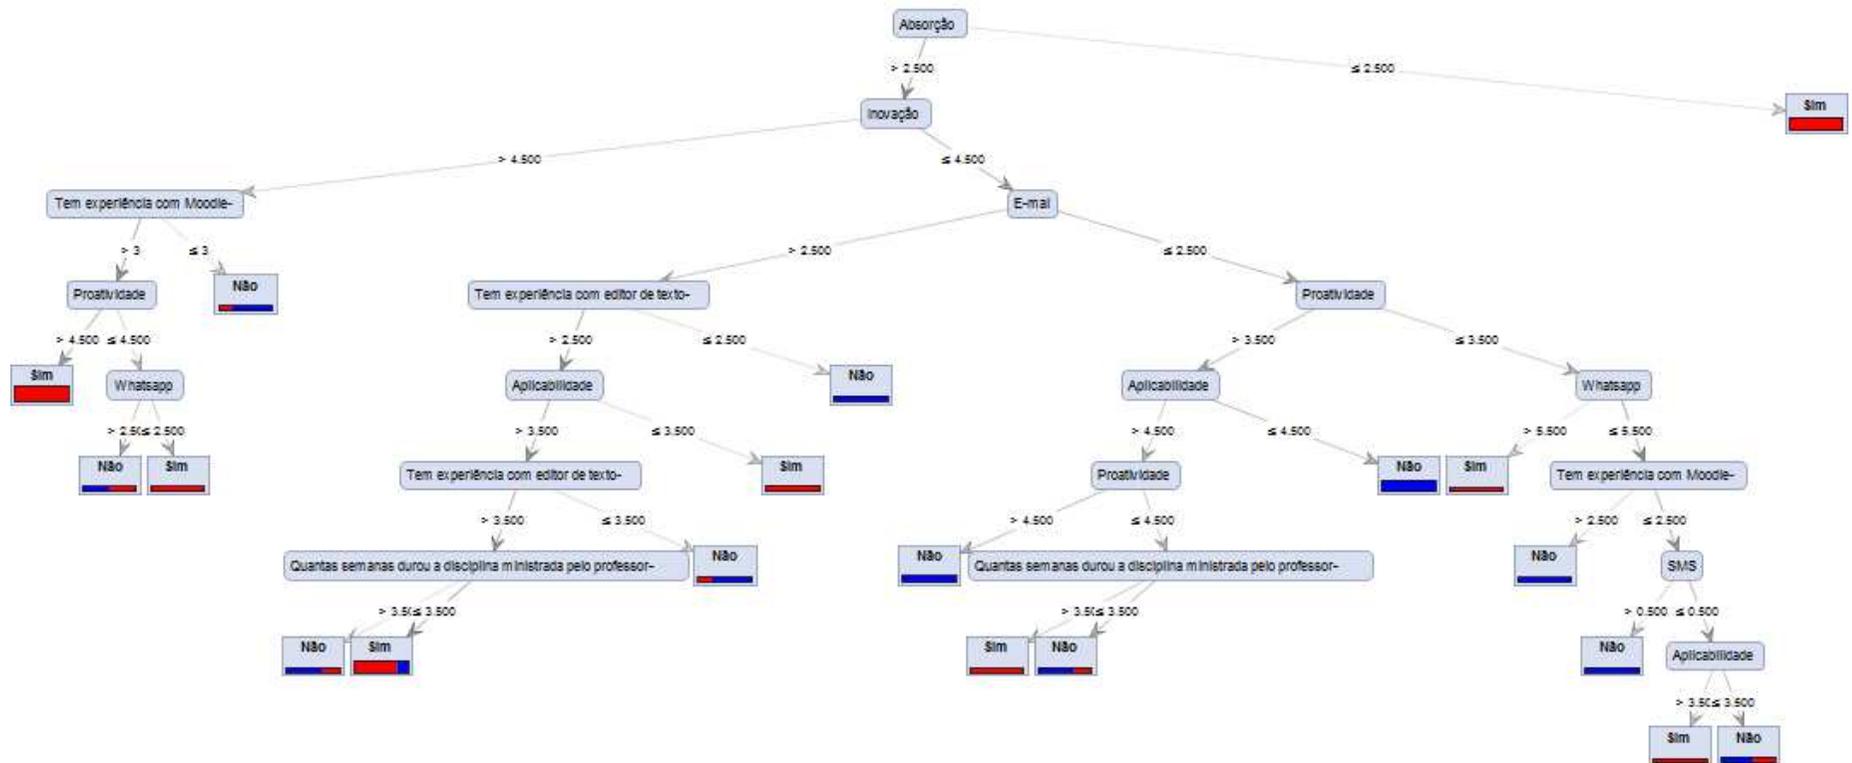
Fonte: Próprio autor

Figura 32 - Perfil do professor classificado

Row No.	ID da resposta	prediction(Enviar para coordenador-)	confidence(Não)	confidence(Sim)
1	37	Sim	0	1
2	37	Sim	0	1
3	37	Sim	0	1

Fonte: Próprio autor

Figura 33 - Árvore de decisão (Perfil do professor)



Fonte: Próprio autor

As Figuras 31, 32 e 33 permitiram analisar o perfil do professor de uma perspectiva diferenciada. Conforme apresentado pela Figura 33 percebe-se que há vários “caminhos” que podem ser percorridos para concluir se um professor precisa de acompanhamento mais intenso por parte da coordenação, considerando suas características próprias. Isso faz com o modelo trabalhe com a possibilidade de perfis dinâmicos, pois as características do professor podem mudar com o tempo o que acarretaria em uma nova avaliação do perfil. A acurácia da Figura 31 informa o percentual de 70%, demonstrando que apesar do número da amostra não ser muito expressivo, as características escolhidas para o perfil do professor foram adequadas, constatação essa que é corroborada pela Figura 32, ao mostrar que a confiança da classificação atingiu o valor máximo de 1 para cada uma das semanas.

Devido ao baixo quantitativo de coordenadores de curso de pós-graduação (total de seis) da UAB no IFAM, não houve processo de classificação de perfil nos mesmos moldes do perfil do professor. Optou-se por traçar o perfil do coordenador do curso de Filosofia da Educação através de um cadastro simples no protótipo, dando a esse perfil uma característica mais estática.

Para o perfil do professor de Libras, a coordenação do curso preencheu o mesmo questionário que foi utilizado para coletar os dados e gerar a árvore que classifica o perfil, porém as últimas questões ficaram parcialmente em branco já que o objetivo foi que a resposta a elas viesse pela classificação da árvore de decisão.

A pergunta não respondida, conforme apresentado pela Figura 34, diz respeito ao meio preferencial para notificar a recomendação ao destinatário. Da mesma forma que ocorreu com os 30 questionários totalmente respondidos, os meios disponíveis para notificar foram: *WhatsApp*, *E-mail*, *Facebook*, *SMS* e uma pergunta do tipo Sim/Não que foi respondida pela classificação da árvore de decisão. Uma das contribuições do M-SRECP é a possibilidade de classificação de perfis, com suporte a perfis variados de professores e coordenadores de curso. Permitir o preenchimento do perfil do professor pela coordenação foi importante, já que o resultado da notificação está diretamente associado com as respostas dadas.

Figura 34 - Meios tecnológicos de notificação

Semana 1

Responda as questões abaixo quanto aos meios tecnológicos de notificação na 1ª semana da disciplina ministrada pelo professor.

WhatsApp
Apenas números podem ser usados nesse campo.

? Informar quantas vezes nessa 1ª semana, foi considerado importante interagir com o professor através do Whatsapp

E-mail
Apenas números podem ser usados nesse campo.

? Informar quantas vezes nessa 1ª semana, foi considerado importante interagir com o professor através do E-mail

Facebook
Apenas números podem ser usados nesse campo.

? Informar quantas vezes nessa 1ª semana, foi considerado importante interagir com o professor através do Facebook

SMS
Apenas números podem ser usados nesse campo.

? Informar quantas vezes nessa 1ª semana, foi considerado importante interagir com o professor através de SMS

Enviar para coordenador?

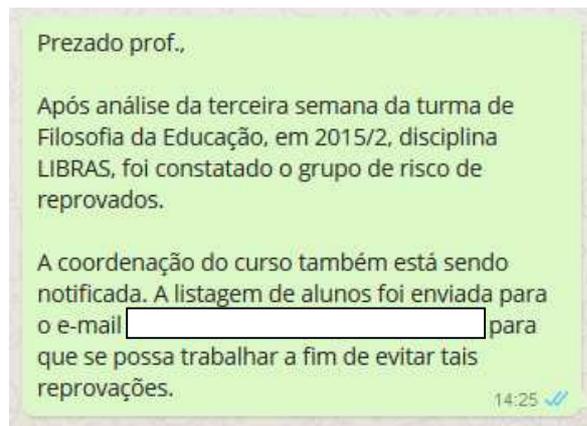
Sim Não

? Informar se nessa 1ª semana, foi considerado importante interagir junto com o professor em dificuldades diversas dos alunos

Ao preencher os meios tecnológicos de notificação, a coordenação do curso considerou como relevante utilizar apenas *WhatsApp* e e-mail para entregar a recomendação para o professor. Para fins do experimento, a coordenação foi notificada apenas pelo e-mail. Quando a árvore de decisão de classificação do perfil de professor definiu o “sim” para notificar o coordenador em todas as semanas da disciplina, partiu-se então para o aguardo do fim de cada semana a fim de receber do sistema externo de predição, quais aprendizes poderiam reprovar na disciplina. No experimento foi utilizado o MD-PREAD.

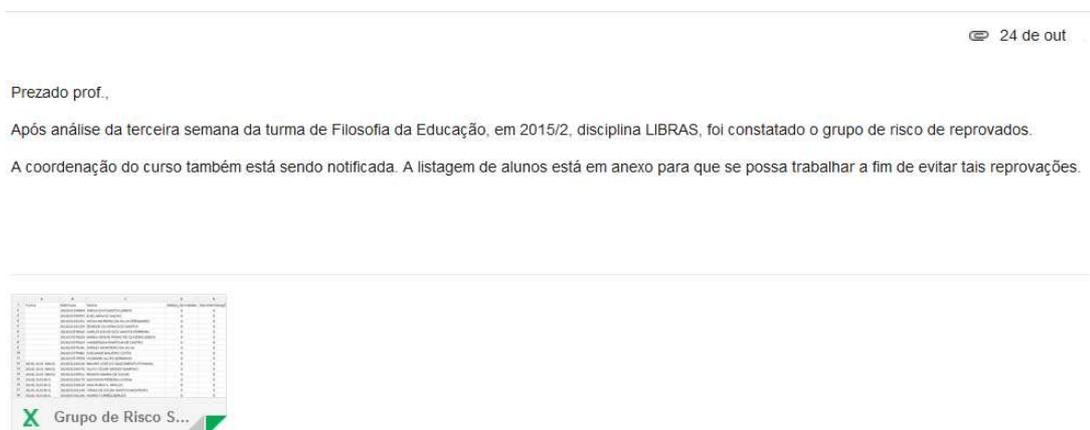
Ao término da primeira semana, o sistema recebeu a análise do grupo de risco de reprovação na disciplina e realizou o envio para apreciação de tomada de decisões. Essa ação se repetiu ao longo das semanas seguintes e serviu como mecanismo de alerta ao professor e à coordenação. Nas Figuras 35 e 36, ficam evidenciadas a notificação sendo feita por *WhatsApp* e e-mail respectivamente. A Figura 37 apresenta um fluxograma do experimento, mostrando o ciclo do início ao término da disciplina.

