

**UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA**

**AFFECTIVE-RECOMMENDER: UM
SISTEMA DE RECOMENDAÇÃO SENSÍVEL
AO ESTADO AFETIVO DO USUÁRIO**

DISSERTAÇÃO DE MESTRADO

Adriano Pereira

Santa Maria, RS, Brasil

2012

**AFFECTIVE-RECOMMENDER: UM SISTEMA DE
RECOMENDAÇÃO SENSÍVEL AO ESTADO AFETIVO DO
USUÁRIO**

Adriano Pereira

Dissertação apresentada ao Curso de Mestrado do Programa de Pós-Graduação em Informática (PPGI), Área de Concentração em Computação, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do grau de
Mestre em Ciência da Computação

Orientadora: Prof^a. Dr^a. Iara Augustin

Santa Maria, RS, Brasil

2012

Pereira, Adriano

Affective-Recommender: um sistema de recomendação sensível ao estado afetivo do usuário / por Adriano Pereira. – 2012.

73 f.: il.; 30 cm.

Orientadora: Iara Augustin

Dissertação (Mestrado) - Universidade Federal de Santa Maria, Centro de Tecnologia, Programa de Pós-Graduação em Informática, RS, 2012.

1. Computação Afetiva, Sistema de Recomendação, Sistema de Recomendação Sensível ao Contexto, Computação Ubíqua, *e-learning*.
I. Augustin, Iara. II. Título.

© 2012

Todos os direitos autorais reservados a Adriano Pereira. A reprodução de partes ou do todo deste trabalho só poderá ser feita mediante a citação da fonte.

E-mail: apereira@inf.ufsm.br

**Universidade Federal de Santa Maria
Centro de Tecnologia
Programa de Pós-Graduação em Informática**

A Comissão Examinadora, abaixo assinada,
aprova a Dissertação de Mestrado

**AFFECTIVE-RECOMMENDER: UM SISTEMA DE RECOMENDAÇÃO
SENSÍVEL AO ESTADO AFETIVO DO USUÁRIO**

elaborada por
Adriano Pereira

como requisito parcial para obtenção do grau de
Mestre em Ciência da Computação

COMISSÃO EXAMINADORA:

Iara Augustin, Dr^a.
(Presidente/Orientadora)

Andrea Schwertner Charão, Dr^a. (UFSM)

Patrícia Jaques Maillard, Dr^a. (UNISINOS)

Santa Maria, 21 de Dezembro de 2012.



AGRADECIMENTOS

Agradeço a todos que, de alguma forma, contribuíram na minha trajetória de realização deste trabalho.

Meus agradecimentos a minha mãe Leda e irmã Aline, por sempre me escutarem e acreditarem em minha capacidade, a minha namorada Giséli, por todo apoio, incentivo e ajuda neste trabalho.

Obrigado aos meus amigos de longa data, familiares mais distantes, e aos colegas do NTE e do CPD – UFSM por compartilharem momentos dessa caminhada. Agradeço, também, à professora Iara, pela orientação do trabalho, em uma nova e área, com novos desafios. Meu muito obrigado às professoras Andrea Charão e Patrícia Jaques, por aceitarem participar de minha banca de defesa, pelas considerações e sugestões; sem esquecer das professoras Liziany Muller e Cláudia Barin, que aceitaram o desafio de aplicar o sistema em suas turmas.

Enfim, a todos que participaram desta minha conquista, muito obrigado.

RESUMO

Dissertação de Mestrado
Programa de Pós-Graduação em Informática
Universidade Federal de Santa Maria

AFFECTIVE-RECOMMENDER: UM SISTEMA DE RECOMENDAÇÃO SENSÍVEL AO ESTADO AFETIVO DO USUÁRIO

AUTOR: ADRIANO PEREIRA

ORIENTADORA: IARA AUGUSTIN

Local da Defesa e Data: Santa Maria, 21 de Dezembro de 2012.

Sistemas de Computação Pervasiva buscam melhorar a interação humano-computador através do uso de variáveis da situação do usuário que definem o contexto. A explosão da Internet e das tecnologias de informação e comunicação torna crescente a quantidade de itens disponíveis para a escolha, impondo custo para o usuário no processo de tomada de decisão. A Computação Afetiva tem entre seus objetivos identificar o estado emocional/afetivo do usuário durante uma interação computacional, para automaticamente responder a ele. Já Sistemas de Recomendação auxiliam a tomada de decisão, selecionando e sugerindo itens em situações onde há grandes volumes de informação, tradicionalmente, utilizando as preferências dos usuários para a seleção e sugestão. Esse processo pode ser melhorado com o uso do contexto (físico, ambiental, social), surgindo os Sistemas de Recomendação Sensíveis ao Contexto. Tendo em vista a importância das emoções em nossas vidas, e a possibilidade de tratamento delas com a Computação Afetiva, este trabalho utiliza o contexto afetivo do usuário como variável da situação, durante o processo de recomendação, propondo o *Affective-Recommender* – um sistema de recomendação que faz uso do estado afetivo do usuário para selecionar e sugerir itens. O sistema foi modelado a partir de quatro componentes: (i) detector, que identifica o estado afetivo, utilizando o modelo multidimensional Pleasure, Arousal e Dominance e o instrumento Self-Assessment Manikin, solicitando que o usuário informe como se sente; (ii) recomendador, que escolhe e sugere itens, utilizando uma abordagem baseada em filtragem colaborativa, em que a preferência de um usuário para um item é vista como sua reação – estado afetivo detectado após o contato – ao item; (iii) aplicação, que interage com o usuário, exibe os itens de provável maior interesse definidos pelo recomendador, e solicita que o estado seja identificado, sempre que necessário; e (iv) base de dados, que armazena os itens disponíveis para serem sugeridos e as preferências de cada usuário. Como um caso de uso e prova de conceito, o *Affective-Recommender* é empregado em um cenário de *e-learning*, devido à importância da personalização, obtida com a recomendação, e das emoções no processo de aprendizagem. O sistema foi implementado utilizando-se como base o AVEA Moodle. Para expor o funcionamento, estruturou-se um cenário de uso, simulando-se o processo de recomendação. Para verificar a aplicabilidade real do sistema, ele foi empregado em três turmas de cursos de graduação da UFSM, sendo analisados dados de acesso e aplicado um questionário para identificar as impressões dos alunos quanto a informar como se sentem e receber recomendações. Como resultados, percebeu-se que os alunos conseguiram informar seus estados afetivos, e que houve uma mudança em neste estado com base no item acessado, embora não tenham vislumbrado melhorias com as recomendações, em virtude da pequena quantidade de dados disponível para processamento e do curto tempo de aplicação.

Palavras-chave: Computação Afetiva, Sistema de Recomendação, Sistema de Recomendação Sensível ao Contexto, Computação Ubíqua, *e-learning*.

ABSTRACT

Master's Dissertation
Post-Graduate Program in Informatics
Federal University of Santa Maria

AFFECTIVE-RECOMMENDER: A RECOMMENDATION SYSTEM AWARE TO USER'S AFFECTIVE STATE

AUTHOR: ADRIANO PEREIRA

ADVISOR: IARA AUGUSTIN

Defense Place and Date: Santa Maria, December 21st, 2012.

Pervasive computing systems aim to improve human-computer interaction, using users' situation variables that define context. The boom of Internet makes growing available items to choose, giving cost in made decision process. Affective Computing has in its goals to identify user's affective/emotional state in a computing interaction, in order to respond to it automatically. Recommendation systems help made decision selecting and suggesting items in scenarios where there are huge information volume, using, traditionally, users' preferences data. This process could be enhanced using context information (as physical, environmental or social), rising the Context-Aware Recommendation Systems. Due to emotions importance in our lives, that could be treated with Affective Computing, this work uses affective context as context variable, in recommendation process, proposing the *Affective-Recommender* – a recommendation system that uses user's affective state to select and to suggest items. The system's model has four components: (i) detector, that identifies affective-state, using the multidimensional Pleasure, Arousal and Dominance model, and Self-Assessment Manikin instrument, that asks user to inform how he/she feels; (ii) recommender, that selects and suggests items, using a collaborative-filtering based approach, in which user's preference to an item is his/her affective reaction to it – as the affective state detected after access; (iii) application, which interacts with user, shows probable most interesting items defined by recommender, and requests affect identification when it is necessary; and (iv) data base, that stores available items and users' preferences. As a use case, Affective-Recommender is used in a e-learning scenario, due to personalization – obtained with recommendation – and emotion importances in learning process. The system was implemented over Moodle LMS. To expose its operation, a use scenario was organized, simulating recommendation process. In order to check system applicability, with students opinion about to inform how he/she feels and to receive suggestions, it was applied in three UFSM graduation courses classes, and then it were analyzed data access and the answers to a sent questionnaire. As results, it was perceived that students were able to inform how they feel, and that occurred changes in their affective state, based on accessed item, although they don't see improvements with the recommendation, due to small data available to process and show time of application.

Keywords: Affective Computing, Recommendation System, Context-Aware Recommendation System, Ubiquitous Computing, e-learning.

LISTA DE FIGURAS

Figura 3.1 – Arquitetura do sistema	27
Figura 3.2 – SAM utilizado para definir os valores de PAD. De cima para baixo, escalas de <i>pleasure</i> , <i>arousal</i> e <i>dominance</i> (BRADLEY; LANG, 1994)	28
Figura 4.1 – AffectButton - De cima para baixo, de esquerda para a direita, faces geradas para os estados: Feliz, Com medo, Surpreso, Triste, Bravo, Relaxado, Contente, Frustrado (BROEKENS; BRINKMAN, 2009)	35
Figura 4.2 – Modelo Entidade-Relacionamento de Tabelas para o Caso de Uso	39
Figura 4.3 – AffectButton dentro do Moodle	40
Figura 4.4 – Curso do Moodle estruturado em semanas	40
Figura 4.5 – Curso do Moodle estruturado em tópicos	41
Figura 4.6 – Exemplo de Recomendação de Material Didático no Moodle	43
Figura 5.1 – Cenário de Uso - Materiais Disponíveis	47
Figura 5.2 – Cenário de Uso - Recomendações para Usuário 1	49
Figura 5.3 – Cenário de Uso - Recomendações para Usuário 4	49
Figura A.1 – Fluxo do Sistema	65
Figura D.1 – Ocorrências de Cada Estado Afetivo - <i>Disciplina 1</i> : Educação em Ciências Agrárias Mediada por Tecnologia da Comunicação e Informação, do Curso de Medicina Veterinária	70
Figura D.2 – Ocorrências de Cada Estado Afetivo - <i>Disciplina 2</i> : Educação em Ciências Agrárias Mediada por Tecnologia da Comunicação e Informação, do Curso Superior de Tecnologia em Alimentos	70
Figura D.3 – Ocorrências de Cada Estado Afetivo - <i>Disciplina 3</i> : Informática Aplicada a Processos Químicos, do Curso Superior de Tecnologia em Processos Químicos.	71
Figura D.4 – Ocorrências de Cada Estado Afetivo - Total	71

LISTA DE TABELAS

Tabela 3.1 – Possíveis Estados Afetivos.....	31
Tabela 5.1 – Reações de cada usuário aos itens	46
Tabela 5.2 – Reações de cada usuário aos itens	47
Tabela 5.3 – Reações de cada usuário aos itens, em PAD.....	48
Tabela 5.4 – Respostas Formulário - Geral	52
Tabela 5.5 – Número de Detecções por Estado Afetivo e Disciplina	52
Tabela 5.6 – Número de Detecções de Estado Afetivo por Aluno	53
Tabela 5.7 – Estados Diferentes Indicados por Aluno	53
Tabela 5.8 – Porcentagem de Ocorrências de cada Estado Afetivo	53
Tabela 5.9 – Número de Reações por Estado Afetivo - Total	54
Tabela 5.10 – Características das Reações	54
Tabela C.1 – Respostas Formulário - <i>Disciplina 1</i> : Educação em Ciências Agrárias Mediada por Tecnologia da Comunicação e Informação, do Curso de Medicina Veterinária	69
Tabela C.2 – Respostas Formulário - <i>Disciplina 2</i> : Educação em Ciências Agrárias Mediada por Tecnologia da Comunicação e Informação, do Curso Superior de Tecnologia em Alimentos.....	69
Tabela C.3 – Respostas Formulário - <i>Disciplina 3</i> : Informática Aplicada a Processos Químicos, do Curso Superior de Tecnologia em Processos Químicos.....	69
Tabela E.1 – Número de Reações por Estado Afetivo - <i>Disciplina 1</i> : Educação em Ciências Agrárias Mediada por TCI, do Curso de Medicina Veterinária	72
Tabela E.2 – Número de Reações por Estado Afetivo - <i>Disciplina 2</i> : Educação em Ciências Agrárias Mediada por TIC, do Curso Superior de Tecnologia em Alimentos	72
Tabela E.3 – Número de Reações por Estado Afetivo - <i>Disciplina 3</i> : Informática Aplicada a Processos Químicos, do Curso Superior de Tecnologia em Processos Químicos.	73

LISTA DE ABREVIATURAS E SIGLAS

AVEA Ambiente Virtual de Ensino e Aprendizagem

PAD *Pleasure, Arousal e Dominance*

SAM *Self-Assessment Manikin*

UFSM Universidade Federal de Santa Maria

SUMÁRIO

1 INTRODUÇÃO	12
1.1 Objetivos	13
1.2 Justificativa	14
1.3 Apresentação do Texto	15
2 REVISÃO DA LITERATURA	17
2.1 Computação Ubíqua	17
2.2 Computação Afetiva	17
2.3 Educação Mediada por Dispositivos Computacionais	20
2.3.1 Ambiente Virtual de Ensino-Aprendizagem	20
2.3.2 <i>Ubiquitous Learning</i>	21
2.3.3 O Estado Afetivo na Educação	21
2.4 Sistemas de Recomendação	22
2.4.1 Métodos Baseados em Conteúdo	22
2.4.2 Métodos Baseados em Filtragem Colaborativa	23
2.4.3 Sistemas de Recomendação Sensíveis ao Contexto	23
2.4.4 Sistemas de Recomendação e <i>e-learning</i>	24
3 AFFECTIVE-RECOMMENDER - SISTEMA DE RECOMENDAÇÃO SENSÍVEL AO ESTADO AFETIVO DO USUÁRIO	25
3.1 Requisitos	25
3.2 Arquitetura do Sistema	26
3.2.1 O Detector de Estado Afetivo	26
3.2.2 O Recomendador	29
3.2.3 A Aplicação	32
3.2.4 A Base de Dados	33
3.3 Fluxo de Funcionamento	33
4 AFFECTIVE-RECOMMENDER : CASO DE USO	34
4.1 Arquitetura do Sistema	34
4.1.1 O Detector de Estado Afetivo	34
4.1.2 O Recomendador	35
4.1.3 A Aplicação	36
4.1.4 A Base de Dados	36
4.2 Implementação	37
5 DISCUSSÃO E RESULTADOS	44
5.1 Trabalhos Relacionados	44
5.2 Cenário de Uso	46
5.3 Estudo de Caso	50
5.3.1 Dados das Disciplinas	50
5.3.2 Discussão dos resultados	51
6 CONCLUSÃO	57
REFERÊNCIAS	59
APÊNDICES	64

1 INTRODUÇÃO

Trata-se como *Computação Ubíqua* a fuga da computação das tradicionais estações de trabalho, passando a habitar objetos triviais. Dessa forma, humanos convivem com os equipamentos computacionais, ao invés de apenas interagirem com eles (ARAÚJO, 2003). Weiser (1991), pioneiro na área, enfatiza a invisibilidade da computação, em ambientes ubíquos, centralizando-se nas atividades no usuário (AUGUSTIN, 2004). Um aspecto chave da invisibilidade (não consciência do usuário) é a sensibilidade ao contexto (*context-awareness*). *Contexto* é qualquer informação utilizada para caracterizar a situação de uma entidade relevante para a interação entre usuário e aplicação (ABOWD et al., 1999), sendo tópico de grande interesse em Computação Ubíqua atualmente (ARAÚJO, 2003).

Com a explosão das tecnologias de informação e comunicação, grandes quantidades de dados tornam-se disponíveis para processamento. A tomada de decisão para escolha de um conteúdo em especial torna-se um problema com este volume de informações disponível. Sistemas de recomendação são ferramentas de busca de informação, que lidam com o problema do excesso de dados disponíveis (RICCI, 2010). Eles tornam acessíveis grandes coleções de produtos e serviços, auxiliando os usuários através da sugestão de conteúdos considerados particularmente interessantes (HUSSEIN, 2009). O interesse em sistemas de recomendação está relacionado à grande quantidade de aplicações práticas, baseadas no auxílio a usuários com recomendações personalizadas, e no tratamento de grandes volumes de informação (ADOMAVICIUS; TUZHILIN, 2005).

Sabe-se que o interesse de um usuário por determinado item ou serviço é relacionado, em geral, com a situação específica em que ele se encontra, ou seja, com o contexto no qual ele está inserido. Dessa forma, durante o processo de geração da recomendação, podem-se utilizar as variáveis com informações do ambiente (contexto) disponíveis, além do perfil do usuário, surgindo, assim, os sistemas de recomendação sensíveis ao contexto (HUSSEIN, 2009). Quanto melhores forem as informações acerca do usuário e ambiente onde se encontra, mais precisos serão os itens recomendados (CAZELLA; NUNES; REATEGUI, 2010). Neste sentido, sistemas de recomendação sensíveis ao contexto fazem uso de informações disponíveis no ambiente (capturadas automaticamente) e relevantes ao usuário, buscando apurar a escolha do item a ser sugerido.

Por outro lado, Emoções tem participação importante em nossas vidas, influenciando

o modo de pensar, agir e utilizar produtos e tecnologias (BROEKENS; BRINKMAN, 2009). Neste sentido, a *Computação Afetiva* busca estreitar as relações entre emoções humanas e aplicações computacionais, através de sistemas capazes de reconhecer e responder aos estados afetivos do usuário, como humor e emoção (CALVO; D’MELLO, 2010). Define-se como Computação Afetiva aquela computação que está *relacionada, é gerada, ou influencia* emoções (PICARD, 1995). Interfaces relacionadas com estados afetivos vem sendo desenvolvidas em um domínio que inclui jogos, saúde mental e tecnologias educacionais (CALVO; D’MELLO, 2010).

Usuários transmitem suas decisões juntamente com emoções, sendo interessante detectar as ligações entre as ações dos usuários e este seu estado afetivo. Em sistemas de recomendação, várias técnicas de modelagem do usuário vem sendo criadas e estudadas, havendo, porém, pouca atenção em analisar informações de emoção neste processo (GONZALEZ et al., 2007). Sistemas de Computação Afetiva buscam reconhecer o estado afetivo do usuário, para responder a ele, automaticamente, durante a interação com os dispositivos computacionais, objetivando aumentar a qualidade da interação (CALVO; D’MELLO, 2010). Assim, a emoção do usuário, enquanto estado afetivo, pode ser vista como uma variável do contexto, a ser utilizada no processo de recomendação.

1.1 Objetivos

Este trabalho tem como objetivo propor um sistema de recomendação sensível ao contexto, que utilize o estado afetivo – emoção – do usuário no processo de seleção de itens a serem sugeridos. O sistema foi chamado *Affective-Recommender*. A emoção pode ser definida como um episódio ocasionado por um evento, externo ou interno, com certa duração, e relativa facilidade em ser identificada (SCHERER, 2000). Para demonstrar sua viabilidade, como uma prova de conceito, definiu-se, também como objetivo do trabalho, produzir um caso de uso do sistema. Neste sentido, optou-se por demonstrá-lo em um contexto de educação mediada por dispositivos computacionais (*e-learning*), em virtude da importância das emoções e da personalização no processo de aprendizagem.

Especificamente, para atingir os objetivos, foram seguidas as etapas listadas abaixo.

1. Realização de uma investigação acerca de sistemas de recomendação, em especial, sensíveis ao contexto, e sobre técnicas relacionadas com a Computação Afetiva.