Figura 35 - Notificação (WhatsApp)



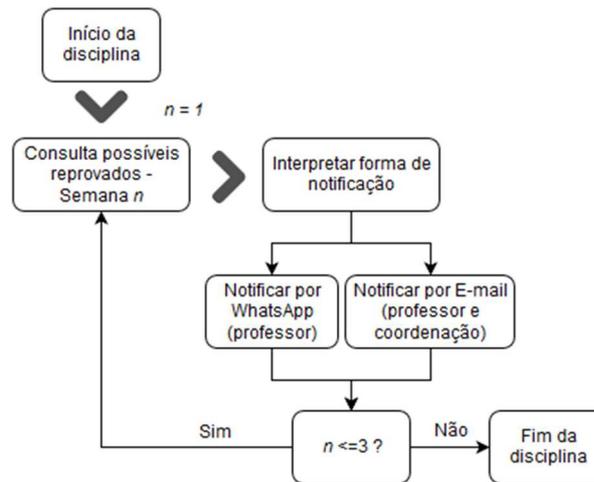
Fonte: Próprio autor

Figura 36 - Notificação (E-mail)



Fonte: Próprio autor

Figura 37 - Fluxograma do experimento



Fonte: Próprio autor

Ainda sobre a Figura 37 percebe-se que à medida que as semanas vão passando, condições são verificadas que norteiam o fluxo do processo.

Num primeiro momento, o módulo de consulta recebe do sistema de predição externo a listagem dos alunos candidatos à reprovação. Em seguida, o módulo de análise de dados confronta o perfil do usuário com a classificação do perfil de professor, para avaliar de que forma vai ocorrer a notificação, tanto para o professor quanto para o coordenador do curso. Após essa etapa, os tipos de notificação detectados são acionados disparando a recomendação aos usuários. Posteriormente há uma verificação para interpretar se o total de semanas daquela disciplina foi atingido, em caso positivo o sistema volta para o estado da consulta, do contrário o trabalho é encerrado.

Apesar do módulo administrativo não estar explícito no fluxograma, ele é o encarregado pelo cadastramento dos dados dos perfis e pela interação dos usuários com o sistema.

O coordenador do curso, através da interface do sistema, pode encaminhar diretamente ao professor da disciplina conteúdos midiáticos que julgar importantes, não ficando, portanto, restrito ao recebimento da listagem de alunos por parte do professor. Caso entenda que haja necessidade em modificar as respostas do perfil do professor, o coordenador pode realizar as alterações e solicitar uma reclassificação do perfil do professor, porém a mudança na classificação final dependerá das regras de classificação identificadas no treinamento.

Durante o experimento, constatou-se a possibilidade de conceber funcionalidades novas para a aplicação, como por exemplo, classificar o perfil do coordenador de curso de maneira semelhante à classificação feita com o perfil do professor. Outra possibilidade é a utilização de outro(s) algoritmo(s) de classificação além da árvore de decisão para os perfis de usuário.

Ambas as funcionalidades podem ser adicionadas com pouca ou nenhuma modificação no M-SRECP, expressando dessa forma que o modelo proposto é capaz de atender diferentes particularidades. Além dessas, pode ser adotado o uso de *NoSQL* (*Not Only SQL*) e programação reativa (*Reactive Programming*) como uma alternativa para o modelo de programação imperativo baseado em *threads*, visando a escalabilidade da aplicação.

Foram executadas um total de quatro recomendações, uma por semana. Por serem ambos alvos da recomendação, o professor e a coordenação do curso utilizaram o protótipo com

o objetivo de saber quem eram os aprendizes que poderiam reprovar na disciplina e atuaram em conjunto objetivando a redução do quantitativo.

Na primeira semana o sistema recomendou por meio de envio de mensagens de *WhatsApp* (para o professor) e e-mail (para professor e coordenador), 124 aprendizes matriculados no curso, informação esta que também estava disponível e acessível pela *interface web* do sistema. Todos os 124 aprendizes estavam com predição de reprovação, o que gerou uma preocupação inicial. No entanto, após uma análise cuidadosa, percebeu-se que essa era a demanda inicial do curso em 2014/2 e naquele momento muitos desistentes ainda constavam como matriculados. Além disso, uma atividade avaliativa da primeira semana não havia tido respostas de nenhum aprendiz.

Na segunda semana, o sistema voltou a fazer recomendação via mensagens de *WhatsApp* e e-mails, da mesma maneira que ocorreu na primeira semana, novamente disponibilizando a mesma listagem pela *interface web*. Ao ter acesso a essa informação, professor e coordenador perceberam que o número havia reduzido para 54. Apesar de nesse quantitativo ainda constar os desistentes do curso, notou-se uma redução na possível reprovação mostrando que a atuação em conjunto do professor e da coordenação, e que envolveu inclusive tutores, surtiu efeito.

Na terceira semana, após uma nova rodada de recomendação, uma vez mais através de mensagem por *WhatsApp* para professor e e-mails para professor e coordenador, ambos foram informados pelo sistema que a predição havia aumentado para 90. Após um breve momento de apreensão, concluiu-se que além dos aprendizes desistentes, alguns outros ficaram com o *status* de possível reprovação porque naquela semana haviam duas atividades avaliativas no Ambiente Virtual de Aprendizagem que não foram respondidas, semelhantemente ao que havia ocorrida na primeira semana. A recomendação, a essa altura, foi útil para manter professor e coordenador em estado de alerta para a quarta e derradeira semana da disciplina.

Na quarta semana, quando houve a última recomendação pelo sistema, utilizando *WhatsApp* e e-mails, ocorreu uma leve mudança de comportamento por parte do professor e da coordenação. Apesar de terem recebido as recomendações, da mesma maneira que ocorreu nas semanas anteriores, ambos deram prioridade para acesso às informações pela *interface web*, pois por ela tinham acesso direto e centralizado aos dados consolidados de todas as semanas, o que os incentivou a terem uma atuação ainda mais incisiva com os aprendizes. O sistema recomendou na última semana, 70 possíveis reprovados. Apesar dos desistentes ainda constarem na listagem, o número foi considerado elevado. A explicação para tal se deu pelo motivo de que a nota da avaliação presencial, conforme organização didática do IFAM, a qual é obrigatória e tem peso dois, ainda não havia sido lançada.

Ao término das rodadas de recomendações, foi constatado pelo MD-PREAD que na última semana havia efetivamente 15 aprendizes com predição de reprovação: 9 lograram êxito na aprovação, e outros 6 reprovaram. Estatisticamente, 60% dos aprendizes que corriam o risco de reprovar na disciplina de Libras, aprovaram. Dentre os 9 aprendizes aprovados, constatou-se que: (i) 4 foram concludentes e que estavam pendentes apenas com o trabalho de conclusão de curso; (ii) 3 estavam com pendência em 1 disciplinas; (iii) 1 estava com pendência em 2 disciplinas; (iv) 1 estava com pendência em 4 disciplinas.

Portanto 44,4% dos aprendizes obtiveram aprovação e outros 33% estavam bem encaminhados para a conclusão do curso. Esses números foram considerados positivos pelo professor e pela coordenação, pois permitiram que 4 dos 9 aprendizes pudessem seguir adiante no curso com caminho desimpedido rumo à certificação, já quem 2015/2 foi efetivamente o último semestre do curso.

Após o envio de 12 mensagens em 4 semanas, sendo que 8 dessas mensagens foram destinadas ao professor (4 por WhatsApp e 4 por e-mail) e 4 ao coordenador (todas por e-mail), além de um total de 32 acessos ao sistema (13 pelo professor e 19 pela coordenação), constatou-se que as ações tomadas por parte de ambos os profissionais foram relevantes para recuperar os aprendizes, ações essas que foram consequência das recomendações feitas semanalmente. Pode-se afirmar, portanto, que as recomendações feitas auxiliaram professor e coordenação do curso a se empenharem pela redução de reprovação dos aprendizes.

O protótipo mostrou um funcionamento adequado a aquilo que se propõe no modelo. O objetivo de enviar recomendações ao professor de uma disciplina em andamento, bem como para a coordenação do curso, foi alcançado. As funcionalidades apresentadas no modelo e implementadas no protótipo, foram testadas e deram os resultados esperados.

O processo de classificação realizado no *RapidMiner*, com a árvore de decisão, e que foi integrado ao protótipo pelo uso de sua API, operou com sucesso visto que as recomendações ocorreram de acordo com o informado pela ferramenta na classificação do perfil do professor.

O uso dos *plug-ins* de CRM para *Grails* também foi proveitoso, pois permitiu que os conceitos de relacionamento ao cliente, em uma perspectiva voltada para o ensino, pudessem ser utilizados, especialmente o agendamento de tarefas e notificação ao usuário. Outro recurso testado foi o envio de conteúdo midiático pelo sistema, usado principalmente pelo coordenador de curso que utilizou essa funcionalidade para enviar ao professor, pelo sistema, sugestões pedagógicas para serem tomadas em conjunto, em formatos diversos como arquivos PDF, e links para sites ou para vídeos no *YouTube*.

A *interface web* proporcionou aos usuários uma experiência adicional, permitindo a busca da informação diretamente no sistema, não se restringindo apenas as mensagens oriundas das recomendações semanais. Um benefício de buscar as informações diretamente no sistema é a centralização das informações semanais facilitando o acesso às mesmas, visto que as recomendações feitas por *WhatsApp* e e-mail eram feitas periodicamente exigindo, portanto, mais esforço pelos usuários para unificá-las.

A avaliação de funcionalidade permitiu que tanto professor, quanto coordenador, qualificasse o uso do sistema. A eles foi submetido o mesmo questionário utilizado pela avaliação de usabilidade e ambos avaliaram as funcionalidades de forma positiva, respondendo com total concordância a todas as questões do questionário, formulado de acordo com a Tabela 2 vista na seção 6.2 sobre a avaliação de usabilidade. Como forma complementar informaram também que a ferramenta proporcionou uma integração maior entre professor e coordenação de curso, além de aprimorar o entendimento pedagógico de ambos, fazendo-os chegar a um consenso quanto às ações tomadas.

As seguintes sugestões foram apresentadas pelos avaliadores para melhoria do sistema:

- incluir outros tipos de usuários no modelo, como tutores a distância e presenciais, e coordenadores de polo;
- explorar mais o recurso de classificação de perfis, incluindo os novos tipos de usuários e ampliando as opções resultantes da classificação;
- disponibilizar mais opções de meios tecnológicos para enviar a recomendação;
- possibilitar o cadastro de anotações para registro de ações, principalmente em relação aos aprendizes;

- permitir que os aprendizes sejam “etiquetados” no sistema. Ex: Aprendiz01 etiquetado como “reprovado” ou “aprovado”;
- fornecer um recurso de convites, a fim de chamar outros usuários para interagir na ação de reverter a reprovação dos aprendizes.