2. Definição de um conjunto de requisitos que o sistema deve satisfazer.
3. Estruturação de uma arquitetura do sistema, detalhando módulos e funcionamento.
4. Definição de um modelo de estado afetivo, para representar o estado de cada usuário.
5. Definição de um método de detecção de estado, com base no modelo.
6. Proposição de um algoritmo de recomendação, que faça uso do estado afetivo do usuário representado no modelo escolhido.
7. Construção de um caso de uso, em um cenário de *e-learning*, ilustrando o comportamento da arquitetura neste ambiente como prova de conceito, validando o modelo de arquitetura e funcionamento do sistema proposto.
8. Avaliação dos resultados do caso de uso, através de implementação do caso; exposição de seu funcionamento em um ambiente simulado; e aplicação como apoio a turmas de cursos de graduação, para posterior análise de dados de acesso e opinião dos estudantes envolvidos.

1.2 Justificativa

Muitos trabalhos vem sendo conduzidos sobre sistemas de recomendação, tanto na academia quanto na indústria, devido à sua aplicabilidade prática. Aplicações de recomendação são ferramentas capazes de lidar com grandes volumes de dados (ADOMAVICIUS; TUZHILIN, 2005), cenário cada vez mais comum com a explosão da informação e mobilidade.

Os sistemas de recomendação sensíveis ao contexto agem proativamente, utilizando o contexto (ambiente) da interação com o usuário para a sugestão de itens (BURIANO et al., 2006). Muitas pesquisas nesta área são realizadas, pois esses sistemas buscam aumentar a precisão da recomendação, ao utilizarem variáveis do contexto (ADOMAVICIUS; TUZHILIN, 2011).

Sabe-se que as emoções possuem um importante papel na vida humana, estando envolvidas no processo de tomada de decisão (PICARD et al., 2004). A Computação Afetiva busca relacioná-las com interações computacionais, para melhorar esta interação. Propõe-se o uso do estado afetivo do usuário como variável do contexto, devido à essa importância para a tomada de decisão, estando envolvida no processo de escolha por um ou outro item.

Emoções estão inseridas no processo de aprendizagem, de modo que o processo pode ser abandonado em virtude de sentimentos negativos. A interação com aplicações computacionais que possam reconhecer emoções dos usuários é beneficiada no campo do ensino. Ambientes virtuais de aprendizagem são aplicações que podem se beneficiar se puderem reconhecer a emoção do aluno (PICARD, 1997).

A personalização é uma importante característica em sistemas de *e-learning*, em virtude das diferentes experiências carregadas pelos alunos adultos, principal foco deste tipo de modalidade de ensino (KERKIRI; MANITSARIS; MAVRIDOU, 2007). Todavia, a maior parte dos sistemas voltados ao *e-learning* não são personalizados, em especial, com relação à adaptação da estrutura do curso em função do aluno (KHRIBI; JEMNI; NASRAOUI, 2009). Neste contexto, sistemas de recomendação auxiliam alunos a tomarem decisões mesmo sem ter conhecimento do conteúdo das opções disponíveis (TAN; GUO; LI, 2008). Desta maneira, sistemas de recomendação podem ser utilizados para personalizar ambientes de *e-learning*, sugerindo materiais de provável interesse do aluno, levando em consideração, no processo de recomendação, seu estado afetivo. Por isso, essa área de aplicação foi escolhida para a prova de conceito do Affective-Recommender, com a estruturação e avaliação de um caso de uso.

1.3 Apresentação do Texto

O texto da dissertação está organizado em capítulos cuja sequência é descrita a seguir. O capítulo 2 faz uma revisão da literatura, discutindo os principais tópicos relacionados com Computação Ubíqua, Computação Afetiva, *e-learning* e sistemas de recomendação, abordando métodos baseados em conteúdo e filtragem colaborativa, sistemas de recomendação sensíveis ao contexto e a relação entre estes tópicos.

O capítulo 3 descreve o Affective-Recommender, sistema de recomendação sensível ao estado afetivo do usuário. São expostos os requisitos levantados para a modelagem do sistema; sua arquitetura, com detector de estado afetivo, recomendador, aplicação e base de dados; além do fluxo de funcionamento previsto para ele.

O capítulo 4 expõe o caso de uso do Affective-Recommender em *e-learning*, informando como a arquitetura do sistema deve se comportar nesse contexto, juntamente com a implementação do sistema com base no Ambiente Virtual de Ensino-Aprendizagem Moodle.

Já o capítulo 5 traz os resultados e discussão do trabalho, através de uma revisão de trabalhos relacionados, juntamente com um cenário simulado do Affective-Recommender, de-

envolvido a partir da implementação com o Moodle. Além disso, traz detalhes sobre o teste desta implementação, aplicado em três turmas de cursos de graduação da UFSM, como ferramenta de apoio ao ensino, juntamente com dados levantados a partir de questionário aplicado aos alunos, e análise de informações de acesso.

Por fim, o capítulo 6 finaliza o trabalho, com a conclusão e os próximos passos da pesquisa.

2 REVISÃO DA LITERATURA

Este capítulo aborda tópicos relacionados ao trabalho, realizando uma revisão de conceitos difundidos na literatura. São abordados a Computação Ubíqua e Computação Afetiva, envolvendo modos de representação e detecção de estados relativos à emoção; o ensino mediado por dispositivos computacionais (*e-learning*); e sistemas de recomendação, incluindo os cientistas ao contexto. Também são expostas algumas relações acerca dos assuntos abordados.

2.1 Computação Ubíqua

Segundo Weiser (1991), pioneiro na área, a Computação Ubíqua ou Pervasiva busca integrar a computação à vida do usuário, centralizando as tarefas nele. A visão de Weiser enfatiza a invisibilidade da computação, onde as aplicações devem ser capazes de ajustarem-se às necessidades do usuário, tornando-se a tecnologia que desaparece (AUGUSTIN, 2004). A convergência de dispositivos digitais leva ao conceito de ubiquidade, buscando aumentar a capacidade humana através da coordenação entre dispositivos móveis e fixos (ARAUJO, 2003).

Dentre os tópicos de pesquisa em Computação Ubíqua, tem-se o tratamento do contexto (ARAUJO, 2003). Considera-se como *contexto* qualquer informação que pode ser utilizada para caracterizar a situação de uma entidade relevante para a interação entre usuário e aplicação (ABOWD et al., 1999). Sistemas computacionais sensíveis ao contexto são capazes de examinar o ambiente computacional ao qual estão inseridos e reagir a mudanças ocorridas nele (SCHILIT; ADAMS; WANT, 1994). Segundo Augustin (2004), software adaptativo é “aquele que usa as informações disponíveis sobre o ambiente para melhorar seu comportamento no tempo” (AUGUSTIN, 2004).

Como variável da situação do usuário, pode-se citar a sua emoção. O tratamento deste tipo de informação, em um ambiente computacional, é realizado através do campo de pesquisa em Computação Afetiva.

2.2 Computação Afetiva

Picard (1995) define o campo da Computação Afetiva como a computação que está *relacionada*, *é gerada* ou *influencia* emoções em humanos, de forma a assisti-los, provendo habilidades para tomar decisões. Isto é possível devido à importância das emoções nos campos

da percepção e cognição. Dentre os domínios de aplicações da computação afetiva tem-se: aprendizagem assistida por computador, recuperação de informação, artes, entretenimento e cuidados de saúde (PICARD, 1995).

Através de modelos, pode-se reconhecer emoções humanas. A modelagem afetiva do usuário é a capacidade de um sistema modelar o estado afetivo dele (ELLIOTT; RICKEL; LESTER, 1999).

A Computação Afetiva tem entre seus objetivos construir sistemas capazes de reconhecer os estados afetivos do usuário, respondendo a eles automaticamente. É funcionalidade básica, na Computação Afetiva, o reconhecimento e a resposta automáticos aos estados afetivos do usuário, durante a interação com um computador, aumentando, assim, a qualidade dessa interação (CALVO; D'MELLO, 2010).

Aplicações de Computação Afetiva estão divididas entre (i) aquelas que detectam a emoção do usuário; (ii) sistemas que expressam, de alguma forma, algo que o usuário possa identificar como uma emoção; e (iii) sistemas que “sentem” uma emoção (PICARD, 1997) apud (CALVO; D'MELLO, 2010).

De acordo com Calvo e d’Mello (2010), emoções podem ser definidas a partir de seis perspectivas: como expressões, como incorporações, através de abordagens cognitivas, como construções sociais, através de neurociência e como construções psicológicas. A seguir são descritas estas perspectivas (CALVO; D'MELLO, 2010).

- Como expressões. As emoções do usuário são vistas como expressões, em especial, da face. Utiliza-se como premissa o fato de que há expressões faciais emotivas universalmente reconhecíveis. Nesta abordagem, sistemas baseados em câmera são os mais comumente utilizados para a detecção. Como vantagens, citam-se o fato de serem não intrusivos e de não requererem equipamentos com preço elevado. Além do uso de expressão facial, fazem parte dessa perspectiva o uso de canais como a voz, linguagem corporal, postura e gestos.
- Como incorporações. Nessa perspectiva, utilizam-se fatores fisiológicos, verificando as manifestações corporais que acompanham determinadas emoções. Para detecção são utilizados equipamentos, em especial sensores, que recuperam os sinais fisiológicos do usuário. Apesar da disponibilidade de recuperação de grandes quantidades desses sinais, esta abordagem tende a ser intrusiva, em virtude do uso de equipamentos não convencionais.

- Abordagens cognitivas. Nessa perspectiva, acredita-se que experiências emotivas estão relacionadas diretamente a algum evento ou objeto, baseando-se nas experiências e objetivos do usuário em questão. A teoria proposta por Ortony, Clore e Collins (OCC) indica que emoções são reações a avaliações situacionais de eventos, atores e objetos (ORTONY; CLORE; COLLINS, 1988a), criando um modelo de emoção computacionalmente tratável. Modelos computacionais derivados de teorias avaliativas podem ser utilizados em pesquisas de psicologia e inteligência artificial.
- Como construções sociais. Para tratar emoções como construções sociais torna-se necessário um nível de análise social para compreendê-las, dando importância para os processos sociais como forma de explicação dos fenômenos emocionais.
- Neurociência. Nesta abordagem, verificam-se as emoções através do estudo dos processos neurológicos correlatos a elas. Envolvem-se métodos de imageamento cerebral, estudo de lesões, genética e fisiologia elétrica.
- Construção psicológica e núcleo afetivo. Perspectiva inspirada no trabalho de Russell, menciona que existem diferentes teorias sobre emoções, pois cada uma trata de algo diferente. Russel (2003) traz um *framework*, onde as teorias emocionais são centradas em um núcleo afetivo e valoriza-se a importância do contexto em relação a episódios emocionais (RUSSELL, 2003).

A detecção do estado afetivo do usuário é crucial em sistemas que dependam deste estado. A detecção não precisa ser perfeita, mas deve chegar o mais próximo possível da realidade (CALVO; D'MELLO, 2010). Picard (1995) propõe a busca por funções observáveis que correspondam a determinados estados afetivos (PICARD, 1995).

Em Computação Afetiva, o problema de reconhecimento e modelagem de emoções é simplificado através do uso de conjuntos pequenos e discretos de emoções. Ainda, pode-se assumir emoções como variáveis contínuas, considerando-se as categorias discretas como regiões do espaço contínuo (PICARD, 1995).

O estado afetivo do usuário pode ser detectado de forma *explícita* ou *implícita*. Na forma implícita, identifica-se o estado afetivo a partir da análise de condições ou comportamento do usuário. Por outro lado, os métodos explícitos pedem que o usuário informe variáveis, a partir das quais seu estado será identificado (BROEKENS; BRINKMAN, 2009).

Calvo e d’Mello (2010) descrevem seis modalidades de detecção afetiva, além de uma sétima, composta pelo uso de mais de uma delas. São elas: (i) expressões faciais, englobando a maior parte das pesquisas em detecção de estados afetivos, identifica o estado do usuário através da face; (ii) voz, através de análises sobre *o que* é dito e *como* foi dito; (iii) linguagem corporal e posturas verificando como o usuário está postado e seus movimentos; (iv) fisiologia, utilizando-se fatores fisiológicos e técnicas de aprendizagem, encontrando padrões referentes a diferentes emoções; (v) imageamento cerebral, através do mapeamento das atividades de circuitos neurais; (vi) texto, analisando linguagem escrita e transcrições de comunicação oral; e (vii) várias modalidades, combinando mais de uma modalidade. Além dessas, pode-se fazer uso de dados comportamentais do usuário, em relação ao sistema, como forma de detecção da emoção, a partir da interação com os meios tradicionais, como teclado e mouse, em particular, em contextos bem definidos, como em aprendizagem através de computador (MARTINHO; MACHADO; PAIVA, 2000).

2.3 Educação Mediada por Dispositivos Computacionais

Tecnologias de informação e comunicação vem sendo inseridas no processo de construção de conhecimento, modelando um novo paradigma para os educadores (LONGHI et al., 2007). Estilos tradicionais de aprendizagem, limitados em tempo e espaço, vem sendo substituído por atividades realizadas na Internet (LIU; SHIH, 2007). Trata-se por educação mediada por dispositivos computacionais (*e-learning*) a entrega de instruções através destes equipamentos, incluindo conteúdos relevantes para o objetivo do aprendizado, métodos instrucionais e materiais multimídia.

Cursos em meio eletrônico são formados tanto por informações, em seus conteúdos, quanto por técnicas de ensino, para auxiliar os alunos no processo de aprendizagem. São desenvolvidos em meio digital, utilizando materiais escritos, ilustrações, animações e vídeos (CLARK; MAYER, 2011).

2.3.1 Ambiente Virtual de Ensino-Aprendizagem

De acordo com CHENG; SAFONT; BASU (2010), ambientes virtuais de aprendizagem (*Learning Management Systems*) são “softwares construídos para suportar ensino e aprendizagem em um ambiente educacional”. Estes são utilizados para planejar, gerenciar e entregar

objetos de aprendizagem organizados, incluindo aulas virtuais com suporte de instrutores. Em geral, Ambientes Virtuais de Aprendizagem são sistemas baseados na Web, e contem tanto ferramentas administrativas para gerenciamento dos cursos, professores e estudantes, quanto ferramentas voltadas a aprendizagem, através do acesso do aluno aos conteúdos e trabalhos disponíveis (CHENG; SAFONT; BASU, 2010).

2.3.2 *Ubiquitous Learning*

Com a evolução e o crescimento das tecnologias educacionais, tem-se um envolvimento delas em cenários de Computação Ubíqua, surgindo o *Ubiquitous Learning (u-learning)*. Nesse aspecto, o estudante está imerso em um espaço de dispositivos, interagindo com eles. Educação adaptativa busca alterar as metodologias de ensino com base nos diferentes estilos de aprendizagem dos estudantes. Baseia-se na ideia que um método individualizado pode ajudar os estudantes a aprenderem de maneira mais rápida e efetiva, melhorando o entendimento. Educação adaptativa provê aos estudantes conhecimento específico e personalizado quando e onde ele deseja. Através de ambientes de *u-learning*, estudantes podem interagir de maneira flexível, em uma aprendizagem adaptada às suas necessidades e interesses (JONES; JO, 2004).

2.3.3 O Estado Afetivo na Educação

Sabe-se que as emoções estão inseridas no processo de aprendizagem. Este processo pode ser prejudicado em razão de sentimentos negativos, como frustração. As interações entre humano e computador são beneficiadas se este for capaz de detectar as emoções daquele, principalmente em ambientes de ensino. Um bom professor é capaz de identificar o estado afetivo dos seus estudantes, respondendo a ele de forma a evitar uma quebra no processo de ensino-aprendizagem (PICARD, 1997).

As emoções afetam diretamente a atenção, a memória e a tomada de decisão, elementos críticos no processo de aprendizagem. Emoções tem um papel importante neste processo, particularmente, em *e/u-learning*. Diferentes emoções são percebidas no processo de ensino online, devido a diferentes fatores. Frustração, medo, ansiedade, apreensão, timidez, entusiasmo e orgulho são alguns exemplos destas emoções (O'REGAN, 2003).

A inteligência e a afetividade estão em constante interação. Os elementos afetivos estão inseridos nos mecanismos cognitivos. Experiências como prazer, decepção, cansaço e esforço são percebidas no desenvolver de um trabalho, enquanto que êxito ou fracasso podem ser viven-

ciados ao seu final. A afetividade pode causar comportamentos, interferindo no funcionamento da inteligência, causando aceleração ou atraso no desenvolvimento intelectual (PIAGET, 2005).

2.4 Sistemas de Recomendação

Sistemas de recomendação auxiliam usuários em cenários com grandes quantidades de dados, provendo sugestões personalizadas de conteúdos e serviços (ADOMAVICIUS; TUZHILIN, 2005). São ferramentas selecionadoras de informação e tomadoras de decisão, capazes de realizarem recomendações personalizadas, com base nas necessidades e preferências do usuário, a cada requisição realizada (RICCI, 2010). Sistemas de recomendação utilizam técnicas de descoberta do conhecimento para sugerir itens de forma personalizada (SARWAR et al., 2001).

O problema de recomendação pode ser visto como o problema de avaliar itens ainda não avaliados por um usuário, classificando-os para, então, sugerir os que obtiverem a melhor pontuação. Esta avaliação pode ser feita através de *heurísticas* ou, ainda, *estimativas* (ADOMAVICIUS; TUZHILIN, 2005).

Estes sistemas podem ser divididos, com base em como a recomendação é feita, em: (i) baseados em *conteúdo* (*content-based*), onde se busca recomendar itens semelhantes àqueles que o usuário teve interesse no passado; (ii) baseados em *filtragem colaborativa* (*collaborative filtering*), através da identificação de usuários com preferências similares ao atual, recomendando itens que foram de interesse daqueles usuários semelhantes; e (iii) *abordagem híbrida*, resultante da combinação dos outros dois métodos (ADOMAVICIUS; TUZHILIN, 2005) (BALABANOVIC; SHOHAM, 1997).

2.4.1 Métodos Baseados em Conteúdo

Métodos baseados no conteúdo calculam a utilidade de um item s para um usuário c com base nas utilidades de itens “similares” a s para o mesmo usuário c . O cálculo da similaridade entre itens é realizado a partir do uso de um conjunto de atributos que caracterizam cada item (ADOMAVICIUS; TUZHILIN, 2005). Estes métodos tem origem no campo da recuperação de informação. Métodos “puros” de recomendação baseada em conteúdo são aqueles em que recomendações são baseadas apenas no perfil do usuário, construído pela análise do conteúdo avaliado por ele (BALABANOVIC; SHOHAM, 1997).

São problemas desta técnica (i) a análise limitada de conteúdo, visto que se está limitado

às características explicitamente associadas aos objetos recomendados; (ii) excesso de especificação, em casos onde o sistema recomenda apenas itens com alta similaridade, serão sempre recomendados itens altamente parecidos, não havendo uma diversificação; e (iii) presença de novos usuários, os quais deverão avaliar determinado número de itens antes de receber uma recomendação útil (ADOMAVICIUS; TUZHILIN, 2005).

2.4.2 Métodos Baseados em Filtragem Colaborativa

Técnicas de filtragem colaborativa recomendam itens bem avaliados por outros usuários, “similares” ao atual (BALABANOVIC; SHOHAM, 1997). O cálculo de utilidade de um item s em relação a um usuário c é feita a partir da utilidade do mesmo item s para outros usuários c' , similares ao usuário c (ADOMAVICIUS; TUZHILIN, 2005). Usualmente é mantida, para cada usuário, um conjunto de *vizinhos próximos*, formado por outros usuários com avaliações semelhantes para mesmos itens. Um sistema de recomendação baseado em filtragem colaborativa é visto como um sistema que não analisa os itens propriamente ditos, realizando a recomendação com base apenas na similaridade de preferências entre usuários (BALABANOVIC; SHOHAM, 1997).

Os problemas de análise limitada de conteúdo e excesso de especificação, visualizados nos métodos baseados em conteúdo, não estão presentes na filtragem colaborativa, uma vez que são utilizadas as preferências de outros usuários, independentemente do conteúdo dos itens. Entretanto, são problemas desta abordagem: (i) novos itens começarão a ser recomendados apenas após avaliação de usuários; (ii) conjuntos pequenos de usuários em grandes volumes de dados tornará a recomendação esparsa, diminuindo o conjunto de itens recomendáveis; e (iii) usuários com preferências não usuais, comparados ao resto do grupo, não receberão boas recomendações, pois não terão muitos vizinhos próximos (BALABANOVIC; SHOHAM, 1997).

2.4.3 Sistemas de Recomendação Sensíveis ao Contexto

Sistemas de recomendação baseados em contexto são aqueles sistemas que exploram o uso das variáveis da situação do usuário no processo de recomendação (HUSSEIN, 2009). Isso é possível, pois o interesse por determinado conteúdo está, em geral, relacionado à situação na qual o usuário se encontra (HUSSEIN, 2009).

Sistemas de recomendação sensíveis ao contexto tem como objetivo agir proativamente, sugerindo itens possivelmente interessantes ao usuário, cientes à situação da interação. O sis-

tema recebe como entrada os candidatos à recomendação e a informação do contexto (BURIANO et al., 2006).

Sistemas de recomendação tradicionais utilizam a preferência dos usuários a itens já avaliados para estimar a preferência para itens ainda não analisados por eles. A função R de avaliação pode ser definida como:

$$R : Usuario \times Item \rightarrow Avaliacao$$

Sendo R composta pelas avaliações dadas por todos os usuários a todos os itens. Enquanto isso, os sistemas de recomendação sensíveis ao contexto buscam estimar a avaliação considerando as variáveis da situação do usuário disponíveis. Nestes casos, a função é definida como sendo as avaliações de todos os usuários, para todos os itens, estando em todos os contextos previstos (ADOMAVICIUS; TUZHILIN, 2011):

$$R : Usuario \times Item \times Contexto \rightarrow Avaliacao$$

Para tratar o contexto no processo de recomendação, adaptações são necessárias nos algoritmos, uma vez que a matriz de preferências utilizada nestes casos deve levar em consideração, além da relação entre usuário e item, as variáveis do contexto, na forma: $Usuario \times Item \times Contexto$ ($U \times I \times C$). Nestes sistemas, o contexto pode ser manipulado no processo de recomendação a partir de um *filtro prévio*, *filtro posterior*, ou através de uma *modelagem* (ADOMAVICIUS; TUZHILIN, 2011).

2.4.4 Sistemas de Recomendação e *e-learning*

Em um contexto de educação mediada por dispositivos computacionais, sistemas de recomendação são utilizados como selecionadores de materiais potencialmente interessantes ao aluno, sendo sugeridos para serem utilizados como fontes de conhecimento (KERKIRI; MANITSARIS; MAVRIDOU, 2007) (KHRIBI; JEMNI; NASRAOUI, 2009) (GHAUTH; ABDULLAH, 2009). O auxílio de sistemas de recomendação pode aumentar a eficiência da educação aos estudantes (TAN; GUO; LI, 2008), através do auxílio no processo de tomada de decisão.

Técnicas de *entrega adaptativa de curso* são as mais comuns no cenário de sistemas de recomendação para *e-learning*, adaptando a estrutura do curso dinamicamente, através da seleção de objetos de aprendizagem, e auxílio em uma navegação adaptativa. Estratégias de recomendação são utilizadas para sugerir itens e formar ligações novas e relevantes, auxiliando os alunos em seu desenvolvimento intelectual (KHRIBI; JEMNI; NASRAOUI, 2009).

3 AFFECTIVE-RECOMMENDER - SISTEMA DE RECOMENDAÇÃO SENSÍVEL AO ESTADO AFETIVO DO USUÁRIO

Neste capítulo, é exposto o sistema de recomendação proposto. Ele é capaz de reconhecer o estado afetivo do usuário para, então, selecionar, dentre um conjunto de itens disponíveis, aqueles de provável maior interesse, com base em seu estado e perfil. A proposição do sistema é feita a partir de um levantamento de requisitos, definição de modelo de arquitetura, e exposição de funcionamento.

3.1 Requisitos

Para tratar um usuário individualmente, um sistema deve ser capaz de monitorar sua interação, coletando informações para montar um modelo, contendo seus dados de interesse e preferências. O sistema deve ser capaz de alterar a apresentação de seus conteúdos, reorganizando-a com as informações apropriadas, de acordo com os interesses de cada usuário (CAZELLA; NUNES; REATEGUI, 2010).

Com base na literatura e no propósito deste sistema, levantou-se um conjunto de requisitos para alcançar sua funcionalidade: sugerir itens de provável interesse com base no estado afetivo. Os requisitos definidos para o sistema são:

1. Identificar o estado afetivo – emoção – do usuário. Uma vez que o estado será utilizado no processo de recomendação, é preciso estar ciente dele no momento da escolha dos itens a serem sugeridos. Optou-se pelo uso da emoção, por se tratar de um estado que muda no tempo, e que pode ser detectado através de mecanismos de Computação Afetiva (SCHERER, 2000).
 - (a) Utilizar equipamentos triviais. Para a identificação, utilizar apenas os equipamentos em que usuário acessará os itens recomendados, para que a detecção seja feita sem a necessidade do acréscimo de novos equipamentos específicos.
 - (b) Modelar o estado afetivo. É precisa-se determinar um modelo para a representação deste estado.
 - (c) Definir método de detecção. A partir do modelo de estado, uma maneira de detecção deve ser definida.

- (d) Determinar os momentos de detecção. Deve-se saber quando é necessário identificar o estado do usuário, para que se tenha o estado atualizado no momento da recomendação.
- 2. Definir o conjunto de itens disponíveis para serem recomendados. O sistema precisa ter informação do conjunto de dados disponíveis para serem escolhidos e sugeridos.
- 3. Formar o perfil dos usuários. É precisa-se monitorar o usuário, verificando suas preferências e avaliações em relação aos itens disponíveis e recomendados, para construir o seu perfil.
- 4. Recomendar os itens. Com base no perfil traçado e no estado afetivo, deve-se escolher e sugerir os itens de provável maior interesse, ordenadamente.

3.2 Arquitetura do Sistema

Para atender aos requisitos levantados, definiu-se uma arquitetura de sistema de recomendação sensível ao estado afetivo.

A arquitetura é constituída por quatro componentes, elencados e descritos a seguir. Ela está ilustrada na figura 3.1, com indicações da interação entre seus componentes.

1. *Detector de estado afetivo*. Responsável por identificar o estado afetivo (emoção) do usuário em um momento.
2. *Recomendador*. Escolhe o conjunto de itens a serem sugerido para o usuário, ordenados com base no provável interesse, estando ciente do estado afetivo.
3. *Aplicação*. Interface principal em que o usuário interage com os itens. Através da aplicação, são recebidas as recomendações.
4. *Base de dados*. Conjunto em que são armazenadas as avaliações dos usuários aos itens disponíveis, estando em cada estado afetivo; e os itens disponíveis para serem sugeridos.

A seguir são descritas cada parte da arquitetura do Affective-Recommender.

3.2.1 O Detector de Estado Afetivo

Mehrabian (1980) propõe um modelo afetivo, que se enquadra como uma abordagem multidimensional de emoção, dentro das divisões propostas por Scherer (2000), considerando

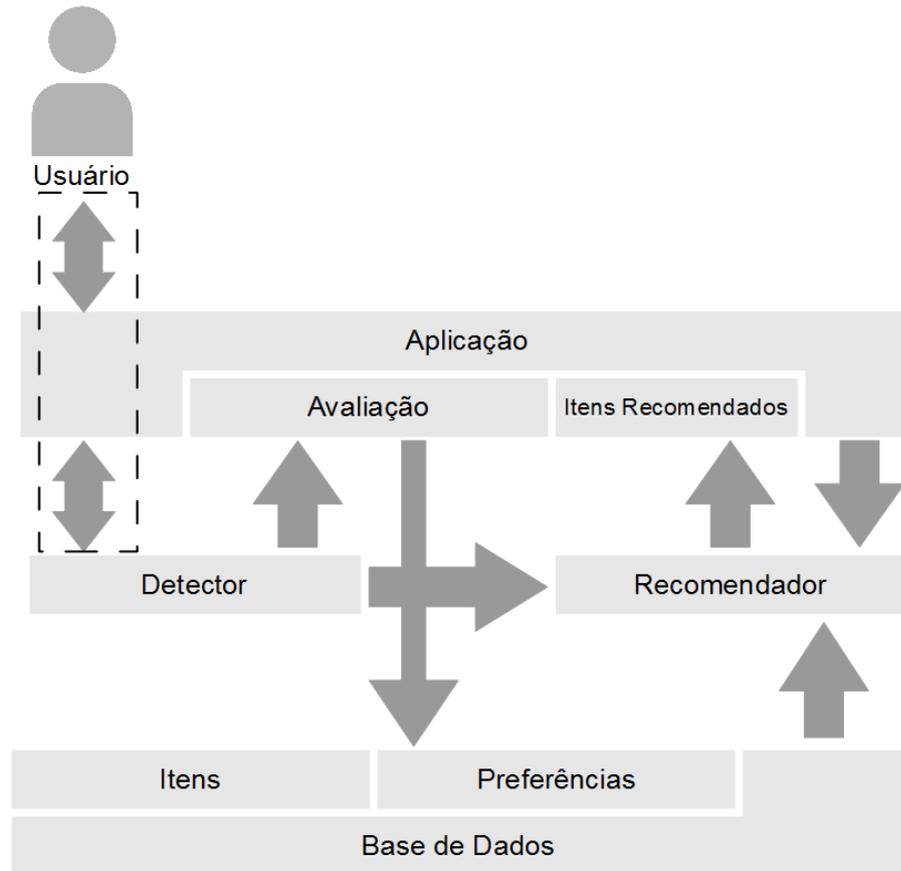


Figura 3.1 – Arquitetura do sistema

que a geração destes estados dá-se a partir de estímulos, medidos através de três dimensões ortogonais entre si, e pervasivas aos julgamentos humanos: *Pleasure* (*valence*), *Arousal* e *Dominance* (PAD) (literalmente: prazer ou valência, estímulo e domínio). Em seu modelo, Mehrabian trata o fator de *pleasure* como a valência da emoção sentida, indo de “agradável” a “desagradável”. O fator de *arousal* trata o grau de excitação, variando entre “excitado” e “relaxado”. Por fim, a dimensão de *dominance* trata o grau de controle do usuário, saindo de “dominante” até seu valor oposto, negativo, “submisso”. Para representar um estado, o valor de cada dimensão PAD é calculado independentemente, recebendo valores numéricos contínuos entre -1 e 1 (SCHERER, 2000) (BALES, 2001) (BRADLEY; LANG, 1994) (GEBHARD, 2005).

No sistema proposto, optou-se por utilizar o modelo de Pleasure, Arousal e Dominance para representação do estado afetivo do usuário. Embora haja outros modelos, como o Modelo OCC, proposto por Ortony, Clore e Collins (1988), que trata emoções como consequências com carga de valência, a eventos, agentes ou objetos, escolheu-se o PAD em virtude de sua forma de representação em termos numéricos, facilitando o tratamento computacional.

A fim de determinar os valores de cada dimensão do modelo PAD, Lang (1980) de-

envolveu o *Self-Assessment Manikin* (SAM): um instrumento orientado a figuras, originalmente implementado como um software, e posteriormente expandido para uma versão em papel (BRADLEY; LANG, 1994). No instrumento SAM, três escalas de figuras com características emocionais são expostas ao usuário, representando valores para cada dimensão PAD (LANG; BRADLEY; CUTHBERT, 1997). Para cada escala (dimensão), o usuário deve escolher uma figura, ou a intersecção entre duas delas (BRADLEY; LANG, 1994), informando, desta forma, como se sente. A escala referente à dimensão *pleasure* vai de uma figura feliz, com uma face sorrindo, a uma infeliz, com a face fechada. Para *arousal*, varia de uma figura excitada, alerta, de olhos arregalados, até uma relaxada, sonolenta, calma. Por fim, *dominance* trata mudanças no tamanho das figuras, indo de uma figura grande, simbolizando “em controle”, até uma pequena, “dominada” (BRADLEY; LANG, 1994) (LANG; BRADLEY; CUTHBERT, 1997). A Figura 3.2 ilustra as imagens originais utilizadas para definir os valores para cada dimensão de PAD pelo instrumento SAM. A primeira escala é referente a *pleasure*, a segunda a *arousal* e a terceira, *dominance*.

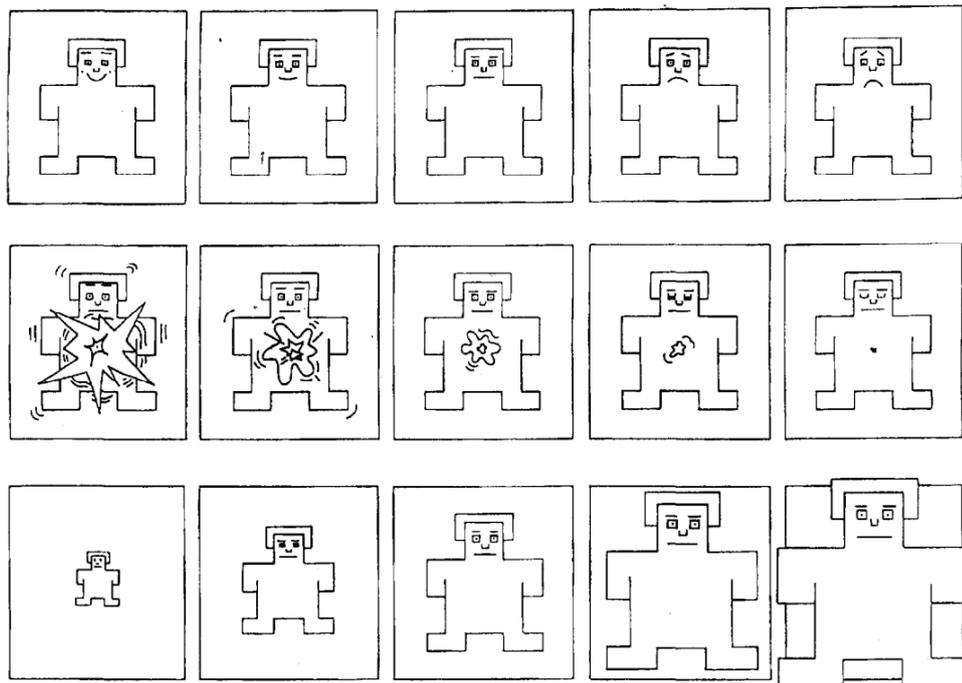


Figura 3.2 – SAM utilizado para definir os valores de PAD. De cima para baixo, escalas de *pleasure*, *arousal* e *dominance* (BRADLEY; LANG, 1994)

No detector, para que os valores de cada dimensão PAD sejam determinados, utiliza-se o instrumento Self Assessment Manikins, pedindo ao usuário que informe como se sente. Considera-se, para tanto, que o usuário seja capaz de informar seu estado durante a interação

com dispositivos computacionais. Como exemplo de situações em que há carga emocional durante a interação humano-computador, cita-se a utilização de *emoticons* na troca de mensagens. Para expressar como se sentem, usuários enviam combinações de caracteres, representando expressões faciais, com pistas sobre seu estado emocional (READ, 2005). Dessa forma, considerou-se que a detecção do estado afetivo do usuário pode ser feita a partir de um questionamento, para que ele informe como se sente.

Optou-se pela utilização da técnica de SAM devido à sua aplicabilidade prática, através da qual é possível identificar os valores para cada dimensão PAD, através de uma inserção de dados do usuário. Com isso, para identificar a emoção, pode-se utilizar os mesmos equipamentos em que a recomendação será feita.

Sendo o estado afetivo tratado como respostas a estímulos, definiu-se que a detecção deve ser feita sempre que o sistema verificar variações nas variáveis do contexto disponíveis, que signifiquem algum novo evento – estímulo. Então, solicita-se que o usuário informe como se sente. Dessa forma, o detector trata os estados como respostas a estímulos – neste caso, vistos como a variação do contexto. Com isso, preenche-se o item 1 dos requisitos do sistema, modelando-se e identificando-se as emoções dos usuários, através do uso dos mesmos equipamentos da interação com os itens, utilizando o instrumento de SAM no momento de mudanças de contexto.

3.2.2 O Recomendador

É necessário definir o perfil de cada usuário para escolher e sugerir itens a eles. O perfil é traçado a partir das *preferências* do usuário aos itens acessados, estando em determinado estado afetivo. Para determinar a *preferência*, utilizaram-se os valores PAD do estado afetivo detectado logo após o contato com o item; ou seja, o grau de interesse de um usuário por um item é tratada como sua reação a ele, como a mudança (ou não) de estado afetivo após o contato com o item. Assim, o recomendador da arquitetura do Affective-Recommender busca sugerir itens que provavelmente levarão o usuário a determinados estados afetivos. Os estados em que o sistema buscará levar os usuários devem ser definidos com base no conjunto de objetos sugeridos: no propósito do sistema de recomendação.

O recomendador utiliza uma abordagem baseada em filtragem colaborativa para a seleção e sugestão de itens. Essa abordagem foi escolhida pois recomenda itens independentemente do conteúdo, não sendo necessário, portanto, relacionar previamente os itens entre si, tampouco

com os estados afetivos.

Algoritmos de recomendação baseados em filtragem colaborativa (CF) buscam prever a preferência de um usuário para um item a partir das avaliações feitas por outros usuários, considerados semelhantes ao atual (ADOMAVICIUS; TUZHILIN, 2005). Estes algoritmos representam a relação de preferência de usuários a itens através de uma matriz bidimensional, $U \times I$, relacionando usuários a itens. A matriz possui valor nulo em elementos correspondentes a itens não avaliados pelos usuários (SARWAR et al., 2001), e algum valor numérico para os casos onde há avaliação, referentes ao grau de interesse do usuário ao item.

Para estimar a preferência de um usuário em relação a um item, usualmente utiliza-se o valor agregado das avaliações dos outros usuários, relacionada à similaridade entre estes usuários. Este cálculo é definido por:

$$r(c, s) = k \times \sum_{c'=c_1}^{c_n} sim(c, c') \times r(c', s)$$

Onde c é o usuário ativo; s o item de interesse; $r(c, s)$ a preferência do usuário c pelo item s ; k um coeficiente de normalização; $c' \in C$, onde C é o conjunto de usuários; $r(c', s)$ a preferência estimada do usuário c' pelo item s ; e $sim(c, c')$ a similaridade entre os usuários c e c' .

A similaridade entre dois usuários pode ser calculada através da abordagem baseada em cosseno. Seu funcionamento consiste em tratar os dois usuários como vetores em um espaço m -dimensional, em que m é o número de itens disponíveis. A similaridade, desta forma, é calculada através do cálculo do cosseno dos ângulos formados entre seus vetores equivalentes (ADOMAVICIUS; TUZHILIN, 2005). Ou seja, quanto menor a distância entre os dois vetores, menor será o ângulo entre eles e, conseqüentemente, maior será o valor de seu cosseno – e da similaridade.

$$sim(c, c') = \cos(\vec{c}, \vec{c}') = \frac{\vec{c} \cdot \vec{c}'}{|c| \times |c'|}$$

Adomavicius e Tuzhilin (2005) apud Adomavicius et al. (2005) propõe um método de redução que se enquadra na abordagem de manipulação de contexto baseada em filtro prévio, para tratar a informação de contexto durante o processo de recomendação. Neste método, deve-se reduzir a matriz que relaciona usuário, item e contexto em uma matriz de usuário e item, para, então, aplicar alguma das técnicas de recomendação tradicionais. Desta forma, os dados relevantes para a recomendação são obtidos, ou gerados, a partir de uma consulta ao conjunto total de informações (ADOMAVICIUS; TUZHILIN, 2011). Na arquitetura do Affective-Recommender, o recomendador utiliza a técnica de redução para tratar o contexto

durante a escolha e sugestão dos itens. Optou-se por esta técnica em virtude da possibilidade de ser utilizada em conjunto com o algoritmo de filtragem colaborativa.

Uma vez que o modelo PAD define os estados em um espaço contínuo, é necessário defini-los de forma discreta para serem manipulados na recomendação pela técnica de redução. Segundo Picard (1995), é possível definir um conjunto discreto de estados afetivos a partir de *regiões* do espaço contínuo. Para tanto, definiram-se duas regiões em cada dimensão do espaço PAD: uma para os valores positivos e outra para os negativos, utilizando-se o sinal de cada valor PAD detectado para determinar o estado afetivo do usuário. Assim, foram determinados oito regiões/estados afetivos, indicados na tabela 3.1. A definição (nome) de cada estado foi determinada com base em Broekens e Brinkman (2009), para facilitar o entendimento, sendo indiferente para o processo de recomendação.