Em relação à inclusão de outros tipos de usuários no modelo, como tutores a distância e presenciais, e coordenadores de polo, os avaliadores entendem que o número de aprovação poderia ser maior caso esses usuários também tivessem sido alvos das recomendações. De acordo com eles, caso o tutor presencial e o coordenador de polo também recebessem as recomendações, estes poderiam tomar ações mais diretas com os aprendizes, por estarem na mesma cidade, sem necessidade de aguardar por serem avisados do fato pelo professor ou pela coordenação do curso.

Uma exploração maior do recurso de classificação do perfil sugere estende-lo aos novos tipos de usuários que foram apresentados. Essa extensão pode influir no tipo de classificador a ser utilizado, no surgimento de novas diretrizes para a entrega da recomendação, e conseqüentemente, na inclusão de opções resultantes das classificações.

A disponibilização de mais opções de meios tecnológicos se trata de ter uma variedade maior na forma da entrega. Envio da recomendação diretamente ao AVA, ou por meio de um aplicativo em dispositivo móvel que seja independente das atuais formas de notificar, são exemplos de acréscimo nas possibilidades.

O cadastro de anotações possibilita um registro mais específico para ações tomadas. Permitiria que um professor pudesse registrar para cada aprendiz, anotações individuais e particulares. Essas anotações ficariam disponíveis para visualização pelos demais usuários.

O uso de “etiquetas”, ou *tags*, teria serventia para marcar os aprendizes com rótulos. Além de etiquetar um aprendiz com “reprovado” ou “aprovado”, outras marcações poderiam existir como “em progresso”, para identificar que um esforço está sendo aplicado com o aprendiz, ou “crítico” para identificar aquele aprendiz como sendo de difícil recuperação. Recurso semelhante é utilizado no repositório de projetos de software *GitHub* (“GitHub - Where software is built”, 2016), onde uma *tag* pode, por exemplo, ser utilizada para documentar uma modificação importante.

O recurso de convites seria para que houvesse outra forma de comunicação entre os usuários, possibilitando que um usuário, pelo sistema, convide outros para opinar sobre determinado assunto.

6.2 Avaliação de usabilidade

Esse experimento realizou uma avaliação de usabilidade do M-SRECP. Foram convidados 15 professores do IFAM que já tiveram experiência com cursos de EaD, para responder um questionário de usabilidade. Dos 15 convidados, 12 responderam o questionário, cada um uma única vez, após terem utilizado brevemente o sistema de recomendação. Foi utilizado o método de pesquisa quantitativa cuja amostragem também foi por escolha racional, pois a característica específica era ter professores que já trabalharam na EaD.

Da mesma forma como foi realizado para a coleta de dados dos perfis dos professores, para esta etapa da avaliação utilizou-se o sistema de questionários *LimeSurvey* (LIMESURVEY, 2015). As respostas foram padronizadas na escala *Likert* (LIKERT, 1932) de

cinco pontos: discordo totalmente (1), discordo parcialmente (2), indiferente (3), concordo parcialmente (4) e concordo totalmente (5). Os itens do questionário foram elaborados com base nos conceitos do modelo de aceitação de tecnologia TAM, do inglês *Technology Acceptance Model*, proposto por (DAVIS, 1989), aplicado e expandido por (YOON; KIM, 2007). O modelo TAM tem sido considerado um padrão para a avaliação de novas tecnologias (MARANGUNIC; GRANIC, 2014). Esse modelo considera os seguintes itens como principais influências para a aceitação de uma nova tecnologia:

- Facilidade de uso percebida: grau em que uma pessoa acredita que a tecnologia poderia diminuir os seus esforços;
- Percepção de utilidade: grau em que uma pessoa acredita que a tecnologia poderia melhorar o desempenho no desenvolvimento de suas atividades.

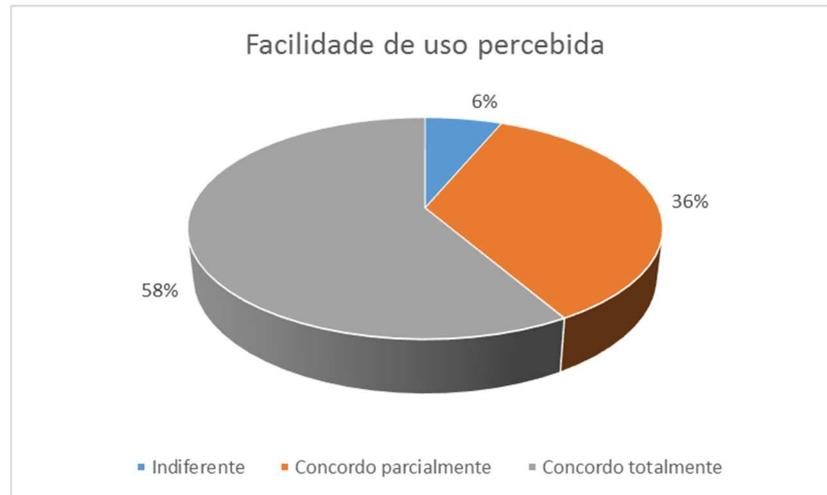
A relação das afirmações apresentadas aos professores neste experimento pode ser vista na Tabela 2. Sendo que das oito afirmações, as quatro primeiras (itens de 1 a 4) referem-se à facilidade percebida no uso do protótipo, as quatro seguintes (itens de 5 a 8) estão relacionadas à utilidade percebida. A análise das respostas foi organizada em gráficos que agrupam os resultados obtidos.

Tabela 2 - Itens do questionário do experimento

Item	Informe de opinião sobre as seguintes afirmações:
1	O sistema é de fácil compreensão.
2	É fácil tornar-se hábil no uso da interface do sistema.
3	As informações sobre os recursos são apresentadas de forma clara e objetiva, permitindo a compreensão.
4	Não é necessário muito esforço para inclusão de novas informações e consulta de informações existentes.
5	Os recursos apresentados são relevantes para redução do índice de reprovação.
6	O uso do sistema estimula o apoio acadêmico e oferece ganhos para a educação.
7	O sistema facilita a identificação de recomendações para disciplinas em andamento.
8	O sistema seria útil para apoiar a tomada de decisões por coordenadores e professores em suas atividades do cotidiano.

Fonte: Próprio autor

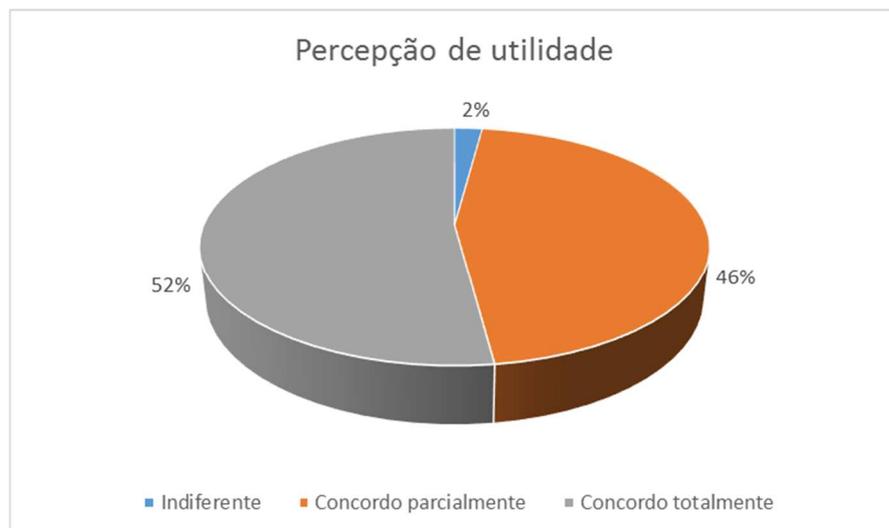
A análise das respostas foi organizada em gráficos que agrupam os resultados obtidos. Os gráficos que representam estatisticamente os itens relacionados à facilidade de uso percebida e percepção de utilidade, podem ser observados respectivamente nas Figuras 38 e 39. A anuência quanto à clareza com que os recursos foram disponibilizados, bem como à serventia que o M-SECP proporciona, está expressa pelas afirmações da Tabela 2.

Figura 38 - Gráfico Facilidade de uso percebida

Fonte: Próprio autor

Conforme apresentado no gráfico da Figura 38 a avaliação dos usuários quanto à facilidade percebida de uso. Observa-se que nesse aspecto o sistema foi avaliado de forma positiva pela maioria dos professores, num total de 94%. Desse total, 58% concordaram totalmente com as afirmações, enquanto 36% concordaram parcialmente. Por outro lado, 6% se mostraram indiferentes, enquanto não houveram respostas para discordância parcial ou total.

Os principais comentários em relação ao aspecto da facilidade percebida de uso relatados por alguns professores, foram em relação a dificuldade na tentativa de utilização do sistema em dispositivos móveis como *tablets* e *smartphones*, o que demonstrou um indicativo da necessidade de desenvolvimento de um aplicativo para dispositivos móveis, bem como trabalhar a interface *web* do sistema para ser mais responsiva nesses dispositivos.

Figura 39 - Percepção de utilidade

Fonte: Próprio autor

Em relação à avaliação da utilidade percebida, o gráfico da Figura 39 apresenta que 98% dos usuários avaliaram positivamente, concordando com os itens de utilidade e relevância. Desse total, 52% concordam totalmente que o sistema é plenamente útil para recomendações de aprendizes com risco de reprovação em disciplinas e 46% concordaram parcialmente. Outros 2% foram indiferentes na avaliação, e não houve incidências sobre discordância.

Os comentários em geral sobre a percepção da utilidade foram positivos. Informação essa que ratifica os números apresentados no gráfico da Figura 38, A maioria dos professores avaliadores ressaltaram a utilidade do M-SRECP. Muitos apontaram a importância dos recursos disponibilizados pelo sistema, devido aos desafios proporcionados pela reprovação de aprendizes. Houve ainda relatos indicando a vantagem de se ter uma ferramenta computacional que faça recomendações enquanto a disciplina está em andamento.

7 CONSIDERAÇÕES FINAIS

Este capítulo apresenta as considerações finais da dissertação. Ao longo do capítulo são apresentados um resumo do trabalho, as principais conclusões, as contribuições do modelo e por fim os trabalhos futuros.

7.1 Resumo e Conclusões

Nos primeiros capítulos, fundamentos teóricos de Educação a distância, sistemas de recomendação, sistemas de recomendação sensíveis a contexto e sistemas de recomendação educacional, foram apresentados. Em seguida retratou-se uma comparação de trabalhos relacionados, contrapondo quesitos pautados nos trabalhos.

O capítulo subsequente, o quarto, fez a apresentação do modelo proposto, relacionando seus módulos e componentes. No quinto capítulo foram apresentados os aspectos de implementação do protótipo do M-SRECP.

No sexto capítulo apresentou-se os aspectos de avaliação do modelo, o qual permitiu avaliar os pontos positivos e os pontos de melhoria. Os resultados obtidos tanto na avaliação semanal ocorrida com o professor da disciplina e com a coordenação do curso, quanto na aplicação do questionário TAM, demonstraram que o modelo proposto teve boa aceitação, trazendo o benefício de reduzir o número total de reprovados em 60%.