Tabela 3.1 – Possíveis Estados Afetivos

Estado Afetivo	Pleasure	Arousal	Dominance
Feliz	+P	+A	+D
Com medo	-P	+A	-D
Surpreso	+P	+A	-D
Triste	-P	-A	-D
Bravo	-P	+A	+D
Relaxado	+P	-A	-D
Contente	+P	-A	+D
Frustrado	-P	-A	+D

Com a definição discreta dos estados, a matriz construída para o recomendador é tridimensional, relacionando $Usuario \times Item \times EstadoAfetivo$. Para reduzir esta matriz em uma bidimensional ($U \times I$), o recomendador seleciona as avaliações de usuários com o mesmo estado afetivo do usuário ativo.

Para estimar a preferência de um usuário para um item, utilizou-se o somatório descrito anteriormente, com ajustes quanto ao cálculo de similaridade e da preferência de um usuário por um item. Para o cálculo da similaridade entre os usuários, utiliza-se uma abordagem baseada no cálculo do cosseno, aplicado à matriz já reduzida:

$$sim(c, c', e) = \sum_{s'=s_1}^{s_n} \cos(reacao(c, s', e), reacao(c', s', e))$$

onde c e c' são os usuários; e é o estado afetivo; $s' \in S$ o conjunto de itens acessados pelos dois usuários estando no estado afetivo e ; e $reacao(c, s', e)$ e $reacao(c', s', e)$ os vetores tridimensionais formados pelos valores de PAD, referentes à reação ao acesso dos usuários c e c' ao item s' ,

estando no estado e . Desta forma, os vizinhos próximos serão usuários que obtiveram reações similares às do usuário ativo, estando no estado afetivo atual dele. Quanto maior o número de itens acessados pelos dois usuários, melhor será o cálculo da similaridade entre eles.

Uma vez que a preferência é armazenada em função das três dimensões, *Pleasure*, *Arousal* e *Dominance*, referentes ao estado encontrado após o acesso ao item em questão, para calcular o valor de $r(c', s, e)$ – preferência de um usuário c' por um item s , estando em um estado e – é necessário reduzir os três valores a um só. Para tanto, definiu-se que:

$$r(c', s, e) = k \times P + l \times A + m \times D$$

Dessa forma, dependendo da natureza da aplicação e dos itens que serão recomendados, deve-se definir os pesos para coeficientes de cada dimensão (k , l e m), recomendando-se, assim, itens que provavelmente levarão o usuário a determinados estados determinados. Em geral, espera-se que o valor de k seja maior, uma vez que se refere à valência do estado e , assim, buscar-se-á sugerir itens que levem a estados com valência mais positiva. A partir do recomendador, o quarto requisito do sistema é atendido

3.2.3 A Aplicação

A aplicação tem como função interagir diretamente com o usuário, coletando dados para traçar o seu perfil e expondo os itens de provável interesse, sugeridos pelo recomendador. Trata-se do ponto central da arquitetura do sistema, sendo responsável por acionar os demais componentes sempre que necessário.

O modelo de estado afetivo PAD trata as emoções como eventos originários a partir de estímulos (BRADLEY; LANG, 1994). Em virtude disso, a aplicação deve monitorar as variáveis de contexto disponíveis, a fim de acionar o detector, para identificar o estado afetivo do usuário, sempre que ocorra alguma modificação que possa levar a uma alteração deste estado. A partir da detecção do estado do usuário, a aplicação solicita ao recomendador o conjunto de itens de provável maior interesse, para que sejam sugeridos. Essa solicitação é feita informando-se o estado afetivo identificado pelo detector. De posse do retorno do recomendador, a aplicação pode alterar a sua apresentação, exibindo os itens de provável maior interesse.

Por fim, tem-se como funcionalidade da aplicação definir a reação de um usuário a um item, estando em um estado afetivo, formando o seu perfil. Esta definição é feita acionando-se o detector após o usuário ter acesso a um item, encontrando, assim, sua reação. Dessa forma, atende-se ao terceiro item dos requisitos.

3.2.4 A Base de Dados

A base de dados tem como funções (i) armazenar as avaliações de todos os usuários para todos os itens, estando em cada estado afetivo disponível, sendo esta avaliação vista como a reação do usuário, composta pelo estado afetivo detectado após entrar-se em contato com cada item; e (ii) armazenar os itens disponíveis para a recomendação.

Para tanto, é formada por uma estrutura de banco de dados relacional, composta por duas tabelas: *Preferências* e *Itens*. A tabela de *Preferências* armazena registros compostos por quatro campos: identificadores de *usuário*, *item* e *estado afetivo*; e a *reação*, expressa em valores numéricos, formada pelos valores PAD do estado afetivo detectado posteriormente ao contato com o item. Enquanto isso, a tabela *Itens* é utilizada para armazenar os artigos disponíveis para a recomendação. As duas tabelas são utilizadas pelo recomendador, para verificar as reações do usuário e buscar os itens disponíveis para sugestão. Por outro lado, a tabela *Preferências* tem seus valores atualizados pela aplicação. Através da tabela *Itens*, define-se o conjunto de objetos disponíveis para a recomendação, atendendo, portanto, o segundo requisito definido.

3.3 Fluxo de Funcionamento

O funcionamento do sistema de recomendação proposto inicia com a interação do usuário com a aplicação. Sempre que se detecta uma variação nas variáveis de contexto disponíveis, que indiquem um evento que pode alterar o estado afetivo, a aplicação ativa o detector. Através do detector, utilizando o instrumento SAM, o usuário informa como se sente, definindo seu estado através do modelo PAD.

De posse do estado afetivo do usuário, a aplicação aciona o recomendador. Este, por sua vez, encontra os itens de provável maior interesse do usuário, através da técnica de filtragem colaborativa, levando em consideração o estado afetivo identificado. Para tanto, o recomendador faz uso do perfil do usuário e dos vizinhos próximos.

Conhecendo os itens a serem sugeridos, a aplicação altera a sua apresentação, exibindo estes objetos. O usuário irá, então, acessar algum dos itens sugeridos. Findado o acesso, a aplicação solicita uma nova detecção. De posse do novo estado do usuário, obtem-se e armazena-se sua reação na tabela de preferências, na base de dados, reiniciando o processo de sugestão, com base neste estado detectado. A figura A.1, no Apêndice A traz o fluxo de funcionamento do sistema.

4 AFFECTIVE-RECOMMENDER : CASO DE USO

A importância do estado afetivo (emoção) do aluno no processo de aprendizagem; a transposição da educação convencional para o ensino mediado por computador, com o crescimento da educação a distância e da educação ubíqua; juntamente com a necessidade de personalização nesta modalidade de ensino, possível com o uso de sistemas de recomendação, projeta a análise do emprego do Affective-Recommender em um ambiente de *e-learning*. Demonstra-se, assim, como este caso de uso, a viabilidade do uso e funcionamento do sistema.

Para tratar o aluno de forma individual, em *e-learning*, utilizam-se abordagens de reestruturação dinâmica dos cursos, com a seleção adaptativa de objetos de aprendizagem (KHRIBI; JEMNI; NASRAOUI, 2009). Dessa forma, pode-se utilizar uma abordagem de recomendação de materiais didáticos para personalizar o ensino, ciente do estado afetivo dos alunos no processo de seleção destes materiais. Um material didático pode ser visto como “um produto pedagógico utilizado na educação e, especificamente, como o material instrucional que se elabora com finalidade didática” (BANDEIRA, 2009).

Neste capítulo, é discutida a forma de implementação do Affective-Recommender no contexto de *e-learning*, como um caso de uso. A seguir, é exposta (i) como deve se comportar a arquitetura do sistema neste ambiente, elencando-se cada uma de suas partes; e (ii) a implementação deste sistema, utilizando como base o Ambiente Virtual de Ensino e Aprendizagem Moodle, para a escolha e sugestão de materiais didáticos, com base no estado afetivo do aluno.

4.1 Arquitetura do Sistema

A especificação do Affective-Recommender no contexto de *e-learning* demanda a definição de cada um dos quatro componentes de sua arquitetura para este cenário. Detector, recomendador, aplicação e base de dados são descritos a seguir.

4.1.1 O Detector de Estado Afetivo

Broekens e Brinkman (2009) apresentam, em seu trabalho, o AffectButton: uma ferramenta para a detecção do estado afetivo do usuário a partir de *feedback* explícito. Trata-se de um componente que funciona como um botão, onde o usuário pode informar dinamicamente o seu estado. O AffectButton é construído de forma similar ao instrumento SAM. Medem-se,

portanto, os valores para cada dimensão *pleasure*, *arousal* e *dominance* através da escolha do usuário. O componente exibe uma face que muda de expressão com o mover do mouse nos eixos x e y. Com a mudança das expressões, são alterados os valores de cada dimensão PAD. Quando o usuário pressiona o botão, são capturados os valores correntes de cada dimensão. O uso do SAM implica que o usuário entenda o significado de cada dimensão/escala, o que não é necessário com o AffectButton, uma vez que, neste caso, deve-se escolher a face que representa uma emoção que o usuário julga semelhante a sentida por ele. Além disso, o espaço em tela necessário para a exibição do botão é menor que o necessário para exibir as imagens das três dimensões em SAM (BROEKENS; BRINKMAN, 2009). A Figura 4.1 ilustra exemplos de faces para o AffectButton, cujos nomes de estados forem definidos no trabalho de Broekens e Brinkman (2009).

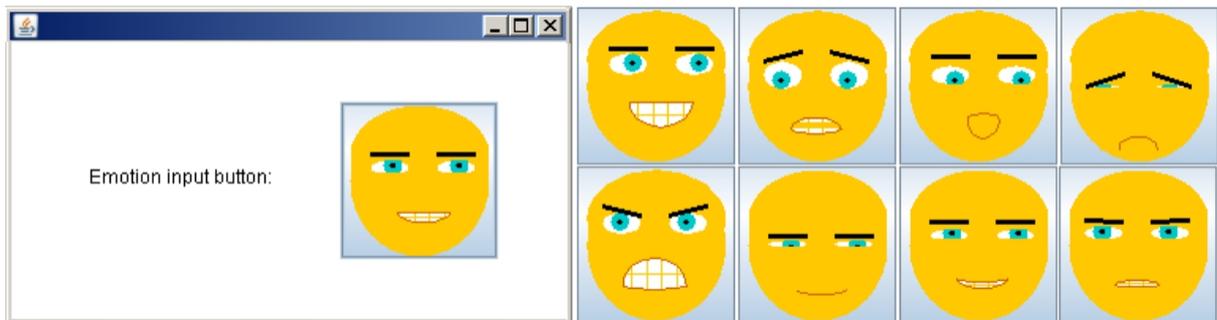


Figura 4.1 – AffectButton - De cima para baixo, de esquerda para a direita, faces geradas para os estados: Feliz, Com medo, Surpreso, Triste, Bravo, Relaxado, Contente, Frustrado (BROEKENS; BRINKMAN, 2009)

No experimento de Conati (2004) apud Jaques (2008), verificou-se que alunos sentiam-se pouco desconfortáveis com a presença de janelas de diálogo perguntando sobre seu estado, não havendo, porém, uma interferência da aparição destas janelas em sua condição (CONATI, 2004). Dessa forma, no caso de uso proposto, o detector é composto pelo AffectButton, possibilitando que os alunos informem como se sentem, nas dimensões do modelo PAD, sem a necessidade de conhecerem cada dimensão, o que seria necessário com o uso do método tradicional de *Self-Assessment Manikin*.

4.1.2 O Recomendador

O recomendador escolhe os materiais didáticos para serem sugeridos aos alunos, ciente de seu estado afetivo atual. É utilizado, como descrito no Affective-Recommender, um algoritmo de filtragem colaborativa, sendo recomendados itens cuja reação de alunos considerados

semelhantes ao atual seja a mais positiva possível.

No contexto de um curso de *e-learning*, é necessário que o aluno estude todos os conteúdos previstos. Dessa forma, não é necessário recomendar um material em que o aluno já tenha estudado, e é necessário recomendar todos os materiais que o usuário precisa para realizar seu curso. Sendo assim, o recomendador deve ter consciência dos materiais já acessados, para que escolha apenas itens ainda não visualizados pelo aluno.

Para determinar o valor da preferência do usuário a um item, a partir dos valores de PAD da reação dele, definiram-se os valores das constantes k , l e m como 2, 1, 1, respectivamente. Dessa forma, o valor é calculado a partir da expressão $2 \times P + 1 \times A + 1 \times D$, fazendo com o que o valor da valência, indicado pela dimensão *Pleasure*, seja maior que os demais, buscando-se recomendar materiais didáticos que levem o aluno a uma emoção mais positiva, visto que essas emoções ajudam a melhorar o desempenho do aluno (JAQUES; LEHMANN; JAQUES, 2008).

4.1.3 A Aplicação

Neste cenário de *e-learning*, a aplicação é o Ambiente Virtual de Ensino-Aprendizagem (AVEA). Trata-se do software principal de interação com o aluno, em que são apresentados todos os recursos e ferramentas necessários para o desenvolvimento do curso mediado por computador.

O AVEA é responsável por solicitar ao detector que identifique o estado afetivo do aluno ao verificar mudanças nas variáveis do contexto disponíveis: momento de acesso ao ambiente; tipo de atividade realizada no ambiente, como acesso a mensagens e visualização de notas; e após o contato com um material didático, para determinar a preferência do aluno. Também é papel do AVEA solicitar ao recomendador que indique os materiais para serem sugeridos, quando o aluno acessar a lista de materiais disponíveis.

4.1.4 A Base de Dados

Usualmente o AVEA manterá uma base de dados, a qual também será utilizada para a recomendação, com o acréscimo da tabela de *Preferências*. A tabela de usuários do AVEA é utilizada como fonte de dados dos alunos, assim como a tabela dos materiais didáticos, que fornece informações sobre os itens a serem recomendados. Assim, a tabela de *Preferências* contém identificadores do aluno, referenciando a tabela de usuários do AVEA; item, referenciando os materiais didáticos disponíveis; além do estado afetivo e dos valores PAD da reação do aluno.

4.2 Implementação

Existem diversos ambientes virtuais de ensino e aprendizagem disponíveis. Para o caso de uso proposto, foi feita uma implementação do Affective-Recommender com base no Moodle (MOODLE, 2012), um AVEA de código aberto, executado como aplicativo Web, escrito na linguagem PHP. O Moodle foi escolhido por ser amplamente utilizado para mediação de cursos realizados a distância e como ferramenta de apoio ao ensino; pela sua possibilidade de edição, uma vez que possui código aberto; e pelo seu suporte, também, a dispositivos móveis.

A implementação do caso de uso foi feita a partir de alterações na aplicação – Moodle, instalada na versão 2.2.3, a última disponível no início do desenvolvimento. Como servidor Web, utilizou-se o Apache versão 2.2.22. A versão utilizada do PHP foi a 5.3.10. Como base de dados, optou-se pelo uso do PostgreSQL, por ser software livre e suportado pela aplicação. A versão utilizada foi a 8.4. O código desta implementação está disponível em <http://code.google.com/p/affective-recommender/>.

Estruturalmente, o Moodle é dividido em cursos (*courses*), espaços nos quais os usuários – alunos e professores, principalmente – interagem, acessando e adicionando materiais e atividades, para o desenvolvimento do processo de ensino e aprendizagem. Os cursos podem ser agrupados em categorias que, sua vez, podem ser reagrupadas em outras categorias, em níveis, constituindo-se uma estrutura de árvore. Os cursos do Moodle são divididos por *tópicos* ou *semanas*, sendo que cada tópico/semana é construído pelo professor com o uso das ferramentas disponíveis. Destacam-se como ferramentas os *recursos*, a partir dos quais o professor expõe o conteúdo elaborado, através de materiais hipermediáticos como páginas Web, arquivos, pastas, vídeos; e as *atividades*, colaborativas ou individuais, síncronas ou assíncronas, nas quais os alunos podem interagir, provendo *feedbacks* aos conteúdos abordados pelos recursos.

Para armazenar os estados afetivos e itens disponíveis, o estado afetivo dos alunos e a preferência deles para um item, estando em um estado, conforme determinado na arquitetura, criaram-se 4 tabelas, descritas a seguir, e ilustradas no diagrama entidade-relacionamento da figura 4.2.

- *Affect Items*. Responsável por armazenar os itens disponíveis para recomendação, conforme a tabela *Itens* da base de dados da arquitetura. Os itens são os recursos adicionados pelos professores. Utiliza-se o log gerado pelo Moodle para localizar um recurso adicionado, para que seja inserido na lista de itens disponíveis. Essa tabela possui uma

referência para o log da criação do item, a partir do qual é possível recuperar a URL para acesso, e um identificador do curso ao qual o item faz parte. Foi criada pois os recursos do Moodle estão divididos em mais de uma tabela.

- *Affect States*. Tabela contendo os estados afetivos disponíveis, conforme a Tabela 3.1. É composta pelo nome do estado, e os valores booleanos para cada dimensão PAD, e utilizada como referência a outras tabelas.
- *Students Affect States*. Armazena os estados afetivos dos alunos, com o identificador do respectivo usuário, os valores de PAD, e o momento em que a detecção foi realizada.
- *Affect Preferences*. Guarda as preferências dos alunos pelos itens disponíveis, estando em determinado estado afetivo, conforme a tabela *Preferencias* da base de dados da arquitetura. A preferência é dada pelos valores de PAD do estado detectado logo após o acesso a um item. A tabela é composta pelo identificador do aluno, identificador do estado detectado antes de acessar o item, identificador do item em questão, e pelos valores PAD do estado detectado após o acesso.

Para a detecção, utilizou-se o *AffectButton* como um *applet Java*, recurso disponível no site do autor do aplicativo (<http://www.joostbroekens.com/>). O *applet* foi inserido em uma janela do tipo *dialog modal*, utilizando jQuery, para que, sempre que necessário, seja solicitado ao aluno que informe como se sente. O detector foi inserido no Moodle como um bloco: uma caixa que pode ser adicionada em diferentes contextos, como, no caso de uso, em todas as páginas. Dessa forma, através da análise dos logs gerados pelo AVEA, é possível determinar o melhor momento para realizar a detecção, exibindo, neste instante, o *AffectButton*. Os momentos definidos para a detecção foram:

1. Novo acesso ao AVEA. Sempre que um estudante acessa o ambiente, verifica-se há quanto tempo foi realizada a última detecção de estado, caso haja uma. Se foi há mais de uma hora, ou nunca foi feita uma detecção, é exibido o *AffectButton*.
2. Após acessar um recurso. Analisam-se os últimos logs de acesso gerados para um estudante, verificando se há um relativo a acesso a um recurso, e se o aluno permaneceu com este recurso aberto por 5 minutos ou mais. Sendo assim, é solicitada a detecção.
3. Após enviar uma atividade. Feito o envio ou a participação em uma atividade, através da análise dos logs, é exibido o *AffectButton* para detectar o estado afetivo do aluno.