A avaliação feita com o professor de Libras e com a coordenação do curso sugestionou a criação de outros perfis de usuários como tutores a distância, tutores presenciais e coordenadores de polo, inclusive utilizando a classificação de perfis para os mesmos. Através dessa avaliação foi possível identificar a necessidade de incluir mais mecanismos para a notificação visando a ampliação das possibilidades tecnológicas de realizar a recomendação e também de classificar todos os tipos de perfis de usuário.

Quanto à avaliação TAM, no que diz respeito à utilidade percebida, houve uma concordância positiva num total de 98% dos professores. Uma vez que essas questões dão ênfase à utilidade para recomendações de aprendizes com risco de reprovação em disciplinas, estímulo ao apoio acadêmico e recuperação de aprendizes, entende-se que sistemas de recomendação educacional que deem suporte a professores e coordenadores de curso devem também oferecer mecanismos que suportem estes tipos de características.

Com relação à facilidade de uso percebida, houve uma concordância positiva de 94% dos professores. Notou-se que são necessários ajustes de aspectos relacionados à interação com o sistema aplicativo, em especial à interface do mesmo. Esse resultado vai de encontro com os comentários feitos pelos professores, que sugerem uma interface mais responsiva em dispositivos móveis *como smartphones e tablets*. Houve também sugestões de criação de um aplicativo específico para dispositivos móveis, considerando que é mais fácil para o usuário abrir diretamente um aplicativo com esse fim do que memorizar a URL completa do sistema web. Embora não tenha sido desenvolvido um aplicativo desse tipo, é possível implementá-lo e integra-lo ao M-SRECP.

Além dessas conclusões alcançadas nesta dissertação, outras podem ser destacadas, que são as seguintes:

- o desenvolvimento do protótipo do M-SRECP expôs a exequibilidade de um modelo computacional com suporte a diferentes perfis de usuários de professores e coordenadores;
- a criação de uma árvore de decisão que realiza a classificação do perfil de professor permitiu identificar padrões de comportamento, mostrando-se bastante útil na notificação ao coordenador de curso;
- o uso de questionários para coleta de dados viabilizou a criação de um conjunto de treinamento que possibilitou a classificação do perfil de professor;
- o desenvolvimento do protótipo permitiu constatar que o M-SRECP pode suportar diferentes aplicações relacionadas sistemas de recomendação educacional para professores e coordenadores, mostrando assim ser um modelo genérico;
- o uso de sensibilidade ao contexto mostrou a relevância do sistema buscar ter uma interação com o usuário, e não o contrário, em determinado período de tempo;
- utilizar CRM para o ensino mostrou que é possível adaptar o conceito de “relacionamento com o cliente” para “relacionamento com o professor”, ou ainda “com o coordenador”.

7.2 Contribuições

Este trabalho contribuiu com a aplicação das técnicas de classificação de perfis de professores, sensibilidade a contexto e *Customer Relationship Management* moldado para o ensino, mostrando que é possível criar um SRE que busque realizar entrega de recomendações de reprovação de aprendizes em disciplinas, com regras baseadas em perfis de professores e coordenadores de curso.

Também constatou que a utilização do modelo pode contribuir na atenuação dessas reprovações por ser uma ferramenta computacional que permite a interação com professores e coordenadores, enquanto a disciplina está em andamento. Uma contribuição que auxilia na tomada de decisões preventivas, e não apenas corretivas, visando corrigir problemas que causem danos maiores, como o atraso na formação ou até mesmo desistência do curso. Contribuição que também é social, pois oferece a oportunidade de impedir a reprovação, o que garante ao aprendiz um melhor coeficiente de rendimento em seu histórico escolar.

Este trabalho tem como diferencial recomendar a predição de reprovação na disciplina para professores e coordenadores num contexto ativo de resgate de aprendizes, ao invés de recomendar diretamente ao próprio aprendiz na esperança passiva que o mesmo se reinvente pedagogicamente.

A Tabela 3 possui o mesmo formato utilizado na Tabela 1, apresentada no capítulo três. Nesta nova tabela foi acrescentada uma coluna para a comparação dos trabalhos relacionados com o M-SRECP. Em seguida é informado como o M-SRECP aborda cada um dos quesitos de comparação:

- **Objetos de aprendizagem:** o modelo não utiliza objetos de aprendizagem, porém possui a funcionalidade de gerenciamento de conteúdo do CRM para envio de arquivos de um usuário (geralmente coordenador) para outro (geralmente professor);
- **Sensibilidade a contextos:** o M-SRECP tem como funcionalidade a notificação por agendamento, o que lhe confere a característica de possuir informações sobre o contexto em que determinado(s) usuário(s) está(ão) inserido(s);
- **Utiliza Agentes:** não utilizou-se agentes de software no modelo, pois não foi identificada a necessidade de usufruir de sua principal característica, que é ser uma entidade computacional com um comportamento autônomo que lhe permite decidir suas próprias ações;
- **Utiliza Ontologia:** não houve uso de ontologia, no entanto utilizou-se metamodelos de perfis dos usuários, permitindo treinar e classificar informações provenientes desses perfis através do uso de árvore de decisão;
- **Público-alvo:** o M-SRECP pode ser utilizado para dois tipos de público: professor e coordenador. O professor que está à frente da disciplina, e o coordenador do curso que irá acompanhar o trabalho do professor;
- **Utiliza perfis:** faz uso de gerenciamento de perfis no trabalho. Através do módulo administrativo, cada usuário tem um perfil único no M-SRECP, e possui informações relevantes que são compartilhadas com o módulo de análise de dados;
- **EaD:** houve abordagem na Educação a distância no escopo do trabalho, porém o modelo não está restrito a essa modalidade de ensino;
- **Usa CRM:** como parte da contribuição está o uso de funcionalidades de CRM para um sistema de recomendação educacional, algo que não foi identificado nos demais trabalhos relacionados.

Tabela 3 – Comparação entre os trabalhos relacionados e o M-SRECP

Trabalhos	OA	Contexto	Agente	Ontologia	Público-alvo	Perfis	EAD	CRM
Geração recomendações sensíveis a contexto (GALLEGO <i>et al.</i> , 2012)	Sim	Social, localização e do usuário	Não	Não	Aprendizes e Professores	Usuário	Sim	Não
Ubigroup (FERREIRA <i>et al.</i> , 2015)	Sim	Momento do aprendizado	Sim	Sim	Aprendizes e Professores	De aprendizado	Não	Não
Recomendação baseado na Problematização (GOMINHO; TEDESCO; BELIAN, 2014)	Sim	Conjunto de dado, informação ou conhecimento	Não	Não	Aprendizes	Usuário	Não	Não
MobiLE (SILVA, LUIZ CLÁUDIO)	Sim	Estático, considerand	Sim	Sim	Aprendizes	Usuário	Não	Não

NOGUEIRA DA; NETO; JÚNIOR, 2011)		o local, dia e horário						
e-LORS (ZAINA <i>et al.</i> , 2012)	Sim	Ações que o usuário executa	Não	Não	Aprendizes	Usuário	Não	Não
AICAPA (MENEZES; VALE; CRUZ, 2014)	Não	Problema de Pesquisa	Sim	Sim	Professores (pesquisad ores)	Usuário (interess es)	Não	Não
RECoaComp (CAZELLA <i>et al.</i> , 2012)	Sim	Desenvolvi mento do aprendizado	Não	Não	Aprendizes e Professores	Usuário	Sim	Não
Auxílio Personalizado com Agentes (BREMGA RTNE R; NETTO, 2012)	Não	Não	Sim	Sim	Aprendizes e Professores	Usuário	Sim	Não
Otilia (MOTA; DE CARVALHO; REIS, 2014)	Não	Aprendizado e Criação de cenários	Não	Sim	Professores	Usuário	Sim	Não
M-SRECP	Não	Sim, da disciplina	Não	Não	Professores e coordenado res	Usuário, com classific ação de perfil	Sim	Sim

Fonte: Próprio autor

7.3 Trabalhos futuros

O M-SRECP estabelece uma proposta inicial que pode ser melhorada. Ao longo do desenvolvimento deste trabalho, melhorias foram identificadas e avanços que apontam para trabalhos futuros. A seguir são listados os pontos considerados mais importantes:

- incorporar mais conceitos de CRM, como campanhas de marketing e aplica-los no modelo em forma de componentes, em conjunto com recursos de mineração de dados, para melhorar o alcance ao público-alvo e prover análises de apoio a métricas ROI (*Return On Investment*);
- criar outros tipos de perfis de usuários, como tutores e coordenadores de polo, no caso da educação a distância. Para cursos presenciais, outros perfis podem ser estudados;
- progredir a arquitetura do modelo, tornando-a orientada a eventos (*event-driven*), bem como deixa-la escalável para suportar grandes quantidades de acessos e dados. Essa adoção pode implicar na utilização de *NoSQL (Not Only SQL)*;

- ampliar a avaliação, aperfeiçoando o cenário adotado neste trabalho e adotando outros cenários de aplicação, como o ensino presencial, explorando aplicações adicionais do M-SRECP;
- desenvolver um aplicativo em dispositivo móvel para aproximar o usuário ao modelo, explorando mais a sensibilidade a contexto ao facilitar o recebimento de recomendações e agilidade na tomada de ações;
- adoção dos quatro conceitos de sistemas reativos (*Reactive Systems*): responsivo (*responsive*), resiliente (*resilient*), elástico (*elastic*) e impulsionado por mensagens (*Message Driven*);
- disponibilizar o M-SRECP para uso em diversos níveis e modalidades de ensino;
- usar um grupo adicional, de controle, em outro experimento, sendo um grupo com p uso da ferramenta e outro sem o uso, a fim de medir com mais precisão os benefícios do modelo.

REFERÊNCIAS

- ADOMAVICIUS, G.; TUZHILIN, A. Toward the next generation of recommender systems: a survey of the state-of-the-art and possible extensions. *IEEE Transactions on Knowledge and Data Engineering*, v. 17, n. 6, p. 734–749, 1 jun. 2005. Disponível em: <<http://ieeexplore.ieee.org/articleDetails.jsp?arnumber=1423975>>. Acesso em: 9 jul. 2014.
- ADOMAVICIUS, Gediminas; TUZHILIN, Alexander. Context-Aware Recommender Systems. In: RICCI, FRANCESCO *et al.* (Org.). *Recommender Systems Handbook*. Boston, MA: Springer US, 2011. p. 217–253. Disponível em: <http://link.springer.com/chapter/10.1007%2F978-0-387-85820-3_7>. Acesso em: 7 maio 2015.
- AGUIAR, Janderson J B *et al.* Um Mapeamento Sistemático sobre Iniciativas Brasileiras em Sistemas de Recomendação Educacionais. *Anais do Simpósio Brasileiro de Informática na Educação*, n. Cbie, p. 1123–1132, 2014. Disponível em: <<http://www.br-ie.org/pub/index.php/sbie/article/view/3058>>.
- ALVES, Lucineia. *Educação a distância: conceitos e história no Brasil e no mundo*. Disponível em: <http://www.abed.org.br/revistacientifica/Revista_PDF_Doc/2011/Artigo_07.pdf>. Acesso em: 15 fev. 2015.
- BOBADILLA, J. *et al.* Recommender systems survey. *Knowledge-Based Systems*, v. 46, p. 109–132, jul. 2013. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0950705113001044>>. Acesso em: 9 jul. 2014.
- BONHARD, P.; SASSE, M. A. 'Knowing me, knowing you' — Using profiles and social networking to improve recommender systems. *BT Technology Journal*, v. 24, n. 3, p. 84–98, jul. 2006. Disponível em: <<http://link.springer.com/10.1007/s10550-006-0080-3>>. Acesso em: 7 maio 2015.
- BRASIL. Decreto 5.622, de 19 de dezembro de 2005. Regulamenta o artigo 80 da Lei no 9.394, de 20 de dezembro de 1996, que estabelece as diretrizes e bases da educação nacional. [S.l.]: Diário Oficial [da] República Federativa do Brasil, 2005. Disponível em: <http://www.planalto.gov.br/ccivil_03/_Ato2004-2006/2005/Decreto/>.
- BREMGARTNER, Vitor; NETTO, José Francisco M. Relato de uma Experiência de Auxílio Personalizado a Alunos em Ambiente Virtual de Aprendizagem Utilizando Agentes. *Anais do Workshop de Informática na Escola*, 2012. Disponível em: <<http://www.br-ie.org/pub/index.php/wie/article/view/2122>>. Acesso em: 14 fev. 2015.
- BROWN, Malcolm. Learning Analytics: Moving from Concept to Practice. *EDUCAUSE Learning Initiative Brief*, n. July, p. 1–5, 2012. Disponível em: <<http://www.educause.edu/library/resources/learning-analytics-moving-concept-practice>>.
- CAZELLA, Silvio Cesar *et al.* Desenvolvendo um Sistema de Recomendação de Objetos de Aprendizagem baseado em Competências para a Educação: relato de experiências. *Anais do Simpósio Brasileiro de Informática na Educação*, v. 23, n. 1, 2012. Disponível em: <<http://www.br-ie.org/pub/index.php/sbie/article/view/1710>>. Acesso em: 14 fev. 2015.
- COSTA, Evandro; AGUIAR, Janderson; MAGALHÃES, Jonathas. Sistemas de Recomendação de Recursos Educacionais: conceitos, técnicas e aplicações. *Anais da Jornada*

de *Atualização em Informática na Educação*, v. 1, n. 1, 2013. Disponível em: <<http://www.br-ie.org/pub/index.php/pie/article/view/2589>>. Acesso em: 14 fev. 2015.

CUI, Yanchun; BULL, Susan. Context and learner modelling for the mobile foreign language learner. *System*, v. 33, n. 2, p. 353–367, jun. 2005. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0346251X05000229>>. Acesso em: 13 abr. 2015.

DAVIS, Fred D. Perceived Usefulness, Perceived Ease of Use, and User Acceptance of Information Technology on JSTOR. *MIS Quarterly*, v. 13, n. 3, p. 319–340, 1989. Disponível em: <http://www.jstor.org/stable/249008?seq=1#page_scan_tab_contents>. Acesso em: 28 maio 2015.

DEY, Anind K. Understanding and Using Context. *Personal and Ubiquitous Computing*, v. 5, n. 1, p. 4–7, 28 fev. 2001. Disponível em: <<http://dl.acm.org/citation.cfm?id=593570.593572>>. Acesso em: 10 dez. 2014.

Draft Standard for Learning Object Metadata. Disponível em: <http://129.115.100.158/txlor/docs/IEEE_LOM_1484_12_1_v1_Final_Draft.pdf>. Acesso em: 22 abr. 2015.

EHRSSON, Göran. *GR8 CRM - Great Customer Relationship Management Plugins for the Grails Web Framework*. Disponível em: <<http://gr8crm.github.io/>>. Acesso em: 30 jul. 2015.

FELDER, Richard M.; SILVERMAN, Linda K. *Learning and Teaching Styles In Engineering Education*. Disponível em: <<http://www4.ncsu.edu/unity/lockers/users/f/felder/public/Papers/LS-1988.pdf>>. Acesso em: 22 abr. 2015.

FERREIRA, Luis Gustavo Araujo *et al.* UbiGroup: Um Modelo de Recomendação Ubíqua de Conteúdo para Grupos Dinâmicos de Aprendizes. *Revista Brasileira de Informática na Educação*, v. 23, n. 03, p. 40, 29 dez. 2015. Disponível em: <<http://www.br-ie.org/pub/index.php/rbie/article/view/2870>>. Acesso em: 10 jan. 2016.

FERRO, Márcio Robério da Costa *et al.* Um Modelo de Sistema de Recomendação de Materiais Didáticos para Ambientes Virtuais de Aprendizagem. *Anais do Simpósio Brasileiro de Informática na Educação*, 2011. Disponível em: <<http://www.br-ie.org/pub/index.php/sbie/article/view/1643>>. Acesso em: 15 fev. 2015.

GALLEGO, Daniel *et al.* A model for generating proactive context-aware recommendations in e-Learning systems. out. 2012, [S.l.]: IEEE, out. 2012. p. 1–6. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6462246>>. Acesso em: 28 fev. 2015.

GitHub - Where software is built. Disponível em: <<https://github.com>>. Acesso em: 15 jan. 2016.

Global Excursions. Disponível em: <<http://www.globalexursion-project.eu/>>. Acesso em: 27 mar. 2015.

GOMES, Roseane Lins Vasconcelos; BELIAN, Rosalie B. (Orientadora); LIMA, Luciane S. de (Coorientadora). *Estratégia de ensino problematizadora para o processo de aprendizagem na assistência de enfermagem à criança de zero a dois anos: o software penSAE*. 2014. Universidade Federal de Pernambuco, 2014. Disponível em: <<http://repositorio.ufpe.br:8080/xmlui/handle/123456789/13132>>. Acesso em: 22 abr. 2015.

- GOMINHO, Fausto J. F. B.; TEDESCO, Patrícia; BELIAN, Rosalie B. Um Assistente de Recomendação Sensível ao Contexto para Ambientes Virtuais de Aprendizagem baseados na Metodologia da Problematização. *Anais do Simpósio Brasileiro de Informática na Educação*, v. 25, n. 1, p. 1093–1097, 2014. Disponível em: <<http://www.br-ie.org/pub/index.php/sbie/article/view/3053>>. Acesso em: 5 fev. 2015.
- GOTARDO, Reginaldo; CEREDA, Paulo Roberto Massa; JUNIOR, Estevam Rafael Hruschka. *Predição do Desempenho do Aluno usando Sistemas de Recomendação e Acoplamento de Classificadores*. *Anais do Simpósio Brasileiro de Informática na Educação*. [S.l: s.n.]. Disponível em: <<http://www.br-ie.org/pub/index.php/sbie/article/view/2544>>. Acesso em: 6 fev. 2015. , 2013
- GOUVÊA, Guaracira; OLIVEIRA, Carmem Irene. *Educação a distância na formação de professores : viabilidades, potencialidades e limites*. 4. ed. Rio de Janeiro: Vieira & Lent, 2006.
- GRAILS PROJECT. *The Grails framework: A powerful Groovy-based web application framework for the JVM*. Disponível em: <<https://grails.org/>>. Acesso em: 14 mar. 2015.
- GROOVY PROJECT. *The Groovy programming language: A multi-faceted language for the Java platform*. Disponível em: <<http://groovy-lang.org/>>. Acesso em: 14 mar. 2015.
- IMS GLOBAL LEARNING CONSORT. *Learning Design Specifications*. Disponível em: <<http://www.imsglobal.org/learningdesign/>>. Acesso em: 15 fev. 2015.
- IntelliJ IDEA the Java IDE*. Disponível em: <<https://www.jetbrains.com/idea/>>. Acesso em: 7 jan. 2016.
- JADE. *JAVA Agent DEvelopment Framework*. Disponível em: <<http://jade.tilab.com>>.
- JÚNIOR, Aladir F. Silva; SILVA, Leandro Roberto Da; FERNANDES, Clovis Torres. Panorama dos Editores de Atividades de Aprendizagem em IMS Learning Design. *Anais do Simpósio Brasileiro de Informática na Educação*, v. 24, n. 1, 2013. Disponível em: <<http://www.br-ie.org/pub/index.php/sbie/article/view/2512>>. Acesso em: 15 fev. 2015.
- LEVIS, Darci *et al.* Aperfeiçoamento Automático do Perfil do Aprendiz em Ambientes de Educação Ubíqua. *Anais do Simpósio Brasileiro de Informática na Educação*, v. 1, n. 1, p. 165–174, 1 nov. 2007. Disponível em: <<http://www.br-ie.org/pub/index.php/sbie/article/view/566>>. Acesso em: 20 maio 2015.
- LIKERT, R. A technique for the measurement of attitudes. *Archives of Psychology*, v. 22, n. 140, p. 1–55, 1932. Disponível em: <<http://psycnet.apa.org/psycinfo/1933-01885-001>>. Acesso em: 28 maio 2015.
- LIMESURVEY. *LimeSurvey - the most popular Free Open Source Software survey tool on the web*. Disponível em: <<https://www.limesurvey.org/>>.
- LITWIN, Edith. *Educação a distância : Temas para o Debate de Uma Nova Agenda Educativa*. Porto Alegre: Artmed, 2001.
- LONSDALE, Peter *et al.* Context awareness for MOBIlearn: creating an engaging learning experience in an art museum. p. 115, 1 jan. 2005. Disponível em: <http://www.researchgate.net/publication/236943979_Context_awareness_for_MOBIlearn_creating_an_engaging_learning_experience_in_an_art_museum>. Acesso em: 4 maio 2015.
- MAIA, Carmem Neto; MATTAR, Joao Augusto. *Abc da Ead - A Educação And a Distância*

Hoje. 1. ed. São Paulo: Pearson, 2007.

MARANGUNIĆ, Nikola; GRANIĆ, Andrina. Technology acceptance model: a literature review from 1986 to 2013. *Universal Access in the Information Society*, v. 14, n. 1, p. 81–95, 16 fev. 2014. Disponível em: <<http://link.springer.com/10.1007/s10209-014-0348-1>>. Acesso em: 5 mar. 2015.

MariaDB.org - Continuity and open collaboration. Disponível em: <<https://mariadb.org/>>. Acesso em: 7 jan. 2016.

MEC. *Universidade Aberta do Brasil (UAB)*. Disponível em: <http://portal.mec.gov.br/index.php?option=com_content&id=12265:universidade-aberta-do-brasil-uab&Itemid=510>. Acesso em: 23 mar. 2015.

MENEZES, Crediné Silva; VALE, Karla Samantha Bezerra; CRUZ, Patrícia de Oliveira. AICAPA - Um Ambiente Inteligente e Colaborativo para Apoio à Produção Acadêmica. *RENOTE*, v. 11, n. 3, 2 jan. 2014. Disponível em: <<http://seer.ufrgs.br/index.php/renote/article/view/44478>>. Acesso em: 14 fev. 2015.

MLE. *MLE - Mobile Learning Engine*. Disponível em: <<http://mle.sourceforge.net/mle/index.php>>.

MOORE, Philip *et al.* Intelligent Context for Personalised M-Learning. mar. 2009, [S.l.]: IEEE, mar. 2009. p. 247–254. Disponível em: <<http://ieeexplore.ieee.org/articleDetails.jsp?arnumber=5066794>>. Acesso em: 22 abr. 2015.