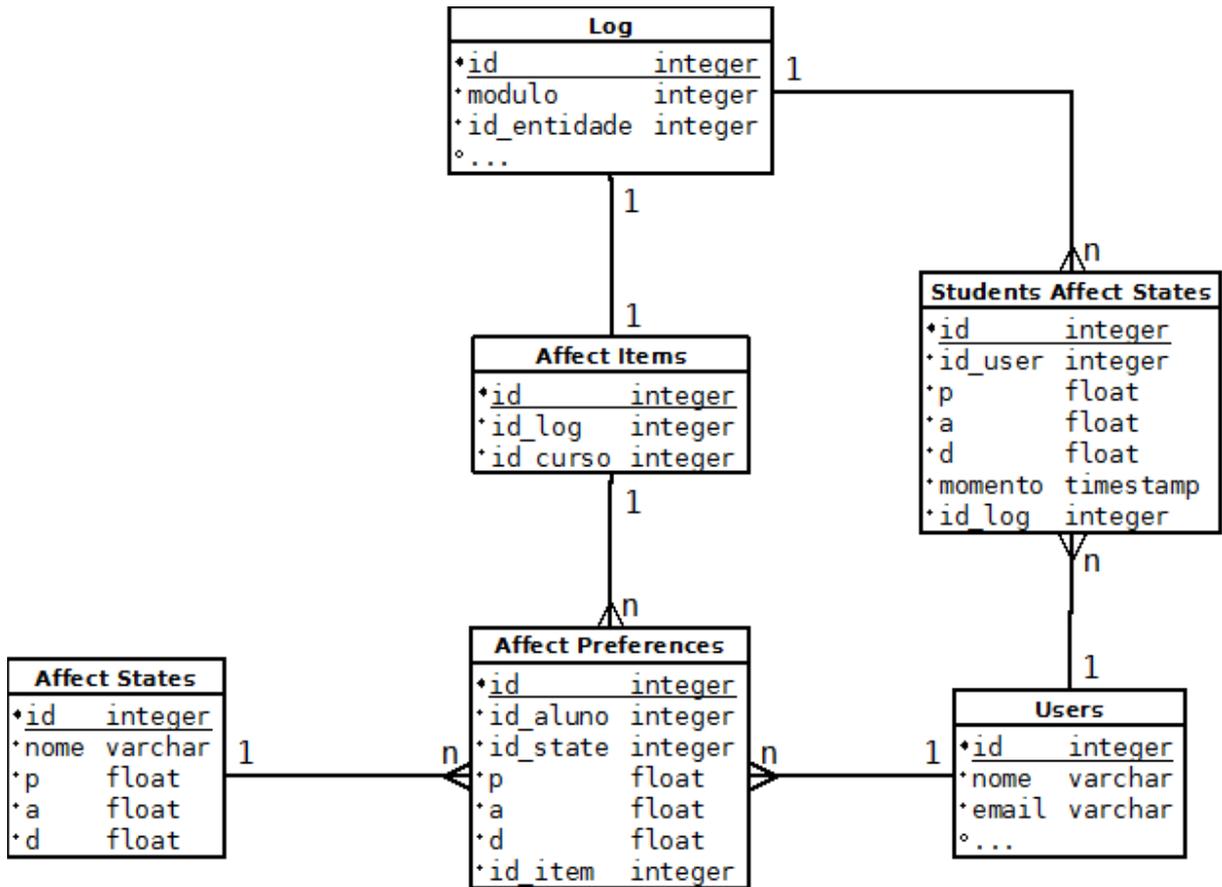


Figura 4.2 – Modelo Entidade-Relacionamento de Tabelas para o Caso de Uso

- Após visualizar as notas. Verifica-se se o aluno verificou suas notas, a partir de seus logs, solicitando-se uma nova detecção, caso tenha verificado.

A detecção realizada após o acesso a um recurso é utilizada para analisar a preferência do usuário ao item. Dessa forma, a tabela *Affect Preferences* é preenchida, como esperado pela base de dados da arquitetura, com os valores PAD do estado detectado após o acesso a cada item. A Figura 4.3 ilustra a exibição do *AffectButton*, solicitando ao usuário que informe como se sente.

A configuração de um curso no Moodle, dividido em semanas e tópicos está ilustrada nas Figuras 4.4 e 4.5, respectivamente. Dentro de uma destas seções, o professor adiciona recursos e atividades. Para que o professor pudesse construir livremente um material didático, composto por recursos e atividades, se necessário, definiu-se que os cursos seriam sempre estruturados em tópicos, e que um *tópico* seria o item de recomendação, uma vez que a configuração em semana relaciona cada seção/semana (tópico) a um período de tempo. Assim, o aluno receberá como recomendação um material didático como montado pelo professor, podendo ser formado de recursos e atividades. Configurou-se o Moodle para que o padrão de estruturação do curso

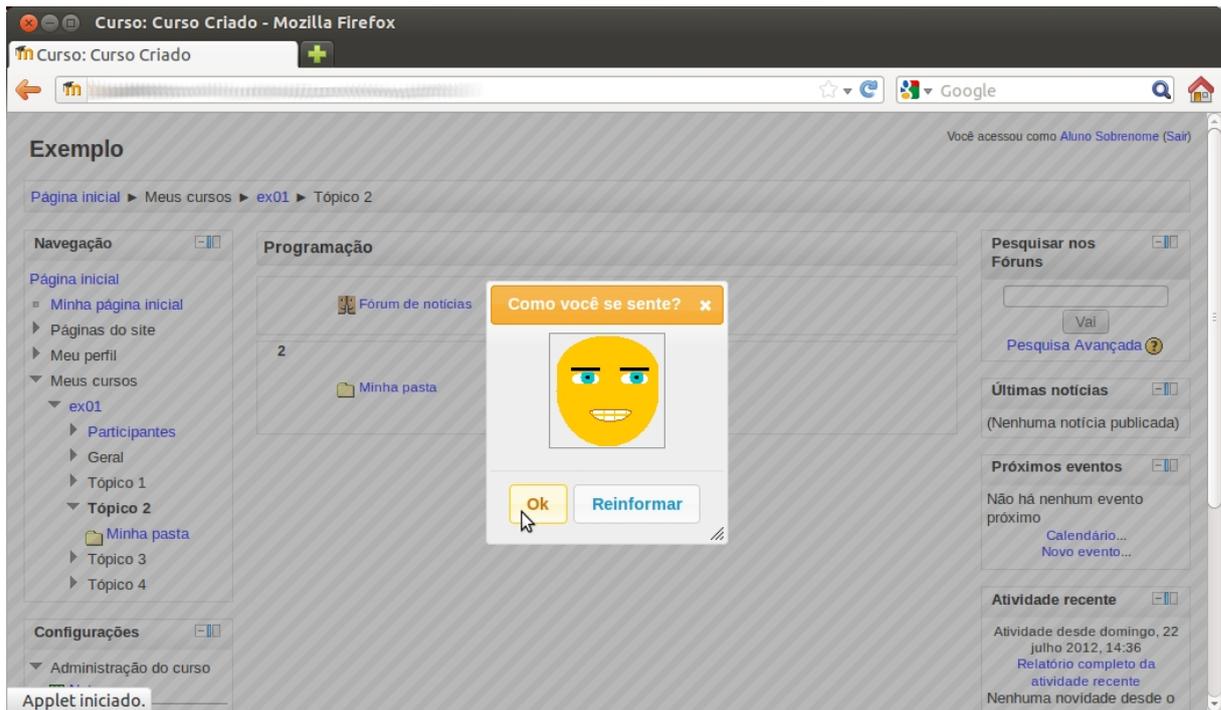


Figura 4.3 – AffectButton dentro do Moodle

seja *tópicos*, e alterou-se o seu código para impedir que o professor altere a configuração para o modo semanal.

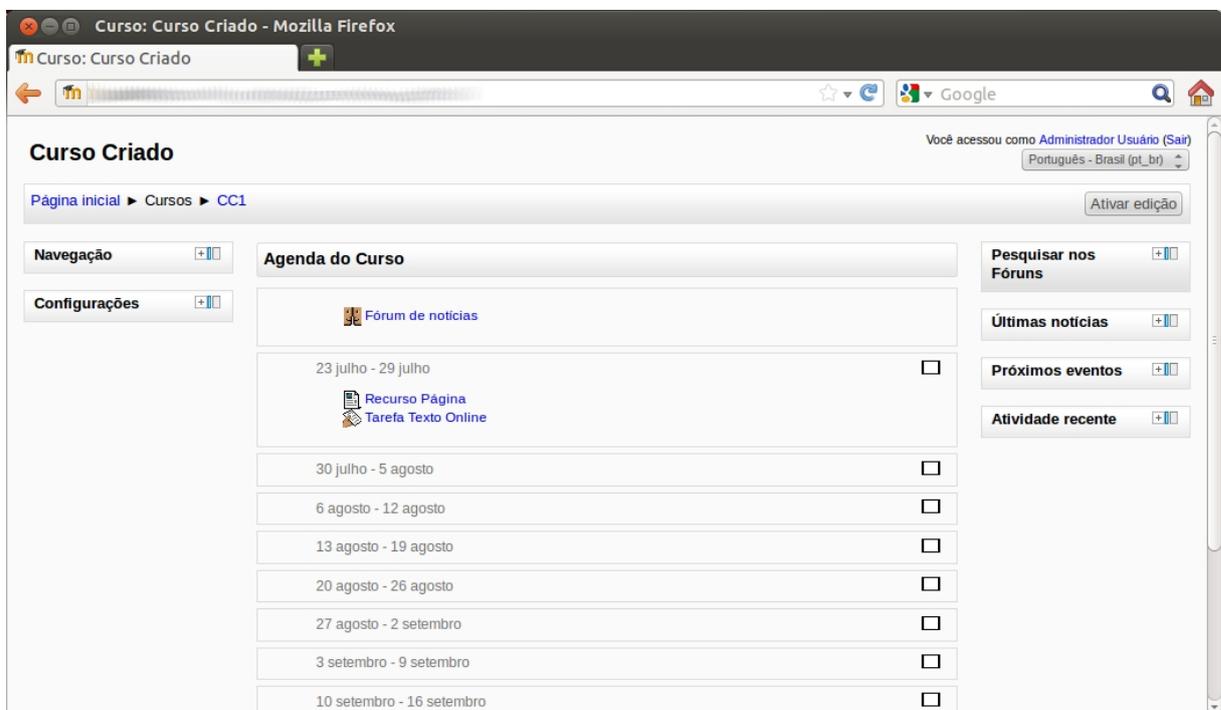


Figura 4.4 – Curso do Moodle estruturado em semanas

O algoritmo de recomendação utilizado faz uso da similaridade entre os usuários para

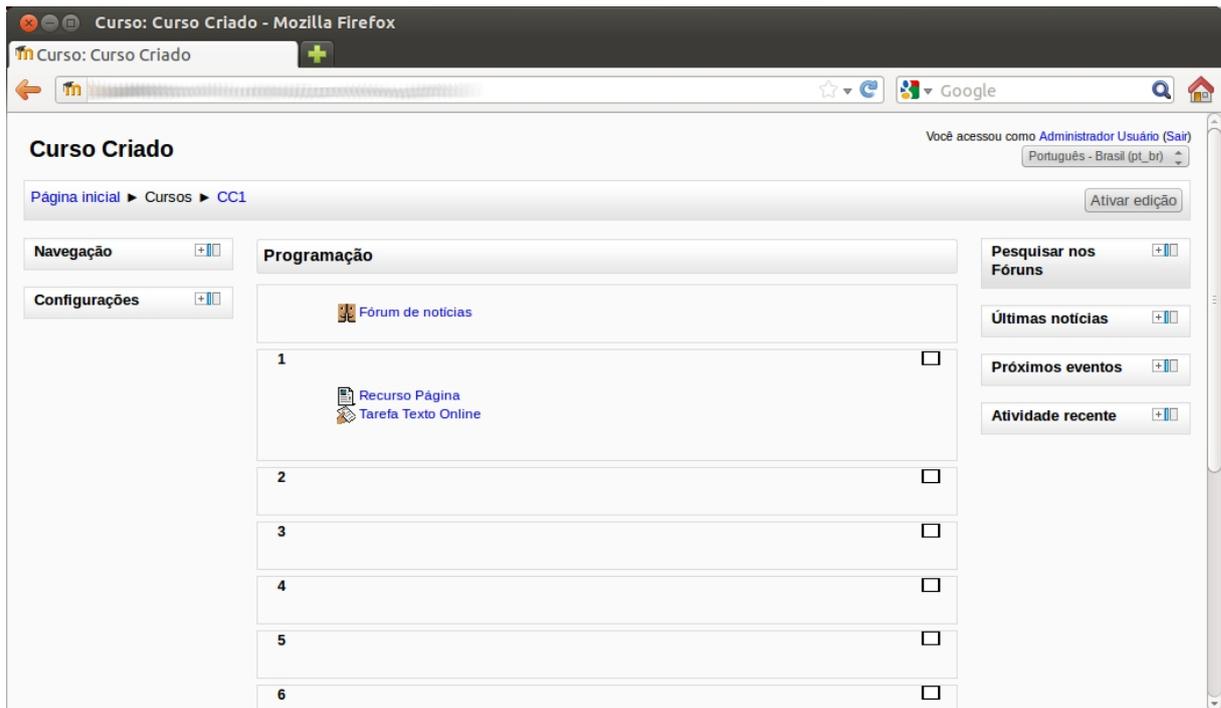


Figura 4.5 – Curso do Moodle estruturado em tópicos

estimar a preferência de um aluno para um item, estando em determinado estado afetivo, conforme esperado pelo *recomendador*. A similaridade entre dois alunos, estando em determinado estado afetivo, é calculada a partir do somatório dos cossenos dos ângulos formados pelos vetores tridimensionais (PAD) de preferência para cada item acessado por eles, conforme discriminado no recomendador da arquitetura do Affective-Recommend. Por sua vez, a preferência do aluno para o item, estando em determinado estado afetivo, é calculada como $2 \times P + A + D$, como exposto anteriormente. Com isso, o algoritmo utilizado para estimar a preferência de um usuário para um item, estando em um estado afetivo, é:

Listing 4.1 – Algoritmo - Estimativa da Preferência de Usuário a Item

```

/**
 * Recupera itens ordenados para um aluno , com base em seu
 * estado afetivo .
 *
 * @param a aluno para o qual serão buscados os itens
 * @param e estado afetivo atual detectado
 */
Array <item> recupera_itens(aluno a, estado e){
    // busca itens disponiveis
    var itens_disponiveis = busca_itens()
    // vetor com as avaliacoes
    var avaliacoes[conta(itens_disponiveis)]
    // Para cada item disponivel

```

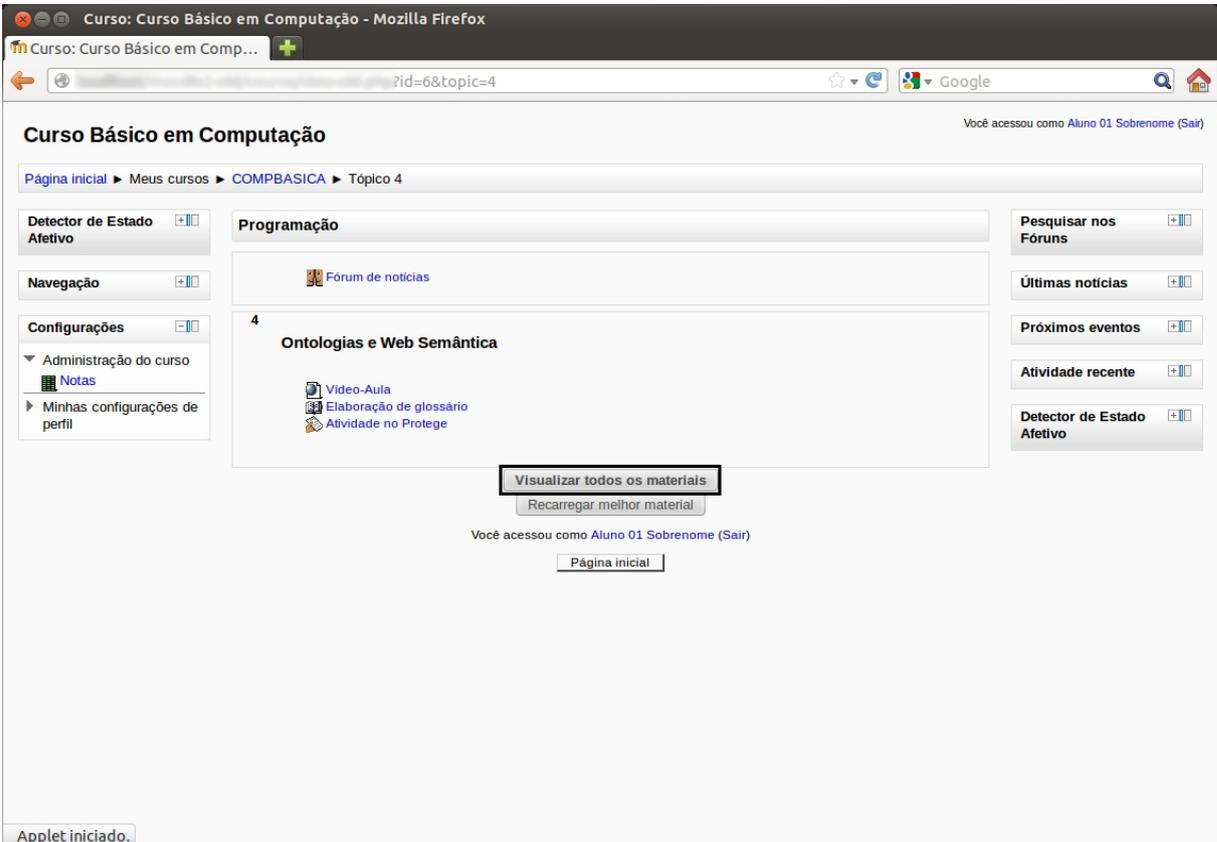
```

foreach (itens_disponiveis as item x){
    // calcula avaliacao para o item e armazena no vetor
    avaliacoes[item x] = {
        // busca a preferencias de outros alunos para o
        // item x, estando no estado do usuario atual (a)
        preferencias_outros_alunos =
            busca_preferencias(item x, estado e)
        // para cada preferencia de outros alunos
        foreach(preferencias_outros_alunos as
            aluno b => preferencia_b){
            preferencia = 0
            // calcula a preferencia do outro aluno ao item
            pref = 2 * preferencia_b.p +
                preferencia_b.a +
                preferencia_b.d
            // calcula a similaridade entre os alunos
            similaridade = {
                prefs_a =
                    busca_preferencias(aluno a, estado e)
                prefs_b =
                    busca_preferencias(aluno b, estado e)
                sim_a_b = 0
                // para cada preferencia dos alunos a um
                // mesmo item, calcula o cosseno do angulo
                para cada (prefs_a as preferencia pref_a,
                    prefs_b as preferencia pref_b){
                    sim_a_b =
                        sima_a_b +
                        cos(pref_a.p, pref_b.p, pref_a.a,
                            pref_b.a, pref_a.d, pref_b.d)
                }
                // retorna a similaridade entre os alunos
                retorna sim_a_b
            }
            // somatorio da preferencia
            preferencia =
                preferencia + similaridade * pref
        }
        // retorna a preferencia calculada para o item
        retorna preferencia
    }
}
// ordena as avaliacoes
retorna ordena(avaliacoes)

```

O algoritmo é aplicado a materiais didáticos ainda não acessados pelo aluno, gerando uma lista ordenada com base no provável maior interesse do aluno aos itens. Quando um aluno

acessa o AVEA Moodle, ele pode visualizar (i) um curso do qual faz parte; (ii) suas mensagens; (iii) seu blog; ou, ainda, (iv) seu perfil. Definiu-se que a recomendação seria realizada no momento em que o aluno acessa um curso. Na implementação, quando o aluno escolhe um curso, o material considerado de provável maior interesse é recomendado. Na mesma interface foi adicionado um botão, para que o aluno possa visualizar a lista de todos os materiais disponíveis para aquele curso, sendo ordenados com base em seu provável interesse. Este cenário é ilustrado na Figura 4.6, em que está sendo recomendado o material sobre “Ontologias e Web Semântica”, e indicado o botão para visualizar todos os materiais.



The screenshot shows a web browser window with the title 'Curso: Curso Básico em Computação - Mozilla Firefox'. The address bar contains 'Curso: Curso Básico em Comp...' and the URL fragment '?id=6&topic=4'. The page content is for the 'Curso Básico em Computação' course, accessed as 'Aluno 01 Sobrenome (Sair)'. The breadcrumb trail is 'Página inicial > Meus cursos > COMPBASICA > Tópico 4'. The main content area is titled 'Programação' and contains a 'Fórum de notícias' section with a topic '4 Ontologias e Web Semântica'. Below this topic, there are three items: 'Vídeo-Aula', 'Elaboração de glossário', and 'Atividade no Protege'. A button labeled 'Visualizar todos os materiais' is highlighted with a black box. Other buttons include 'Recarregar melhor material', 'Página inicial', and 'Detector de Estado Afetivo'. The left sidebar contains 'Configurações' with sub-items 'Administração do curso', 'Notas', and 'Minhas configurações de perfil'. The right sidebar contains 'Pesquisar nos Fóruns', 'Últimas notícias', 'Próximos eventos', 'Atividade recente', and 'Detector de Estado Afetivo'. The status bar at the bottom left says 'Applet iniciado.'.

Figura 4.6 – Exemplo de Recomendação de Material Didático no Moodle

5 DISCUSSÃO E RESULTADOS

Neste capítulo estão descritos trabalhos relacionados ao Affective-Recommender. Além disso, para avaliar o sistema, através de seu caso de uso em um ambiente de *e-learning*, é exposto um cenário de uso controlado, em que o ambiente foi populado com itens e alunos e a reação deles foi descrita para ilustrar o funcionamento do algoritmo de recomendação. Também foi realizado um estudo de caso da implementação sobre o Moodle, como ferramenta de apoio a três disciplinas de cursos presenciais da UFSM. Finalmente, foi empregado um questionário aos alunos destas disciplinas, e feita uma breve análise sobre os estados mais identificados pelo sistema, verificando as opiniões dos alunos acerca do sistema e os seus comportamentos.