MORAIS, Carlos Tadeu Queiroz; FRANCO, Sérgio Roberto K. Estudo de Caso de Alertas e Recomendações para Educação a distância Aplicado em Turmas Heterogêneas. *Informática na educação: teoria & prática*, v. 14, n. 2, 3 maio 2012. Disponível em: <<http://seer.ufrgs.br/index.php/InfEducTeoriaPratica/article/view/22245>>. Acesso em: 14 fev. 2015.

MORAN, José. *O que é Educação a distância*. Disponível em: <<http://www2.eca.usp.br/moran/wp-content/uploads/2013/12/dist.pdf>>. Acesso em: 13 fev. 2015.

MOTA, Dulce; DE CARVALHO, Carlos Vaz; REIS, Luis Paulo. OTILIA — An architecture for the recommendation of teaching-learning techniques supported by an ontological approach. out. 2014, [S.l.]: IEEE, out. 2014. p. 1–7. Disponível em: <<http://ieeexplore.ieee.org/articleDetails.jsp?arnumber=7044479>>. Acesso em: 7 abr. 2015.

NUNES, Ivonio Barros. *Noções de Educacao a Distancia*. Disponível em: <<http://pt.scribd.com/doc/21015548/>>. Acesso em: 15 fev. 2015.

Opencsv. Disponível em: <<http://opencsv.sourceforge.net/>>. Acesso em: 8 jan. 2016.

PREPROCESSOR, Hypertext. PHP. 2015. Disponível em: <www.php.net/>.

PRETI, Oreste. *EAD- uma prática educativa mediadora e mediatizada*. Disponível em: <http://www.uab.ufmt.br/uploads/pcientifica/ead_pratica_educativa.pdf>. Acesso em: 15 fev. 2015.

RAPIDMINER. *RapidMiner - #1 Open Source Predictive Analytics Platform*. Disponível em: <<https://rapidminer.com/>>. Acesso em: 7 out. 2015.

REATEGUI, Eliseo; RIBEIRO, Alexandre; BOFF, Elisa. Um Sistema Multiagente para Controle de um Assistente Pessoal Aplicado a um Ambiente Virtual de Aprendizagem.

RENTE, v. 6, n. 2, 2008. Disponível em:

<<http://seer.ufrgs.br/index.php/renote/article/view/14483>>. Acesso em: 14 fev. 2015.

RIBEIRO, Francisco Adelson Alves; FONSECA, Luis Carlos Costa; FREITAS, Miguel de Sousa. Recomendando Objetos de Aprendizagem a partir das hashtags postadas no Moodle. *Anais do Simpósio Brasileiro de Informática na Educação*, v. 24, n. 1, 2013. Disponível em: <<http://www.br-ie.org/pub/index.php/sbie/article/view/2486>>. Acesso em: 14 fev. 2015.

RICCI, Francesco; ROKACH, Lior; SHAPIRA, Bracha. *Introduction to Recommender Systems Handbook*. Disponível em: <<http://www.inf.unibz.it/~ricci/papers/intro-rec-sys-handbook.pdf>>. Acesso em: 16 fev. 2015.

SILVA, Luiz Cláudio Nogueira Da; NETO, Francisco Milton Mendes; JÚNIOR, Luiz Jácome. MobiLE: Um ambiente Multiagente de Aprendizagem Móvel para Apoiar a Recomendação Sensível ao Contexto de Objetos de Aprendizagem. *Anais do Simpósio Brasileiro de Informática na Educação*, v. 1, n. 1, 2011. Disponível em: <<http://www.br-ie.org/pub/index.php/sbie/article/view/1593>>. Acesso em: 15 fev. 2015.

SILVA, Jader M. *et al.* Content distribution in trail-aware environments. *Journal of the Brazilian Computer Society*, v. 16, n. 3, p. 163–176, 11 jul. 2010. Disponível em: <<http://link.springer.com/10.1007/s13173-010-0015-1>>. Acesso em: 23 abr. 2015.

SILVA, Luiz Cláudio; MENDES NETO, Francisco Milton; JÁCOME JÚNIOR, Luiz. MobiLE: Um Ambiente Multiagente de Aprendizagem Móvel Baseado em Algoritmo Genético para Apoiar a Aprendizagem Ubíqua. *Revista Brasileira de Informática na Educação*, v. 21, n. 01, p. 62, 5 ago. 2013. Disponível em: <<http://www.br-ie.org/pub/index.php/rbie/article/view/1433>>. Acesso em: 14 fev. 2015.

VASCONCELOS, Sérgio Paulo Gomes De. *Educação a distância: histórico e perspectivas*. Disponível em: <<http://www.filologia.org.br/viiiifelin/19.htm>>. Acesso em: 15 fev. 2015.

VERBERT, Katrien *et al.* Context-aware Recommender Systems. *Journal of Universal Computer Science*, v. 16, p. 2175–2178, 2010. Disponível em: <http://www.jucs.org/jucs_16_16/context_aware_recommender_systems/jucs_16_16_2175_2178_editorial.pdf>. Acesso em: 4 maio 2015.

VERBERT, Katrien *et al.* Context-Aware Recommender Systems for Learning: A Survey and Future Challenges. *IEEE Transactions on Learning Technologies*, v. 5, n. 4, p. 318–335, out. 2012. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6189308>>. Acesso em: 16 abr. 2015.

VIEIRA, Vaninha; SANTOS, D O S. *CEManTIKA: A Domain-Independent Framework for Designing Context-Sensitive Systems*. 2008. 73 f. UNIVERSIDADE FEDERAL DE PERNAMBUCO, 2008. Disponível em: <http://www.cin.ufpe.br/~vvs/cemantika/docs/CEManTIKA_description.pdf>.

VIRTUAL, UNIFESP. *Educação a distância: fundamentos e guia metodológico*. Disponível em: <<http://www.virtual.epm.br/material/tis/enf/apostila.htm>>. Acesso em: 15 fev. 2015.

WAGNER, André. *Um Modelo Para Gerenciamento De Perfis De Entidades Através De Inferência Em Trilhas*. Disponível em: <<http://biblioteca.asav.org.br/vinculos/000007/000007D5.pdf>>. Acesso em: 22 maio 2015.

YOON, Cheolho; KIM, Sanghoon. Convenience and TAM in a ubiquitous computing

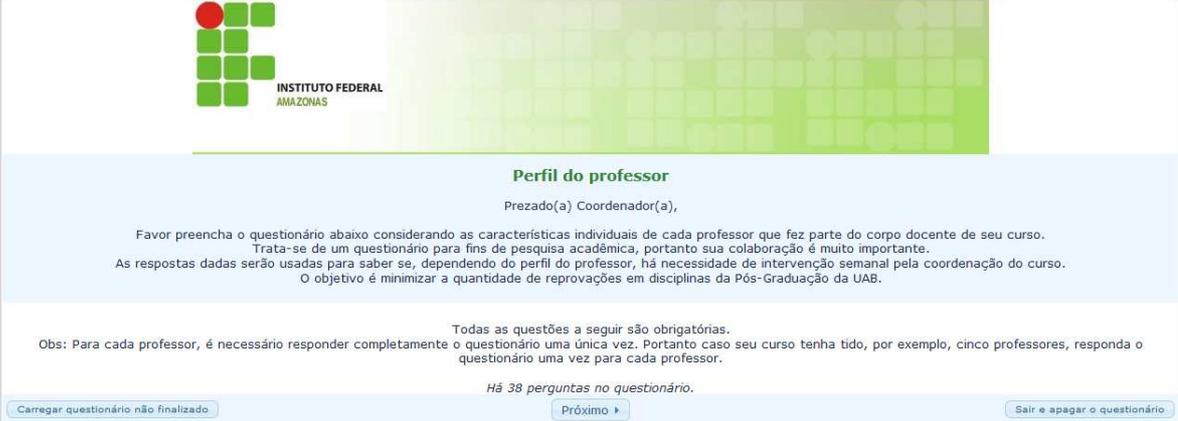
environment: The case of wireless LAN. *Electronic Commerce Research and Applications*, v. 6, n. 1, p. 102–112, mar. 2007. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S156742230600055X>>. Acesso em: 19 abr. 2015.

ZAINA, Luciana A M *et al.* e-LORS: Uma Abordagem para Recomendação de Objetos de Aprendizagem. *Revista Brasileira de Informática na Educação*, v. 20, n. 1, p. 04, 1 abr. 2012. Disponível em: <<http://www.br-ie.org/pub/index.php/rbie/article/view/1289>>. Acesso em: 14 fev. 2015.

APÊNDICE - INFORMAÇÕES COMPLEMENTARES

Neste apêndice estão relacionadas as figuras concernentes ao questionário do perfil de professor, que pode ser visto nas Figuras 40, 41, 42, 43 e 44. Também são apresentadas as listagens de aprendizes com risco de reprovação, resultadas de consultas semanais feitas ao MD-PREAD, nas Tabelas 4, 5, 6 e 7.

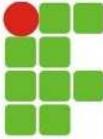
Figura 40 - Questionário de perfil do professor (texto introdutório)



The image shows a web interface for a questionnaire. At the top left is the logo of Instituto Federal Amazonas, consisting of a grid of green squares with one red square at the top left, and the text 'INSTITUTO FEDERAL AMAZONAS' below it. The main heading is 'Perfil do professor'. Below this, it says 'Prezado(a) Coordenador(a),'. The text explains that the questionnaire is for academic research and that responses will be used to determine if weekly intervention is needed to minimize the number of students at risk of failure. It notes that all questions are mandatory and that each professor should complete the questionnaire once. At the bottom, there are three buttons: 'Carregar questionário não finalizado', 'Próximo >', and 'Sair e apagar o questionário'. A status message at the bottom center says 'Há 38 perguntas no questionário.'

Fonte: Próprio autor

Figura 41 - Questionário de perfil do professor (Geral - parte 1)

 **INSTITUTO FEDERAL
AMAZONAS**

Perfil do professor

Prezado(a) Coordenador(a),

Favor preencha o questionário abaixo considerando as características individuais de cada professor que fez parte do corpo docente de seu curso.
Trata-se de um questionário para fins de pesquisa acadêmica, portanto sua colaboração é muito importante.
As respostas dadas serão usadas para saber se, dependendo do perfil do professor, há necessidade de intervenção semanal pela coordenação do curso.
O objetivo é minimizar a quantidade de reprovações em disciplinas da Pós-Graduação da UAB.

0% 100%

Geral

* **Nome**

Data de nascimento

Formato: dd/mm/aaaa

* **Títuloção**
Escolha uma das seguintes respostas:

Especialista
 Mestre
 Doutor(a)
 PhD

 Informe a titulação acadêmica do professor

Fonte: Próprio autor

Figura 42 - Questionário de perfil do professor (Geral - parte 2)

*** Possui cursos de informática?**

Sim Não

? Informar se o professor em questão, tem em seu currículo a realização de curso(s) de informática

*** Possui celular do tipo smartphone?**

Sim Não

? Informar se o professor é detentor de dispositivo móvel com recursos tecnológicos atuais, com Sistema Operacional Android, IOS, Windows, etc.

*** Possui notebook?**

Sim Não

? Informar se o professor, além de possuir, demonstra ter familiaridade com o uso de notebook

*** Possui tablet?**

Sim Não

? Informar se o professor, além de possuir, demonstra ter familiaridade com o uso de tablet

*** Tem experiência com planilhas eletrônicas?**

1 2 3 4 5

? Informar em uma escala de 1 a 5, o nível de familiaridade que o professor demonstra ter com o uso de planilhas eletrônicas como Excel, Libre Office Draw, etc...