5.1 Trabalhos Relacionados

Em (SHIN et al., 2009) é proposta uma abordagem de sistema de recomendação sensível ao contexto, formado por três partes: (i) abstração do contexto visualizado; (ii) definição do contexto do usuário; e (iii) recomendação, associando os itens apropriados. Cada parte é traduzida em uma camada, sendo a primeira responsável por abstrair os dados puros de contexto em conceitos; a segunda determina pesos para cada variável do contexto, com base em sua influência ao usuário; e, por fim, a terceira camada representa os itens com um conjunto de conceitos. Neste artigo, é feita uma abordagem genérica para a recomendação sensível ao contexto, sem utilizar, porém, variáveis referentes ao estado afetivo do usuário. Além disso, não se especifica como as variáveis do contexto são capturadas.

Setten et al. (2004) descreve o COMPASS, uma aplicação de recomendação de pontos turísticos, adaptável ao contexto do usuário. Utiliza-se, nesta aplicação, uma integração entre a plataforma sensível ao contexto e o sistema de recomendação. No trabalho, a localização do usuário é vista como a variável do contexto. O usuário informa suas preferências para cada categoria de ponto turístico formando, assim, o seu perfil. A recomendação é feita com base nos interesses do usuário, em sua localização, e no histórico de locais visitados. A interface da aplicação, através de um mapa, altera seu zoom, bem como o conceito de perto ou longe, com base na velocidade do usuário (SETTEN et al., 2004). Este trabalho utiliza como contexto a localização do usuário, e não o seu estado afetivo. Além disso, o usuário deve informar explicitamente as suas preferências, o que não é necessário no Affective-Recommender. Para a recomendação, é feita uma filtragem dos dados disponíveis, com base na localização, de forma

semelhante a filtragem pré-contextual utilizada no Affective-Recommender.

Iepsen et al. (2011) propõe uma ferramenta para a detecção da frustração (estado afetivo) em alunos da disciplina de algoritmos, e identificação de ações para tratá-la durante o aprendizado. A ferramenta contém uma interface para o desenvolvimento dos algoritmos, e um botão para o aluno indicar quando está frustrado. Encontraram-se características comportamentais que indicam a ocorrência da frustração, a partir da análise dos dados da interação dos alunos que antecederam às suas indicações, pressionando o botão. Para o auxílio, incluiu-se um segundo botão, de ajuda, para acesso a mensagens curtas com dicas para cada exercício, escritas pelo professor e por alunos. Este botão é exibido quando se identificam as variáveis ditas de frustração (IEPSEN; BERCHT; REATEGUI, 2011). Este trabalho trata apenas o estado de frustração, em uma única disciplina, exibindo dicas quando o estado é identificado. O diferencial de nossa proposta de caso de uso é a generalização para qualquer disciplina e curso, e o uso de técnicas de recomendação, para sugerir conteúdos ao estudante, ao invés de dicas.

Shen et al. (2009) propõe um modelo afetivo com detecção baseada em sinais fisiológicos (batimentos cardíacos, condutibilidade da pele, pressão sanguínea e ondas cerebrais), em um contexto de plataforma pervasiva para educação a distância. Propõe-se um modelo para identificar os estados afetivos *interesse*, *compromisso*, *confusão*, *frustração*, *tédio*, *esperança*, *satisfação* e *desapontamento*. No trabalho, identifica-se como as emoções são envolvidas no processo de aprendizagem, para que o sistema consiga detectá-las e responder às mudanças percebidas (SHEN; WANG; SHEN, 2009). O uso de fatores fisiológicos implica o uso de sensores para recuperar essa informação, tornando a detecção não trivial, ao passo que os alunos devem dispor e utilizar estes sensores. Em nossa proposta, este tipo de equipamento não é necessário.

Jaques (2008) traz uma abordagem cognitiva, inspirada no Modelo OCC (dos criadores Ortony, Clore e Collins) (ORTONY; CLORE; COLLINS, 1988b), para a detecção do estado afetivo de alunos em um ambiente virtual de aprendizagem. É utilizado o modelo BDI (*Belief-Desire-Intention*) (MÓRA et al., 1998) para inferir as emoções. Utilizaram-se duas categorias de perfil de aluno, com base em seus objetivos (orientados à *aprendizagem* ou a *desempenho*), aplicando-se um questionário para classificar os alunos nestas categorias. Definiu-se a desejabilidade dos eventos possíveis de ocorrerem. A emoção do usuário é detectada a partir de um conjunto de regras baseadas no Modelo BDI e definidas com base no perfil do aluno e na desejabilidade dos eventos (JAQUES, 2008). Em nosso trabalho, a detecção é feita sem a necessidade

de definir o perfil do usuário com perguntas. Além disso, o conjunto de regras tende a crescer com a inclusão de novos eventos e contextos, tornando este processo custoso, o que não é visto em nossa abordagem.

A Tabela 5.1 sumariza e compara os trabalhos apresentados e o Affective-Recommender.

Tabela 5.1 – Reações de cada usuário aos itens

Trabalho	Deteção afetiva	Equipamentos	Resposta ao usuário
Shin et al., 2009	Não há	Não especificado	Não há – Desconsiderado
Setten et al, 2004	Não há	Mesmos da recomendação	Indicação de pontos turísticos
Iepsen et al., 2011	Dados de interação com o sistema	Mesmos da aplicação	Inclusão de dicas
Shen et al., 2009	Sinais fisiológicos	Sensores “vestíveis”	Entrega de material com base no tipo da emoção detectada
Jaques, 2008	Modelos BDI e OCC	Mesmos da interação	Não há – Desconsiderado
Affective-Recommender	Instrumento SAM e modelo PAD	Mesmos da recomendação	Recomendação de itens

5.2 Cenário de Uso

A fim de expor o funcionamento do processo de recomendação, estruturou-se um cenário de uso do Affective-Recommender, para a seleção e recomendação de materiais didáticos no contexto de *e-learning*, através da implementação utilizando como base o AVEA Moodle. Neste sentido, considerou-se um cenário composto de um curso cadastrado no Moodle, onde estão matriculados cinco alunos, e estão disponíveis cinco materiais didáticos, abordando conteúdos de desenvolvimento voltado para a Web e redes de computadores. A Figura 5.1 ilustra a página inicial do curso no Moodle.

O curso, conforme exposto no capítulo de implementação, foi dividido em tópicos, sendo cada tópico um material didático composto por recursos e atividades. A fim de simplificar o disparo do processo de recomendação, definiu-se que todos os usuários estariam no estado afetivo “Com Medo”, cujos valores de PAD são, respectivamente, -1, +1, -1, em seu primeiro acesso. Este estado foi escolhido por ser facilmente indicado através do AffectButton. A partir deste estado, simulou-se o contato dos alunos com os recursos disponíveis, indicando suas reações, para o cálculo da preferência. A Tabela 5.2 ilustra as reações de cada aluno para

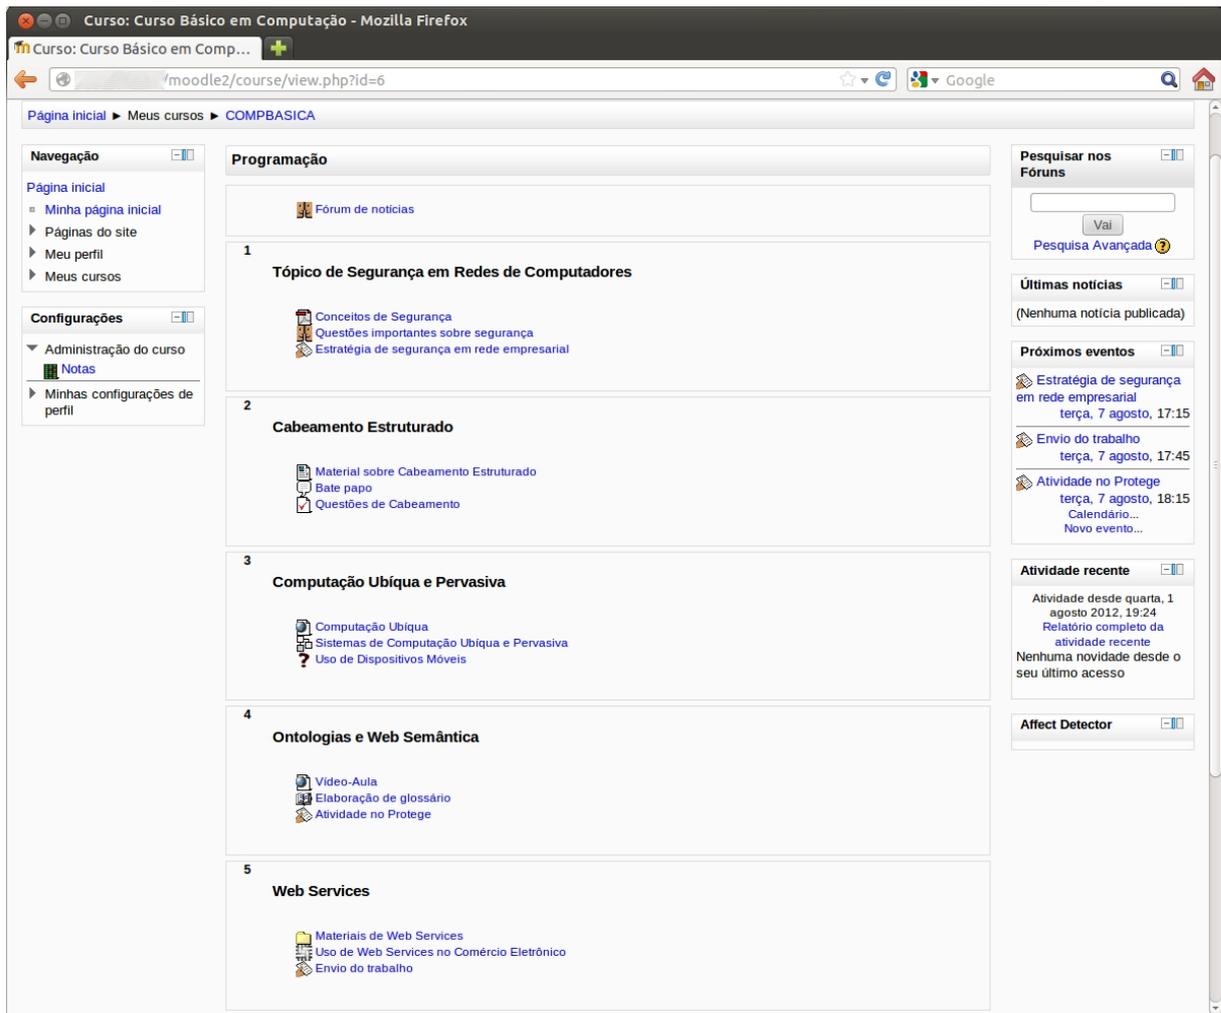


Figura 5.1 – Cenário de Uso - Materiais Disponíveis

determinados itens disponíveis, enquanto que a tabela 5.3 expõe os respectivos valores PAD para cada reação. Espaços em branco indicam itens não acessados.

Tabela 5.2 – Reações de cada usuário aos itens

Alunos	Item 1	Item 2	Item 3	Item 4	Item 5
Aluno 1	Surpreso	Com medo			Feliz
Aluno 2	Surpreso	Com medo		Feliz	
Aluno 3	Surpreso	Bravo	Feliz		
Aluno 4	Bravo	Bravo			
Aluno 5	Bravo	Feliz		Bravo	Surpreso

Os alunos 1 e 2 são vizinhos próximos, uma vez que suas reações aos itens 1 e 2 foram as mesmas – *Surpreso* e *Com Medo*. Além disso, os alunos 1, 2 e 3 também são próximos, pois a reação deles ao item 1 – *Surpreso* – foi a mesma. O Aluno 4, por sua vez, é próximo aos alunos 3 e 5, em virtude de possuírem reações idênticas aos itens 2 e 1, respectivamente – *Bravo*. Além disso, o Aluno 4 possui maior semelhança com o Aluno 5, uma vez que o cosseno

Tabela 5.3 – Reações de cada usuário aos itens, em PAD

Alunos	Item 1	Item 2	Item 3	Item 4	Item 5
Aluno 1	1, 1, -1	-1, 1, -1			1, 1, 1
Aluno 2	1, 1, -1	-1, 1, -1		1, 1, 1	
Aluno 3	1, 1, -1	-1, 1, 1	1, 1, 1		
Aluno 4	-1, 1, 1	-1, 1, 1			
Aluno 5	-1, 1, 1	1, 1, 1		-1, 1, 1	1, 1, -1

formado entre as reações ao item 2, também visualizado pelos dois alunos, possui um valor maior que o cosseno entre as reações dos alunos 4 e 3 ao item 1.

Para o Aluno 1, o recomendador selecionará e informará, como sugestão, o Item 4, uma vez que o Aluno 2 é o seu vizinho mais próximo, portanto, possuem maior similaridade, e a reação do Aluno 2 a este item foi a melhor possível (estado Feliz), tendo a maior preferência. Além deste item, como uma segunda sugestão, tem-se o Item 3, que levou o Aluno 3 ao estado Feliz. A provável avaliação do Aluno 2 ao Item 3 será menor que ao Item 4 devido à menor similaridade entre os alunos 1 e 3. O valor calculado para a similaridade entre os alunos 1 e 3 é de 1.33 , enquanto que entre os alunos 1 e 2 é de 2 . O valor da preferência dos usuários para os itens é o mesmo, uma vez que ambos foram para o estado *Feliz*, ficando com um valor 4 . Dessa forma, a estimativa do Aluno 1 para o Item 3 ficou em 5.33 , enquanto que para o Item 4 ficou em 8 , sendo recomendado o item 4 primariamente, e o 3 em seguida, conforme a Figura 5.2.

Para o Aluno 4, os itens sugeridos, em ordem de provável melhor reação, são os itens 3 e 5, e o Item 4. Os itens 3 e 5 geram o mesmo valor para o provável interesse do usuário, pois a similaridade entre os alunos 4 e 5 é maior que entre os alunos 3 e 4, em virtude de a reação ao Item 2, entre os alunos 4 e 5, possuir valor do cosseno maior que a reação ao Item 1, entre os alunos 3 e 4, e a reação do Aluno 3 ao Item 3 levar ao estado Feliz, com um valor de preferência melhor que do item 5 que, por sua vez, é referente ao Aluno 5 que possui maior semelhança com o Aluno 4. O Item 4 é o último a ser sugerido em virtude do baixo valor gerado de sua preferência. Desta forma, a similaridade entre os usuários 4 e 5 é de 1.33 , enquanto que entre os usuários 4 e 3 é de 0.66 . O valor da preferência para o Item 5 é, pela reação do Aluno 5 a ele, 2 ; para o Item 3 é 4 , com base na reação do Aluno 3; por fim, para o Item 4, a preferência gerada pelo usuário 5 tem o valor nulo 0 , porém, devido a similaridade entre os alunos 4 e 2, calculada em 0.0045 , e a preferência do Aluno 2 para o Item 5 possuir um valor 4 , este item é estimado para o Aluno 4 com um valor de preferência 0.018 . Dessa forma, os itens 3, 5 e 4 são recomendados, sendo a ordem dos dois primeiros indiferente, exposta na Figura 5.3.

The screenshot shows a Moodle course page titled "Curso Básico em Computação" in a Mozilla Firefox browser. The URL is "/moodle2/course/view_affect.php?id=6". The user is logged in as "Aluno 01 Sobre nome (Sair)". The page layout includes a navigation menu on the left with "Navegação" and "Configurações". The main content area is titled "Programação" and contains a "Fórum de notícias" section. Below this, there are four numbered sections:

- 1 Ontologias e Web Semântica**: Includes "Video-Aula", "Elaboração de glossário", and "Atividade no Protege".
- 2 Computação Ubíqua e Pervasiva**: Includes "Computação Ubíqua", "Sistemas de Computação Ubíqua e Pervasiva", and "Uso de Dispositivos Móveis".
- 3**: Empty section.
- 4**: Empty section.

 On the right side, there is a sidebar with several widgets: "Pesquisar nos Fóruns", "Últimas notícias", "Próximos eventos", "Atividade recente", and "Affect Detector". At the bottom left, a small box says "Applet iniciado."

Figura 5.2 – Cenário de Uso - Recomendações para Usuário 1

The screenshot shows the same Moodle course page as Figure 5.2, but with different recommendations. The user is logged in as "Aluno 04 Sobre nome (Sair)". The layout is identical, but the main content area "Programação" has been reorganized:

- 1 Computação Ubíqua e Pervasiva**: Includes "Computação Ubíqua", "Sistemas de Computação Ubíqua e Pervasiva", and "Uso de Dispositivos Móveis".
- 2 Web Services**: Includes "Materiais de Web Services", "Uso de Web Services no Comércio Eletrônico", and "Envio do trabalho".
- 3 Ontologias e Web Semântica**: Includes "Video-Aula", "Elaboração de glossário", and "Atividade no Protege".

 The sidebar on the right remains the same as in Figure 5.2.

Figura 5.3 – Cenário de Uso - Recomendações para Usuário 4

5.3 Estudo de Caso

Além do cenário de uso estruturado, foi realizado um estudo de caso do Affective-Recommender implementado sobre o Moodle, aplicado em três disciplinas de cursos de graduação da Universidade Federal de Santa Maria. As disciplinas fazem parte de cursos presenciais, que utilizam um AVEA como ferramenta de apoio ao ensino. Realizou-se o estudo de caso para verificar as impressões dos alunos quanto ao uso do ambiente, em relação a informar seu estado afetivo e receber recomendações; e para identificar como eles veem as relações da educação com emoções e com o uso de recomendação.

5.3.1 Dados das Disciplinas

As disciplinas que utilizaram o ambiente foram: (1) Educação em Ciências Agrárias Mediada por Tecnologia da Comunicação e Informação, do Curso de Medicina Veterinária; (2) Educação em Ciências Agrárias Mediada por Tecnologia da Comunicação e Informação, do Curso Superior de Tecnologia em Alimentos; e (3) Informática Aplicada a Processos Químicos, do Curso Superior de Tecnologia em Processos Químicos. As disciplinas possuem 21, 36 e 29 alunos, respectivamente.

Salienta-se que o uso do Affective-Recommender não se deu em um cenário propício à recomendação, em virtude, primeiramente, do curto período de tempo utilizado, dificultando a construção dos perfis dos alunos; e pela dispersão destes alunos entre as disciplinas, não havendo grandes variedades de materiais disponíveis para serem recomendados. Haveria melhores resultados quanto à recomendação se houvesse maior tempo de aplicação, com número maior de disciplinas, por exemplo, se aplicado durante todo um curso de graduação, em todas as disciplinas. Desta forma, haveria tempo disponível para traçar os perfis dos alunos, e grande quantidade de materiais disponíveis para serem recomendados. Isso não foi possível devido ao tempo de elaboração deste trabalho.

Para cada assunto abordado em sala de aula, os professores prepararam um conjunto de materiais didáticos (entre 3 e 4 por assunto), adicionados ao ambiente, possibilitando a recomendação aos alunos. A utilização do ambiente deu-se, primeiramente, em 41 dias para a turma do curso de Tecnologia em Processos Químicos, e 17 dias para as turmas dos cursos de Medicina Veterinária e Teconologia em Alimentos.

Após o período inicial de interação, foi aplicado um questionários aos alunos, para ve-

rificar suas impressões a respeito do sistema. O questionário foi composto por perguntas de múltipla escolha e por um espaço, no fim, onde o aluno poderia escrever sugestões e detalhar sua opinião sobre o Affective-Recommender. Ao todo, foram propostas 12 questões, descritas no Apêndice B. As questões de múltipla escolha eram de resposta obrigatória, enquanto que a questão discursiva, opcional. O questionário, de caráter anônimo, foi enviado por email aos alunos. Além disso, foi solicitado pelos professores responsáveis pelas disciplinas que os alunos respondessem-no.