*** Tem experiência com editor de texto?**

1 2 3 4 5

? Informar em uma escala de 1 a 5, o nível de familiaridade que o professor demonstra ter com o uso de planilhas eletrônicas como Word, Libre Office Writer, etc...

*** Tem experiência com acesso à internet?**

1 2 3 4 5

? Informar em uma escala de 1 a 5, o nível de familiaridade que o professor demonstra ter com acesso à Internet

*** Tem experiência com apresentação de slides?**

1 2 3 4 5

? Informar em uma escala de 1 a 5, o nível de familiaridade que o professor demonstra ter com apresentação de slides usando ferramentas como Power Point, Libre Office Presentation, etc...

Fonte: Próprio autor

Figura 43 - Questionário de perfil do professor (Geral - parte 3)

*** Tem experiência com Moodle?**

1 2 3 4 5

? Informar em uma escala de 1 a 5, o nível de familiaridade que o professor demonstra ter com o uso do Moodle

*** Proatividade**

1 2 3 4 5

? Informar em uma escala de 1 a 5, sendo 1 = Muito baixo e 5 = Muito alto, como você qualifica a proatividade do professor em lidar com problemas relacionados a dificuldade de aprendizado de um aluno

*** Afinidade**

1 2 3 4 5

? Informar em uma escala de 1 a 5, sendo 1 = Muito baixo e 5 = Muito alto, como você qualifica o professor quanto à afinidade com as tecnologias dos dias atuais

*** Aplicabilidade**

1 2 3 4 5

? Informar em uma escala de 1 a 5, sendo 1 = Muito baixo e 5 = Muito alto, como você qualifica o professor quanto à aplicabilidade do conteúdo curricular

*** Absorção**

1 2 3 4 5

? Informar em uma escala de 1 a 5, sendo 1 = Muito baixo e 5 = Muito alto, como você qualifica o professor quanto à preocupação com a absorção de conhecimento por parte dos alunos

*** Inovação**

1 2 3 4 5

? Informar em uma escala de 1 a 5, sendo 1 = Muito baixo e 5 = Muito alto, como você qualifica o professor quanto à busca em inovar seus métodos de ensino

*** Quantas semanas durou a disciplina ministrada pelo professor?**
Apenas números podem ser usados nesse campo.
A sua resposta deve ser entre 1 e 4

Fonte: Próprio autor

Figura 44 - Questionário de perfil do professor (tipos de notificações semanais)

0% 100%

Semana 1

Responda as questões abaixo quanto aos meios tecnológicos de notificação na 1ª semana da disciplina ministrada pelo professor.

*** Whatsapp**
Apenas números podem ser usados nesse campo.

? Informar quantas vezes nessa 1ª semana, foi considerado importante interagir com o professor através do Whatsapp

*** E-mail**
Apenas números podem ser usados nesse campo.

? Informar quantas vezes nessa 1ª semana, foi considerado importante interagir com o professor através do E-mail

*** Facebook**
Apenas números podem ser usados nesse campo.

? Informar quantas vezes nessa 1ª semana, foi considerado importante interagir com o professor através do Facebook

*** SMS**
Apenas números podem ser usados nesse campo.

? Informar quantas vezes nessa 1ª semana, foi considerado importante interagir com o professor através de SMS

*** Enviar para coordenador?**

Sim Não

? Informar se nessa 1ª semana, foi considerado importante interagir junto com o professor em dificuldades diversas dos alunos

Retomar mais tarde

Fonte: Próprio autor

Tabela 4 - Grupo de risco (semana 1). Origem: MD-PREAD

Nome	MédiaDeMédia das Atividades	prediction(Situação)	confidence(REPROVADO)
Aluno 01	0	REPROVADO	1
Aluno 02	0	REPROVADO	1
Aluno 03	0	REPROVADO	1
Aluno 04	0	REPROVADO	1
Aluno 05	0	REPROVADO	1
Aluno 06	0	REPROVADO	1
Aluno 07	0	REPROVADO	1
Aluno 08	0	REPROVADO	1
Aluno 09	0	REPROVADO	1
Aluno 10	0	REPROVADO	1
Aluno 11	0	REPROVADO	1
Aluno 12	0	REPROVADO	1
Aluno 13	0	REPROVADO	1
Aluno 14	0	REPROVADO	1
Aluno 15	0	REPROVADO	1
Aluno 16	0	REPROVADO	1
Aluno 17	0	REPROVADO	1
Aluno 18	0	REPROVADO	1
Aluno 19	0	REPROVADO	1
Aluno 20	0	REPROVADO	1
Aluno 21	0	REPROVADO	1
Aluno 22	0	REPROVADO	1
Aluno 23	0	REPROVADO	1
Aluno 24	0	REPROVADO	1
Aluno 25	0	REPROVADO	1
Aluno 26	0	REPROVADO	1
Aluno 27	0	REPROVADO	1
Aluno 28	0	REPROVADO	1
Aluno 29	0	REPROVADO	1
Aluno 30	0	REPROVADO	1
Aluno 31	0	REPROVADO	1
Aluno 32	0	REPROVADO	1
Aluno 33	0	REPROVADO	1
Aluno 34	0	REPROVADO	1
Aluno 35	0	REPROVADO	1
Aluno 36	0	REPROVADO	1
Aluno 37	0	REPROVADO	1
Aluno 38	0	REPROVADO	1

Aluno 39	0	REPROVADO	1
Aluno 40	0	REPROVADO	1
Aluno 41	0	REPROVADO	1
Aluno 42	0	REPROVADO	1
Aluno 43	0	REPROVADO	1
Aluno 44	0	REPROVADO	1
Aluno 45	0	REPROVADO	1
Aluno 46	0	REPROVADO	1
Aluno 47	0	REPROVADO	1
Aluno 48	0	REPROVADO	1
Aluno 49	0	REPROVADO	1
Aluno 50	0	REPROVADO	1
Aluno 51	0	REPROVADO	1
Aluno 52	0	REPROVADO	1
Aluno 53	0	REPROVADO	1
Aluno 54	0	REPROVADO	1
Aluno 55	0	REPROVADO	1
Aluno 56	0	REPROVADO	1
Aluno 57	0	REPROVADO	1
Aluno 58	0	REPROVADO	1
Aluno 59	0	REPROVADO	1
Aluno 60	0	REPROVADO	1
Aluno 61	0	REPROVADO	1
Aluno 62	0	REPROVADO	1
Aluno 63	0	REPROVADO	1
Aluno 64	0	REPROVADO	1
Aluno 65	0	REPROVADO	1
Aluno 66	0	REPROVADO	1
Aluno 67	0	REPROVADO	1
Aluno 68	0	REPROVADO	1
Aluno 69	0	REPROVADO	1
Aluno 70	0	REPROVADO	1
Aluno 71	0	REPROVADO	1
Aluno 72	0	REPROVADO	1
Aluno 73	0	REPROVADO	1
Aluno 74	0	REPROVADO	1
Aluno 75	0	REPROVADO	1
Aluno 76	0	REPROVADO	1
Aluno 77	0	REPROVADO	1
Aluno 78	0	REPROVADO	1
Aluno 79	0	REPROVADO	1

Aluno 80	0	REPROVADO	1
Aluno 81	0	REPROVADO	1
Aluno 82	0	REPROVADO	1
Aluno 83	0	REPROVADO	1
Aluno 84	0	REPROVADO	1
Aluno 85	0	REPROVADO	1
Aluno 86	0	REPROVADO	1
Aluno 87	0	REPROVADO	1
Aluno 88	0	REPROVADO	1
Aluno 89	0	REPROVADO	1
Aluno 90	0	REPROVADO	1
Aluno 91	0	REPROVADO	1
Aluno 92	0	REPROVADO	1
Aluno 93	0	REPROVADO	1
Aluno 94	0	REPROVADO	1
Aluno 95	0	REPROVADO	1
Aluno 96	0	REPROVADO	1
Aluno 97	0	REPROVADO	1
Aluno 98	0	REPROVADO	1
Aluno 99	0	REPROVADO	1
Aluno 100	0	REPROVADO	1
Aluno 101	0	REPROVADO	1
Aluno 102	0	REPROVADO	1
Aluno 103	0	REPROVADO	1
Aluno 104	0	REPROVADO	1
Aluno 105	0	REPROVADO	1
Aluno 106	0	REPROVADO	1
Aluno 107	0	REPROVADO	1
Aluno 108	0	REPROVADO	1
Aluno 109	0	REPROVADO	1
Aluno 110	0	REPROVADO	1
Aluno 111	0	REPROVADO	1
Aluno 112	0	REPROVADO	1
Aluno 113	0	REPROVADO	1
Aluno 114	0	REPROVADO	1
Aluno 115	0	REPROVADO	1
Aluno 116	0	REPROVADO	1
Aluno 117	0	REPROVADO	1
Aluno 118	0	REPROVADO	1
Aluno 119	0	REPROVADO	1
Aluno 120	0	REPROVADO	1

Aluno 121	0	REPROVADO	1
Aluno 122	0	REPROVADO	1
Aluno 123	0	REPROVADO	1
Aluno 124	0	REPROVADO	1
Aluno 125	0	REPROVADO	1
Aluno 126	0	REPROVADO	1
Aluno 127	0	REPROVADO	1
Aluno 128	0	REPROVADO	1

Fonte: Próprio autor

Tabela 5 - Grupo de risco (semana 2). Origem: MD-PREAD

Nome	Média_Atividades	DesvDeInterações	prediction(Situação)	confidence(REPROVADO)
Aluno 01	6,173333333	21	REPROVADO	0,571428571
Aluno 02	5,9725	1	REPROVADO	0,571428571
Aluno 03	4,69625	0	REPROVADO	0,571428571
Aluno 04	7,036666667	34	REPROVADO	0,571428571
Aluno 05	5,239090909	21	REPROVADO	0,571428571
Aluno 06	6,178	0	REPROVADO	0,571428571
Aluno 07	6,601666667	28	REPROVADO	0,571428571
Aluno 08	6,831818182	0	REPROVADO	0,571428571
Aluno 09	6,877272727	0	REPROVADO	0,571428571
Aluno 10	7,104166667	12	REPROVADO	0,571428571
Aluno 11	6,809166667	9	REPROVADO	0,571428571
Aluno 12	7,731666667	29	REPROVADO	0,571428571
Aluno 13	7,569166667	27	REPROVADO	0,571428571
Aluno 14	7,405	5	REPROVADO	0,571428571
Aluno 15	0	32	REPROVADO	0,571428571
Aluno 16	0	0	REPROVADO	0,571428571
Aluno 17	8	42	REPROVADO	0,571428571
Aluno 18	0	0	REPROVADO	0,571428571
Aluno 19	0	0	REPROVADO	0,571428571
Aluno 20	0	0	REPROVADO	0,571428571
Aluno 21	0	0	REPROVADO	0,571428571
Aluno 22	0	0	REPROVADO	0,571428571
Aluno 23	0	0	REPROVADO	0,571428571
Aluno 24	0	10	REPROVADO	0,571428571
Aluno 25	0	0	REPROVADO	0,571428571
Aluno 26	0	0	REPROVADO	0,571428571
Aluno 27	0	13	REPROVADO	0,571428571
Aluno 28	8	9	REPROVADO	0,571428571
Aluno 29	0	0	REPROVADO	0,571428571