Excetuando-se à da questão número 5, que dissertou sobre o número de aparições do AffectButton, as opções das questões de múltipla escolha foram baseadas na escala de Likert. Essa escala prevê a proposição de frases aos sujeitos da pesquisa, sendo oferecidas como opções de resposta itens que variam no grau de concordância do sujeito à frase, desde o menor valor, de discordância, ao maior, de concordância (CUNHA, 2007). No caso deste trabalho, as opções foram: (i) *Discordo totalmente*, (ii) *Discordo em parte*, (iii) *Concordo em parte* e (iv) *Concordo totalmente*. Para que os alunos sempre respondessem às questões com uma carga positiva ou negativa, de concordância ou discordância com cada afirmação, não foi disponibilizado uma opção intermediária, neutra.

Além do questionário, ainda para avaliar o uso do Affective-Recommender no contexto de *e-learning* apresentado, analisaram-se dados de detecção dos estados afetivos dos alunos.

A seguir, é feita uma discussão a respeito do resultado obtido pelo envio do questionário, e pela análise destes dados de detecção.

5.3.2 Discussão dos resultados

Como respostas aos questionários enviados, receberam-se avaliações de 6, 15 e 22 alunos, para as Disciplinas 1, 2 e 3, respectivamente, totalizando 43 formulários respondidos. Para análise, definiu-se um valor a cada opção das questões objetivas: naquelas cujas opções estavam na escala Likert, os valores foram 1, 2, 3 e 4 para as opções *Discordo totalmente*, *Discordo em parte*, *Concordo em parte* e *Concordo totalmente*, respectivamente. Dessa forma, os valores indicam o grau de concordância dos alunos para cada afirmação, com mínimo 1 e máximo 4. Já para a questão número 5, que trata do número de vezes que o AffectButton foi exibido, os valores foram 1 para a opção *O botão aparece muitas vezes*, 2 para *O botão aparece um número bom de vezes* e 3 para *O botão aparece poucas vezes*. A Tabela 5.4 sumariza a média, desvio padrão e moda das respostas das três disciplinas. No Apêndice C, as Tabelas C.1, C.2 e C.3

indicam estes mesmos dados, para cada disciplina.

Tabela 5.4 – Respostas Formulário - Geral

Questão	1	2	3	4	5	6	7	8	9	10	11
Média	3,25	2,77	3,51	2,53	1,49	1,79	2,93	2,30	2,84	2,83	3,28
Desvio Padrão	0,87	0,92	0,77	0,83	0,67	0,96	1,05	1,16	1	1,10	0,88
Moda	4	3	4	2	1	1	4	1	3	4	4

Na Tabela 5.5 estão indicados o número de vezes que cada estado afetivo foi detectado, para cada disciplina, e o geral. Enquanto isso, a Tabela 5.6 indica, para cada disciplina, (i) o número de alunos que efetivamente informou o seu estado, ao menos uma vez; (ii) número médio de detecções feitas por aluno; e (iii) o desvio padrão para essa amostra. Já a Tabela 5.7 indica a média e desvio padrão de estados afetivos diferentes que cada usuário indicou. A partir destas tabelas, pode-se perceber que os alunos informaram, em média, mais de uma vez o seu estado afetivo, e mais de um estado afetivo diferente. Assim, pode-se afirmar que eles conseguiram utilizar o AffectButton e que escolheram uma face para informar seu estado. Isso é ratificado através das respostas para a primeira questão do formulário (*Consigno informar meu estado emocional (como eu me sinto) a partir do botão da “face amarela” que aparece no Moodle*), que indica uma concordância dos alunos em conseguir informar como eles se sentem, a partir do AffectButton.

Tabela 5.5 – Número de Detecções por Estado Afetivo e Disciplina

Estado Afetivo	Disciplina 1	Disciplina 2	Disciplina 3	Total
Bravo	6	19	14	39
Com medo	1	6	2	19
Contente	24	102	37	163
Feliz	41	65	42	148
Frustrado	8	29	17	54
Relaxado	7	90	25	122
Surpreso	3	15	9	27
Triste	6	29	32	67
Geral	96	355	178	629
<i>Disciplina 1: Curso de Medicina Veterinária</i>				
<i>Disciplina 2: Curso de Tecnologia em Alimentos</i>				
<i>Disciplina 3: Curso de Tecnologia em Processos Químicos</i>				

A tabela 5.8 e os gráficos das Figuras D.1, D.2, D.3 e D.4, no Apêndice D, indicam as porcentagens de ocorrências de cada estado afetivo, para as Disciplinas 1, 2, 3, e o geral. A partir deles, nota-se que as disciplinas não tiveram um padrão de estado mais indicado: enquanto que a disciplina 1 teve o estado *Feliz* em 43% dos informados, a disciplina 2 registrou uma ligeira

Tabela 5.6 – Número de Detecções de Estado Afetivo por Aluno

Disciplina	Número de alunos	Média	Desvio Padrão	Total
Disciplina 1	16	6	6.85	96
Disciplina 2	34	10	9.89	355
Disciplina 3	26	7	4.6	178
Geral	74	8.5	8	629
<i>Disciplina 1: Curso de Medicina Veterinária</i>				
<i>Disciplina 2: Curso de Tecnologia em Alimentos</i>				
<i>Disciplina 3: Curso de Tecnologia em Processos Químicos</i>				

Tabela 5.7 – Estados Diferentes Indicados por Aluno

Disciplina	Média	Desvio Padrão
Disciplina 1	2.37	1.45
Disciplina 2	3.05	1.75
Disciplina 3	3.3	1.9
Geral	3.1	1.8
<i>Disciplina 1: Curso de Medicina Veterinária</i>		
<i>Disciplina 2: Curso de Tecnologia em Alimentos</i>		
<i>Disciplina 3: Curso de Tecnologia em Processos Químicos</i>		

vantagem para o estado *Contente*, em 28% das indicações. A disciplina 3, por sua vez, também registrou o estado *Feliz* como mais indicado, com 24%. Como um todo, nota-se que os estados mais indicados foram *Contente*, 26%, *Feliz*, 23% e *Relaxado*, 19%. Estes estados possuem como valores PAD, respectivamente, (1, -1, 1), (1, 1, 1) e (1, -1, -1). Todos eles possuem valência positiva, o que pode ser justificado pelas respostas da nona questão (*Acesso o Ambiente Moodle apenas quando tenho vontade de estudar os materiais ou fazer atividades*), que indica que a maioria dos estudantes acessa o ambiente virtual de ensino-aprendizagem quando está disposto a estudar.

Tabela 5.8 – Porcentagem de Ocorrências de cada Estado Afetivo

Estado Afetivo	Disciplina 1	Disciplina 2	Disciplina 3	Geral
Bravo	6%	5%	8%	6%
Com medo	1%	2%	1%	1%
Contente	25%	29%	21%	26%
Feliz	43%	18%	24%	24%
Frustrado	8%	8%	10%	9%
Relaxado	7%	25%	14%	19%
Surpreso	3%	4%	5%	4%
Triste	6%	8%	18%	11%
<i>Disciplina 1: Curso de Medicina Veterinária</i>				
<i>Disciplina 2: Curso de Tecnologia em Alimentos</i>				
<i>Disciplina 3: Curso de Tecnologia em Processos Químicos</i>				

A Tabela 5.9 relaciona todos os estados afetivos, indicando o número de reações aos materiais didáticos, partindo de cada estado enumerado na vertical, à esquerda, para os da horizontal, acima. No Apêndice E, as Tabelas E.1, E.2 e E.3 expõem estes dados, por disciplina. Já a tabela 5.10 resume as características dessas reações, indicando o número de *Positivas*, que chegaram a um estado cujo valor de preferência ($2*P + A + D$) era maior que o do estado anterior; *Negativas*, cujo valor de preferência do estado de reação posterior foi menor que o anterior ao contato com o item; reações que permaneceram no mesmo estado (*Igual*); e reações que partiram para estados diferentes, porém com mesmo valor de preferência (*Neutras*). Dessa forma, verifica-se que, embora haja um grande número de reações sem mudança do estado (36%), a maioria das reações (64%) levou a um estado diferente ao detectado antes do acesso ao item, indicando que o acesso ao material fez mudar o estado do usuário. No questionário aplicado, a segunda questão disserta sobre a percepção dos alunos quanto à essa mudança de estado (*Percebo que meu estado emocional se altera dependendo do material didático estudado*). A partir das respostas à ela, verifica-se uma tendência para a concordância, principalmente na terceira disciplina, ratificando que os alunos identificaram mudanças em seu estado afetivo com base no material didático estudado.

Tabela 5.9 – Número de Reações por Estado Afetivo - Total

	Bravo	Com medo	Contente	Feliz	Frustrado	Relaxado	Surpreso	Triste
Bravo	7	0	1	2	5	2	0	2
Com medo	0	0	1	2	0	0	1	1
Contente	4	0	28	8	9	11	3	2
Feliz	2	1	14	36	5	1	4	2
Frustrado	2	1	6	0	0	6	0	7
Relaxado	1	0	8	1	3	19	6	12
Surpreso	0	0	2	4	3	5	0	0
Triste	3	2	0	3	6	6	0	7

Tabela 5.10 – Características das Reações

Tipo da Reação	Disciplina 1	Disciplina 2	Disciplina 3	Total
Positiva	3	31	34	68
Negativa	8	47	38	93
Igual	7	60	30	97
Neutra	1	4	4	9
<i>Disciplina 1: Curso de Medicina Veterinária</i>				
<i>Disciplina 2: Curso de Tecnologia em Alimentos</i>				
<i>Disciplina 3: Curso de Tecnologia em Processos Químicos</i>				

Verificando as respostas à terceira questão (*Quanto mais eu gosto de um material didá-*

tico, mais feliz eu fico em estudar ele), nota-se que os alunos concordam que se sentem mais felizes, ou seja, vão a estados mais positivos, quando estudam materiais que gostam mais. Dessa forma, ratifica-se o uso da reação como variável da preferência do usuário a um item, neste caso, ao material didático; e o uso de uma fórmula nos termos P, A e D, que privilegie estados mais positivos.

A média da quarta questão (*O item sugerido ao acessar a disciplina e os itens mais ao topo, quando eu clico em “visualizar todos os materiais”, são mais interessantes que os itens que aparecem mais abaixo*) indica um nível neutro de concordância, porém, a moda mostra que a maioria dos usuários não concorda que os itens recomendados fossem mais interessantes que os demais, o que era esperado, em virtude do tempo reduzido para construção dos perfis dos alunos, e da pequena quantidade de dados (itens e alunos) disponível para processamento.

A partir da quinta questão (*Em relação ao número de vezes que o botão (face amarela) aparece no Moodle, para indicar como me sinto, eu julgo que:*), verifica-se que os alunos julgaram que o AffectButton apareceu muitas vezes. Já pela sexta (*Ocorreu de meu estado emocional mudar e o botão não aparecer para que eu pudesse informá-lo*), verifica-se que eles não identificaram, em geral, situações que pudessem alterar seu estado afetivo e que não foram contempladas pela exibição do botão. Com isso, verifica-se que foram englobados muitos momentos de possível troca de estado afetivo, nos quais o AffectButton foi exibido. Sugere-se, então, reanalisar os momentos de detecção para este caso de *e-learning*, alterando a abordagem aplicada. Já para a oitava questão (*Gostaria de utilizar o botão da “face amarela” em todas as disciplinas que participo/participarei no Ambiente Moodle*), as respostas indicam que os alunos não sugerem o uso do AffectButton em outras disciplinas. Essa tendência pode ser justificada pelas questões de número 5 e 6: uma vez que se julgou muito grande o número de aparições do botão, e que não se conduziu a melhores recomendações, os alunos podem não julgar interessante informar como se sentem, uma vez que não melhoraram, neste experimento, os materiais sugeridos.

Para a sétima questão (*Tenho vontade de estudar conteúdos diferentes com base em meu estado emocional (como estou me sentindo)*), indicou-se concordância dos usuários em relação a estudar materiais diferentes baseando-se em seu estado afetivo, confirmando que o estado influencia suas preferências. Vale ressaltar que, para a Disciplina 2, embora a moda indique concordância, a média ficou em um valor neutro, podendo indicar diferentes opiniões com base nos perfis dos alunos, da disciplina e dos cursos envolvidos.

A partir da décima questão (*Geralmente tenho dúvidas sobre qual conteúdo estudar. Logo, acho interessante usar um sistema que recomende um conteúdo que provavelmente irei gostar mais*), sugere-se que a maioria dos alunos tem dúvidas sobre qual conteúdo estudar, ratificando o uso de um sistema de recomendação para auxiliar esta tomada de decisão. Por fim, as respostas à questão número onze (*Meu estado emocional (como me sinto) altera a minha disposição para a aprendizagem*) ratificam a influência do estado afetivo do aluno no processo de aprendizagem, confirmando a importância de seu uso em um ambiente de *e-learning*.

Para a questão discursiva, foram feitos 4 comentários. A partir deles, pode-se verificar descontentamento com o número de vezes que o botão foi exibido, e sobre questões técnicas quanto à necessidade do navegador possuir suporte a Java, uma vez que o AffectButton foi utilizado como um *applet* desenvolvido nesta tecnologia. Como pontos positivos, verifica-se um comentário sobre uma aproximação do aluno com o “professor”, obtido pelo aluno ao indicar como está se sentindo. Uma vez que o uso de um ambiente virtual distancia o contato físico entre aluno e professor, o uso de uma abordagem afetiva pode amenizar essa sensação, melhorando a interação humano-computador, embora o professor, de fato, não tenha acesso a emoção do aluno através do Affective-Recommender.

A partir da análise dos dados de acesso e das respostas do questionário aplicado, verificou-se que os alunos conseguiram informar seus estados afetivos através do AffectButton, modelado nos valores de PAD. Também verificou-se que houve alterações nos estados afetivos após interações com o sistema/materiais didáticos acessados. Os alunos demonstraram identificar relações entre como estão se sentindo, seu processo de aprendizagem, e a escolha de um ou outro material. Por fim, eles foram positivos na ideia de receber recomendações, embora não tenham visualizado essas vantagens no uso do sistema, muito em virtude da pequena quantidade de dados disponíveis para o processamento.

6 CONCLUSÃO

Emoções tem grande importância em nossas vidas, interferindo na interação humano-computador. Aplicações de Computação Ubíqua buscam melhorar o cotidiano dos usuários, utilizando informações disponíveis sobre a sua situação: o contexto. Dessa maneira, o estado afetivo pode ser tratado como variável do contexto, e estudos em Computação Afetiva tratam maneiras de reconhecê-lo.

A explosão de informações disponíveis torna a tomada de decisão um problema. Sistemas de recomendação processam esse conjunto de dados para escolherem e sugerirem itens para os usuários. O uso do contexto neste processo aprimora a seleção e sugestão de itens, baseando-se, também na situação em que o usuário se encontra. A grande importância das emoções, enquanto estado afetivo, em nossas vidas, faz com que elas possam ser utilizadas como variável do contexto, em sistemas de recomendação.

Este trabalho propôs um sistema de recomendação sensível ao estado afetivo do usuário, o Affective-Recommender. O sistema modela este estado do usuário através das dimensões Pleasure, Arousal e Dominance, sendo cada estado afetivo definido como um ponto no espaço formado por estas três bases ortogonais. Para a detecção, utiliza-se o instrumento de Self-Assessment Manikin, que solicita ao usuário que informe como sente. A partir daí, realiza-se a recomendação de itens ao usuário, através de um algoritmo baseado em filtragem colaborativa. Para traçar o perfil dos usuários, com suas preferências quanto a cada item disponível para recomendação, utilizou-se a reação deles a cada item, ou seja, o estado detectado logo após o contato com o item recomendado, estando em cada estado afetivo. Dessa forma, consideraram-se vizinhos próximos os usuários que tiveram reações similares a mesmos conteúdos.

Como caso de uso do sistema e prova de conceito, indicou-se cenários de *e-learning*. A inserção das tecnologias na educação forma um novo paradigma de ensino, capaz de oferecer uma educação a qualquer momento e em qualquer lugar. Emoções influenciam o processo cognitivo, e a personalização é uma característica importante nestes ambientes, tornando a educação mediada por dispositivos tecnológicos um cenário propício ao emprego do Affective-Recommender. Foi feita uma implementação do sistema utilizando o AVEA Moodle, e aplicada em três turmas de cursos de graduação, como ferramenta de apoio. A partir de questionário aplicado aos alunos, e da análise dos dados de acesso, no que tange os estados detectados, pôde-se concluir que os usuários conseguem informar seu estado afetivo; que reações a este estado

são sentidas ao acessar um item; que os alunos tem vontade de estudar materiais diferentes, baseando-se em como se sentem; e que aprovam a sugestão de itens, pois possuem dúvidas sobre qual material escolher.

Através do Affective-Recommender, pode-se realizar recomendações aos usuários, com base em como eles se sentem. Considera-se que aplicações computacionais, cada vez mais ubíquas, devam utilizar variáveis da emoção do usuário para aprimorar a interação. Recomendações possibilitam o tratamento de grandes volumes de dados, e o uso do contexto auxilia a escolha dos itens. O ensino mediado por dispositivos computacionais e, mais, o *u-learning* é uma tendência com a popularidade dos AVEAs e da inserção das TIC no cotidiano, podendo ser aprimorada com o uso do Affective-Recommender.

Como trabalhos futuros, sugere-se o emprego do Affective-Recommender em um campo diferente do *e-learning*, por exemplo, em aplicações que possam sugerir atividades ou produtos aos usuários. Além disso, espera-se fazer uso de outras informações no processo de recomendação, como a natureza de cada item. Por fim, dentro de um contexto de *u-learning*, propõe-se a construção de um AVEA totalmente ubíquo, capaz de monitorar a interação do usuário e outras variáveis de contexto disponíveis, para a seleção e sugestão de itens.

REFERÊNCIAS

- ABOWD, G. D. et al. Towards a Better Understanding of Context and Context-Awareness. In: **Proceedings of the 1st international symposium on Handheld and Ubiquitous Computing**, London, UK. Springer-Verlag, 1999. p.304–307. (HUC '99).
- ADOMAVICIUS, G.; TUZHILIN, A. Toward the Next Generation of Recommender Systems: a survey of the state-of-the-art and possible extensions. **IEEE Trans. on Knowl. and Data Eng.**, Piscataway, NJ, USA, v.17, p.734–749, June 2005.
- ADOMAVICIUS, G.; TUZHILIN, A. Context-Aware Recommender Systems. In: **Recommender Systems Handbook**. 2011. p.217–253.
- ARAÚJO, R. B. de. Computação Ubíqua: princípios, tecnologias e desafios. In: **11o. Simpósio Brasileiro de Redes de Computadores**. 2003. p.45–115.
- AUGUSTIN, I. **Abstrações para uma linguagem de programação visando aplicações móveis em um ambiente de Pervasive Computing**. 2004. Tese (Doutorado em Ciência da Computação) — Universidade Federal do Rio Grande do Sul. Instituto de Informática. Curso de Pós-Graduação em Ciência da Computação.
- BALABANOVIC, M.; SHOHAM, Y. Fab: content-based, collaborative recommendation. **Communications of the ACM**, v.40, p.66–72, 1997.
- BALES, R. **Social Interaction Systems: theory and measurement**. Transaction Publishers, 2001.
- BANDEIRA, D. Material didático: conceito, classificação geral e aspectos da elaboração. In: **Curso de Materiais didáticos para smartphone e tablet**. Curitiba, PR: IESDE, 2009. p.13–33.
- BRADLEY, M. M.; LANG, P. J. Measuring emotion: the self-assessment manikin and the semantic differential. **Journal of Behavior Therapy & Experimental Psychiatry**, v.25, n.1, p.49–59, 1994.
- BROEKENS, J.; BRINKMAN, W.-P. AffectButton: towards a standard for dynamic affective user feedback. In: **Affective Computing and Intelligent Interaction and Workshops**. 2009. p.1–8.

BURIANO, L. et al. The Role of Ontologies in Context-Aware Recommender Systems. In: **INTERNATIONAL CONFERENCE ON MOBILE DATA MANAGEMENT**. Washington, DC, USA. IEEE Computer Society, 2006. p.80–. (MDM '06).

CALVO, R. A.; D'MELLO, S. Affect Detection: an interdisciplinary review of models, methods, and their applications. **IEEE Trans. Affect. Comput.**, Los Alamitos, CA, USA, v.1, p.18–37, January 2010.

CAZELLA, S. C.; NUNES, M. A. S. N.; REATEGUI, E. A Ciência do Palpite: estado da arte em sistemas de recomendação. In: **JORNADA DE ATUALIZAÇÃO DE INFORMÁTICA**, PUC Rio. 2010. p.161–216.