Aluno 30	0	0	REPROVADO	0,571428571
Aluno 31	0	48	REPROVADO	0,571428571
Aluno 32	0	0	REPROVADO	0,571428571
Aluno 33	0	0	REPROVADO	0,571428571
Aluno 34	0	0	REPROVADO	0,571428571
Aluno 35	8	0	REPROVADO	0,571428571
Aluno 36	8	0	REPROVADO	0,571428571
Aluno 37	0	0	REPROVADO	0,571428571
Aluno 38	8	0	REPROVADO	0,571428571
Aluno 39	0	0	REPROVADO	0,571428571
Aluno 40	0	0	REPROVADO	0,571428571
Aluno 41	0	0	REPROVADO	0,571428571
Aluno 42	8	0	REPROVADO	0,571428571
Aluno 43	8	0	REPROVADO	0,571428571
Aluno 44	8	0	REPROVADO	0,571428571
Aluno 45	0	0	REPROVADO	0,571428571
Aluno 46	8	0	REPROVADO	0,571428571
Aluno 47	7	0	REPROVADO	0,571428571
Aluno 48	7	0	REPROVADO	0,571428571
Aluno 49	7	0	REPROVADO	0,571428571
Aluno 50	0	0	REPROVADO	0,571428571
Aluno 51	0	0	REPROVADO	0,571428571
Aluno 52	8	0	REPROVADO	0,571428571
Aluno 53	0	0	REPROVADO	0,571428571
Aluno 54	0	0	REPROVADO	0,571428571

Fonte: Próprio autor

Tabela 6 - Grupo de risco (semana 3). Origem: MD-PREAD

Nome	Média_Atividades	DesvDeInterações	prediction(Situação)	confidence(REPROVADO)
Aluno 01	0	0	REPROVADO	0,57
Aluno 02	0	0	REPROVADO	0,57
Aluno 03	0	0	REPROVADO	0,57
Aluno 04	8	0	REPROVADO	0,57
Aluno 05	0	0	REPROVADO	0,57
Aluno 06	0	0	REPROVADO	0,57
Aluno 07	0	0	REPROVADO	0,57
Aluno 08	0	0	REPROVADO	0,57
Aluno 09	0	0	REPROVADO	0,57
Aluno 10	0	0	REPROVADO	0,57
Aluno 11	0	0	REPROVADO	0,57
Aluno 12	0	0	REPROVADO	0,57
Aluno 13	0	0	REPROVADO	0,57
Aluno 14	0	0	REPROVADO	0,57

Aluno 15	0	0	REPROVADO	0,57
Aluno 16	0	0	REPROVADO	0,57
Aluno 17	0	0	REPROVADO	0,57
Aluno 18	0	0	REPROVADO	0,57
Aluno 19	0	0	REPROVADO	0,57
Aluno 20	0	0	REPROVADO	0,57
Aluno 21	0	0	REPROVADO	0,57
Aluno 22	8	50	REPROVADO	0,57
Aluno 23	0	23	REPROVADO	0,57
Aluno 24	0	22	REPROVADO	0,57
Aluno 25	0	0	REPROVADO	0,57
Aluno 26	8	27	REPROVADO	0,57
Aluno 27	0	0	REPROVADO	0,57
Aluno 28	0	17	REPROVADO	0,57
Aluno 29	0	2	REPROVADO	0,57
Aluno 30	8	44	REPROVADO	0,57
Aluno 31	0	19	REPROVADO	0,57
Aluno 32	8	0	REPROVADO	0,57
Aluno 33	0	0	REPROVADO	0,57
Aluno 34	8	0	REPROVADO	0,57
Aluno 35	0	0	REPROVADO	0,57
Aluno 36	0	0	REPROVADO	0,57
Aluno 37	0	0	REPROVADO	0,57
Aluno 38	0	0	REPROVADO	0,57
Aluno 39	0	0	REPROVADO	0,57
Aluno 40	8	0	REPROVADO	0,57
Aluno 41	0	0	REPROVADO	0,57
Aluno 42	0	0	REPROVADO	0,57
Aluno 43	0	0	REPROVADO	0,57
Aluno 44	8	0	REPROVADO	0,57
Aluno 45	8	0	REPROVADO	0,57
Aluno 46	0	0	REPROVADO	0,57
Aluno 47	0	0	REPROVADO	0,57
Aluno 48	0	0	REPROVADO	0,57
Aluno 49	0	0	REPROVADO	0,57
Aluno 50	8	0	REPROVADO	0,57
Aluno 51	0	0	REPROVADO	0,57
Aluno 52	7	0	REPROVADO	0,57
Aluno 53	7	0	REPROVADO	0,57
Aluno 54	8	0	REPROVADO	0,57
Aluno 55	8	0	REPROVADO	0,57
Aluno 56	0	0	REPROVADO	0,57
Aluno 57	8	0	REPROVADO	0,57
Aluno 58	8	0	REPROVADO	0,57

Aluno 59	8	0	REPROVADO	0,57
Aluno 60	0	0	REPROVADO	0,57
Aluno 61	8	0	REPROVADO	0,57
Aluno 62	8	0	REPROVADO	0,57
Aluno 63	8	0	REPROVADO	0,57
Aluno 64	7	0	REPROVADO	0,57
Aluno 65	0	0	REPROVADO	0,57
Aluno 66	0	0	REPROVADO	0,57
Aluno 67	8	0	REPROVADO	0,57
Aluno 68	0	0	REPROVADO	0,57
Aluno 69	0	0	REPROVADO	0,57
Aluno 70	0	0	REPROVADO	0,57
Aluno 71	0	0	REPROVADO	0,57
Aluno 72	0	0	REPROVADO	0,57
Aluno 73	0	0	REPROVADO	0,57
Aluno 74	0	0	REPROVADO	0,57
Aluno 75	0	0	REPROVADO	0,57
Aluno 76	0	0	REPROVADO	0,57
Aluno 77	0	0	REPROVADO	0,57
Aluno 78	0	0	REPROVADO	0,57
Aluno 79	0	0	REPROVADO	0,57
Aluno 80	0	0	REPROVADO	0,57
Aluno 81	0	0	REPROVADO	0,57
Aluno 82	0	0	REPROVADO	0,57
Aluno 83	0	0	REPROVADO	0,57
Aluno 84	0	0	REPROVADO	0,57
Aluno 85	0	0	REPROVADO	0,57
Aluno 86	0	0	REPROVADO	0,57
Aluno 87	0	0	REPROVADO	0,57
Aluno 88	0	0	REPROVADO	0,57
Aluno 89	0	0	REPROVADO	0,57
Aluno 90	0	0	REPROVADO	0,57

Fonte: Próprio autor

Tabela 7 - Grupo de risco (semana 4). Origem: MD-PREAD

Nome	Média_Atividades	DesvDeInterações	prediction(Situação)	confidence(REPROVADO)
Aluno 01	0	0	REPROVADO	0,571428571
Aluno 02	0	0	REPROVADO	0,571428571
Aluno 03	0	0	REPROVADO	0,571428571
Aluno 04	0	0	REPROVADO	0,571428571
Aluno 05	0	0	REPROVADO	0,571428571
Aluno 06	0	0	REPROVADO	0,571428571
Aluno 07	0	0	REPROVADO	0,571428571

Aluno 08	0	0	REPROVADO	0,571428571
Aluno 09	0	0	REPROVADO	0,571428571
Aluno 10	0	0	REPROVADO	0,571428571
Aluno 11	0	0	REPROVADO	0,571428571
Aluno 12	0	0	REPROVADO	0,571428571
Aluno 13	0	0	REPROVADO	0,571428571
Aluno 14	0	0	REPROVADO	0,571428571
Aluno 15	0	0	REPROVADO	0,571428571
Aluno 16	0	0	REPROVADO	0,571428571
Aluno 17	0	0	REPROVADO	0,571428571
Aluno 18	0	0	REPROVADO	0,571428571
Aluno 19	0	0	REPROVADO	0,571428571
Aluno 20	0	0	REPROVADO	0,571428571
Aluno 21	0	0	REPROVADO	0,571428571
Aluno 22	0	0	REPROVADO	0,571428571
Aluno 23	0	0	REPROVADO	0,571428571
Aluno 24	0	0	REPROVADO	0,571428571
Aluno 25	0	0	REPROVADO	0,571428571
Aluno 26	0	0	REPROVADO	0,571428571
Aluno 27	0	0	REPROVADO	0,571428571
Aluno 28	0	0	REPROVADO	0,571428571
Aluno 29	0	0	REPROVADO	0,571428571
Aluno 30	0	0	REPROVADO	0,571428571
Aluno 31	0	0	REPROVADO	0,571428571
Aluno 32	0	0	REPROVADO	0,571428571
Aluno 33	0	0	REPROVADO	0,571428571
Aluno 34	0	0	REPROVADO	0,571428571
Aluno 35	0	0	REPROVADO	0,571428571
Aluno 36	0	0	REPROVADO	0,571428571
Aluno 37	0	0	REPROVADO	0,571428571
Aluno 38	0	0	REPROVADO	0,571428571
Aluno 39	0	0	REPROVADO	0,571428571
Aluno 40	0	0	REPROVADO	0,571428571
Aluno 41	0	0	REPROVADO	0,571428571
Aluno 42	0	0	REPROVADO	0,571428571
Aluno 43	0	0	REPROVADO	0,571428571
Aluno 44	0	0	REPROVADO	0,571428571
Aluno 45	0	0	REPROVADO	0,571428571
Aluno 46	0	23	REPROVADO	0,571428571
Aluno 47	0	0	REPROVADO	0,571428571
Aluno 48	8	43	REPROVADO	0,571428571
Aluno 49	0	0	REPROVADO	0,571428571
Aluno 50	0	19	REPROVADO	0,571428571
Aluno 51	0	2	REPROVADO	0,571428571

Aluno 52	0	19	REPROVADO	0,571428571
Aluno 53	0	0	REPROVADO	0,571428571
Aluno 54	0	34	REPROVADO	0,571428571
Aluno 55	0	28	REPROVADO	0,571428571
Aluno 56	0	0	REPROVADO	0,571428571
Aluno 57	0	27	REPROVADO	0,571428571
Aluno 58	0	22	REPROVADO	0,571428571
Aluno 59	0	0	REPROVADO	0,571428571
Aluno 60	8	32	REPROVADO	0,571428571
Aluno 61	0	0	REPROVADO	0,571428571
Aluno 62	0	0	REPROVADO	0,571428571
Aluno 63	0	0	REPROVADO	0,571428571
Aluno 64	0	0	REPROVADO	0,571428571
Aluno 65	8	24	REPROVADO	0,571428571
Aluno 66	8	7	REPROVADO	0,571428571
Aluno 67	8	35	REPROVADO	0,571428571
Aluno 68	0	0	REPROVADO	0,571428571
Aluno 69	0	0	REPROVADO	0,571428571
Aluno 70	0	0	REPROVADO	0,571428571

Fonte: Próprio autor