CHENG, I.; SAFONT, L.; BASU, A. **Multimedia in Education**: adaptive learning and testing. World Scientific, 2010.

CLARK, R. C.; MAYER, R. E. **e-Learning and the Science of Instruction**: proven guidelines for consumers and designers of multimedia learning. 3rd.ed. Pfeiffer & Company, 2011.

CONATI, C. How to Evaluate Models of User Affect? In: **ADS'04**. 2004. p.288–300.

CUNHA, L. M. A. da. **Modelos Rasch e Escalas de Likert e Thurstone na medição de atitudes**. 2007.

ELLIOTT, C.; RICKEL, J.; LESTER, J. Lifelike pedagogical agents and affective computing: an exploratory synthesis. In: WOOLDRIDGE, M. J.; VELOSO, M. (Ed.). **Artificial intelligence today**. Berlin, Heidelberg: Springer-Verlag, 1999. p.195–212.

GEBHARD, P. ALMA: a layered model of affect. In: **AUTONOMOUS AGENTS AND MULTIAGENT SYSTEMS**, New York, NY, USA. ACM, 2005. p.29–36. (AAMAS '05).

GHAUTH, K. I. B.; ABDULLAH, N. A. Building an E-learning Recommender System Using Vector Space Model and Good Learners Average Rating. **Advanced Learning Technologies, IEEE International Conference on**, Los Alamitos, CA, USA, v.0, p.194–196, 2009.

GONZALEZ, G. et al. Embedding Emotional Context in Recommender Systems. **2007 IEEE 23rd International Conference on Data Engineering Workshop**, p.845–852, 2007.

HUSSEIN, T. Context-aware Recommendations. In: DUISBURG-ESSEN, U. of (Ed.). . 2009.

IEPSEN, E. F.; BERCHT, M.; REATEGUI, E. Detecção e Tratamento do Estado Afetivo Frustração do Aluno na Disciplina de Algoritmos. **Anais do XXII Simpósio brasileiro de Informática na Educação**, p.80–89, 2011.

JAQUES, P. A. AVALIANDO UM MODELO AFETIVO DE ALUNO BASEADO EM UMA ABORDAGEM COGNITIVA. **Anais do XIX Simpósio brasileiro de Informática na Educação**, p.155–165, 2008.

JAQUES, P. A.; LEHMANN, M.; JAQUES, K. S. F. AVALIANDO A EFETIVIDADE DE UM AGENTE PEDAGÓGICO ANIMADO EMOCIONAL. **Anais do XIX Simpósio brasileiro de Informática na Educação**, p.155–165, 2008.

JONES, V.; JO, J. H. Ubiquitous learning environment: an adaptive teaching system using ubiquitous technology. In: **ASCILITE CONFERENCE**. 2004. p.468–474.

KERKIRI, T.; MANITSARIS, A.; MAVRIDOU, A. Reputation Metadata for Recommending Personalized e-Learning Resources. **Semantic Media Adaptation and Personalization, International Workshop on**, Los Alamitos, CA, USA, v.0, p.110–115, 2007.

KHRIBI, M. K.; JEMNI, M.; NASRAOUI, O. Automatic Recommendations for E-Learning Personalization Based on Web Usage Mining Techniques and Information Retrieval. **Educational Technology e Society**, v.12, n.4, p.30–42, 2009.

LANG, P. J.; BRADLEY, M. M.; CUTHBERT, B. N. **International affective picture system (IAPS): technical manual and affective ratings**. NIMH Center for the Study of Emotional and Attention, 1997.

LIU, F.-j.; SHIH, B.-j. Learning Activity-Based E-Learning Material Recommendation System. In: **NINTH IEEE INTERNATIONAL SYMPOSIUM ON MULTIMEDIA WORKSHOPS**, Washington, DC, USA. IEEE Computer Society, 2007. p.343–348. (ISMW '07).

LONGHI, M. et al. Um estudo sobre os Fenômenos Afetivos e Cognitivos em Interfaces para Softwares Educativos. In: **REVISTA NOVAS TECNOLOGIAS NA EDUCAÇÃO**. 2007. p.31–41.

MARTINHO, C.; MACHADO, I.; PAIVA, A. A Cognitive Approach to Affective User Modeling Affective Interactions. In: PAIVA, A. (Ed.). . Berlin, Heidelberg: Springer Berlin / Heidelberg, 2000. p.64–75. (Lecture Notes in Computer Science, v.1814).

MOODLE. **Moodle.org**: open-source community-based tools for learning. Disponível em: <http://moodle.org/> Acesso em: Março de 2012.

MÓRA, M. C. et al. BDI Models and Systems: reducing the gap. In: **ATAL**. 1998. p.11–27.

O'REGAN, K. E. Emotion and e-learning. **Journal of Asynchronous learning networks**, v.7, n.3, p.78–92, 2003.

ORTONY, A.; CLORE, G. L.; COLLINS, A. **The Cognitive Structure of Emotions**. Cambridge University Press, 1988.

ORTONY, A.; CLORE, G. L.; COLLINS, A. **The Cognitive Structure of Emotions**. Cambridge University Press, 1988.

PIAGET, J. **Inteligencia y afectividad**. Aique, 2005. (Inteligencia y afectividad).

PICARD, R. Affective Computing. In: **MIT Media Laboratory**. 1995.

PICARD, R. W. **Affective computing**. Cambridge, MA, USA: MIT Press, 1997.

PICARD, R. W. et al. Affective Learning — A Manifesto. **BT Technology Journal**, Hingham, MA, USA, v.22, n.4, p.253–269, Oct. 2004.

READ, J. Using emoticons to reduce dependency in machine learning techniques for sentiment classification. In: **ACL STUDENT RESEARCH WORKSHOP**, Stroudsburg, PA, USA. Association for Computational Linguistics, 2005. p.43–48. (ACLstudent '05).

RICCI, F. Mobile Recommender Systems. In: **BOLZANO, F. U. of (Ed.)**. . 2010.

RUSSELL, J. A. Core affect and the psychological construction of emotion. **Psychological review**, Department of Psychology, Boston College, Chestnut Hill, Massachusetts 02467, USA. james.russell@bc.edu, v.110, n.1, p.145–172, Jan. 2003.

SARWAR, B. et al. Item-based collaborative filtering recommendation algorithms. In: **Proceedings of the 10th international conference on World Wide Web**. New York, NY, USA: ACM, 2001. p.285–295. (WWW '01).

SCHERER, K. R. Psychological Models of Emotion. In: BOROD, J. C. (Ed.). **The Neuropsychology of Emotion**. Oxford, New York, Estados Unidos: Oxford University Press US, 2000. p.137–166.

SCHILIT, B.; ADAMS, N.; WANT, R. Context-Aware Computing Applications. In: **FIRST WORKSHOP ON MOBILE COMPUTING SYSTEMS AND APPLICATIONS**, 1994., Washington, DC, USA. IEEE Computer Society, 1994. p.85–90. (WMCSA '94).

SETTEN, M. V. et al. Context-aware recommendations in the mobile tourist application COMPASS. In: **IN NEJDL, W. & DE BRA, P. (EDS.)**. AH 2004, LNCS 3137. Springer-Verlag, 2004. p.235–244.

SHEN, L.; WANG, M.; SHEN, R. Affective e-Learning: using "emotional" data to improve learning in pervasive learning environment. **Educational Technology and Society**, v.12, n.2, p.176–189, 2009.

SHIN, D. et al. Context-Aware Recommendation by Aggregating User Context. In: **IEEE CONFERENCE ON COMMERCE AND ENTERPRISE COMPUTING**, 2009, Washington, DC, USA. IEEE Computer Society, 2009. p.423–430. (CEC '09).

TAN, H.; GUO, J.; LI, Y. E-learning Recommendation System. In: **INTERNATIONAL CONFERENCE ON COMPUTER SCIENCE AND SOFTWARE ENGINEERING - VOLUME 05**, 2008., Washington, DC, USA. IEEE Computer Society, 2008. p.430–433. (CSSE '08).

APÊNDICES

APÊNDICE A – Fluxo de Funcionamento

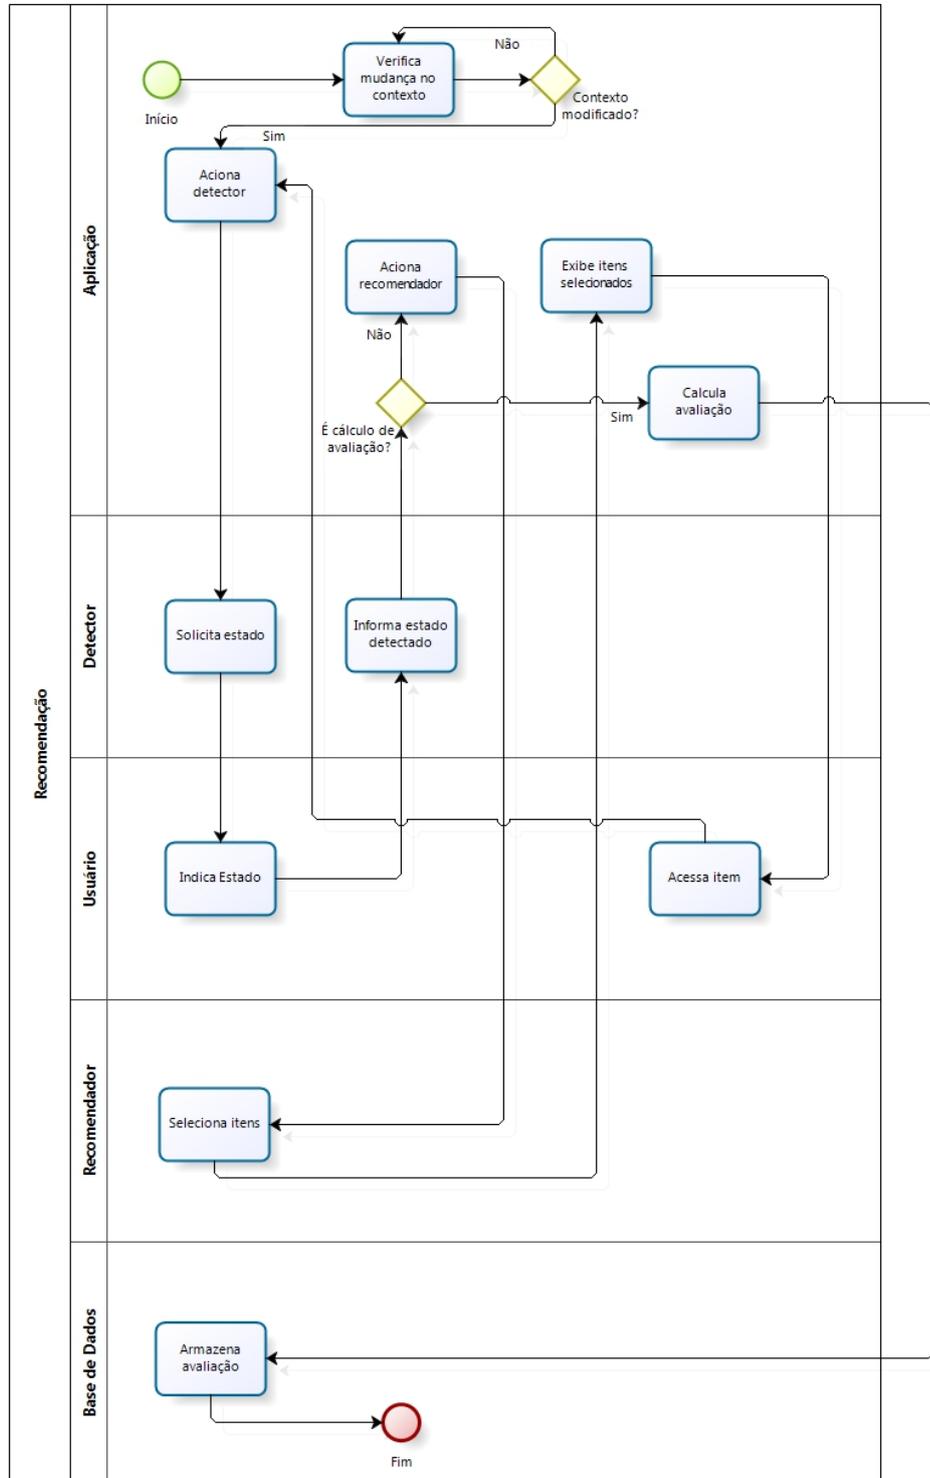


Figura A.1 – Fluxo do Sistema

APÊNDICE B – Questionário aplicado aos alunos

1. Consigo informar meu estado emocional (como eu me sinto) a partir do botão da “face amarela” que aparece no Moodle
 - (a) Concordo totalmente
 - (b) Concordo em parte
 - (c) Discordo em parte
 - (d) Discordo totalmente

2. Percebo que meu estado emocional se altera dependendo do material didático estudado
 - (a) Concordo totalmente
 - (b) Concordo em parte
 - (c) Discordo em parte
 - (d) Discordo totalmente

3. Quanto mais eu gosto de um material didático, mais feliz eu fico em estudar ele
 - (a) Concordo totalmente
 - (b) Concordo em parte
 - (c) Discordo em parte
 - (d) Discordo totalmente

4. O item sugerido ao acessar a disciplina e os itens mais ao topo, quando eu clico em “visualizar todos os materiais”, são mais interessantes que os itens que aparecem mais abaixo.
 - (a) Concordo totalmente
 - (b) Concordo em parte
 - (c) Discordo em parte
 - (d) Discordo totalmente

5. Em relação ao número de vezes que o botão (face amarela) aparece no Moodle, para indicar como me sinto, eu julgo que:

- (a) O botão aparece muitas vezes
 - (b) O botão aparece um número bom de vezes
 - (c) O botão aparece poucas vezes
6. Ocorreu de meu estado emocional mudar e o botão não aparecer para que eu pudesse informá-lo
- (a) Concordo totalmente
 - (b) Concordo em parte
 - (c) Discordo em parte
 - (d) Discordo totalmente
7. Tenho vontade de estudar conteúdos diferentes com base em meu estado emocional (como estou me sentindo)
- (a) Concordo totalmente
 - (b) Concordo em parte
 - (c) Discordo em parte
 - (d) Discordo totalmente
8. Gostaria de utilizar o botão da “face amarela” em todas as disciplinas que participo/participarei no Ambiente Moodle
- (a) Concordo totalmente
 - (b) Concordo em parte
 - (c) Discordo em parte
 - (d) Discordo totalmente
9. Acesso o Ambiente Moodle apenas quando tenho vontade de estudar os materiais ou fazer atividades
- (a) Concordo totalmente
 - (b) Concordo em parte
 - (c) Discordo em parte

(d) Discordo totalmente

10. Geralmente tenho dúvidas sobre qual conteúdo estudar. Logo, acho interessante usar um sistema que recomende um conteúdo que provavelmente irei gostar mais

(a) Concordo totalmente

(b) Concordo em parte

(c) Discordo em parte

(d) Discordo totalmente

11. Meu estado emocional (como me sinto) altera a minha disposição para a aprendizagem

(a) Concordo totalmente

(b) Concordo em parte

(c) Discordo em parte

(d) Discordo totalmente

12. Caso julgue necessário, utilize este espaço para expor sua opinião sobre a recomendação (sugestão) de materiais didáticos com base em como o estudante se sente, e da utilização do botão (face amarela) para informar o estado emocional

APÊNDICE C – Respostas dos Formulários por Disciplina

Tabela C.1 – Respostas Formulário - *Disciplina 1*: Educação em Ciências Agrárias Mediada por Tecnologia da Comunicação e Informação, do Curso de Medicina Veterinária

	1	2	3	4	5	6	7	8	9	10	11
Média	3,33	2,83	3,83	3,33	0,52	1,83	3,33	2,5	3,33	2,83	3,5
Desvio Padrão	0,52	1,17	0,41	0,52	0,52	0,98	1,21	1,22	0,82	1,17	1,22
Moda	3	3	4	3	2	1	4	3	4	3	4

Tabela C.2 – Respostas Formulário - *Disciplina 2*: Educação em Ciências Agrárias Mediada por Tecnologia da Comunicação e Informação, do Curso Superior de Tecnologia em Alimentos

	1	2	3	4	5	6	7	8	9	10	11
Média	3	2,47	3,27	2,53	1,33	1,73	2,53	2,07	2,6	2,71	2,87
Desvio Padrão	1,07	0,99	0,96	0,83	0,62	0,96	1,06	1,1	1,18	0,99	0,83
Moda	4	2	4	3	1	1	3	1	3	3	3

Tabela C.3 – Respostas Formulário - *Disciplina 3*: Informática Aplicada a Processos Químicos, do Curso Superior de Tecnologia em Processos Químicos.

	1	2	3	4	5	6	7	8	9	10	11
Média	3,41	2,95	3,59	2,32	1,54	1,82	3,09	2,41	2,86	2,90	3,5
Desvio Padrão	0,8	0,78	0,67	0,78	0,74	1,01	0,97	1,22	0,89	1,19	0,74
Moda	4	3	4	2	1	1	4	1	3	4	4

APÊNDICE D – Porcentagem de Ocorrências de cada Estado Afetivo

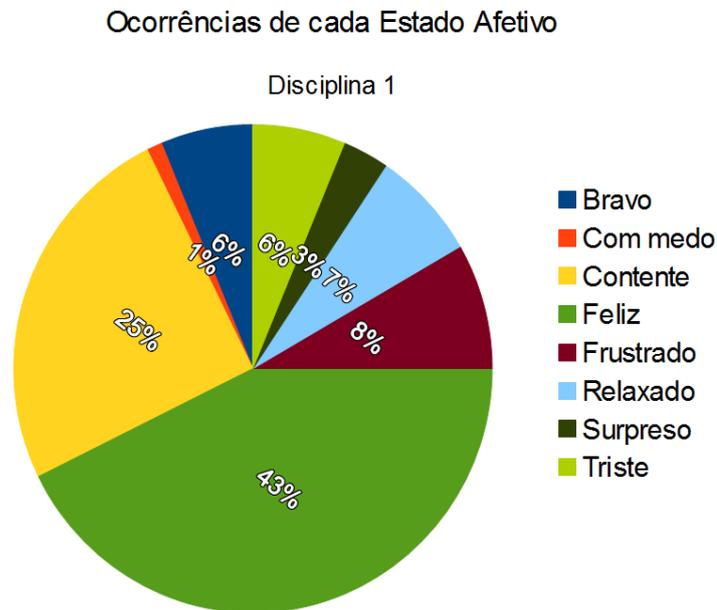


Figura D.1 – Ocorrências de Cada Estado Afetivo - *Disciplina 1*: Educação em Ciências Agrárias Mediada por Tecnologia da Comunicação e Informação, do Curso de Medicina Veterinária

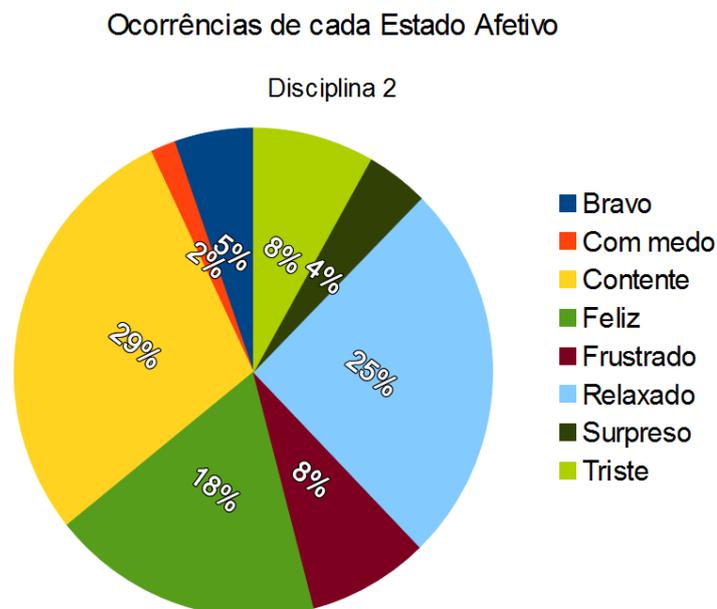


Figura D.2 – Ocorrências de Cada Estado Afetivo - *Disciplina 2*: Educação em Ciências Agrárias Mediada por Tecnologia da Comunicação e Informação, do Curso Superior de Tecnologia em Alimentos

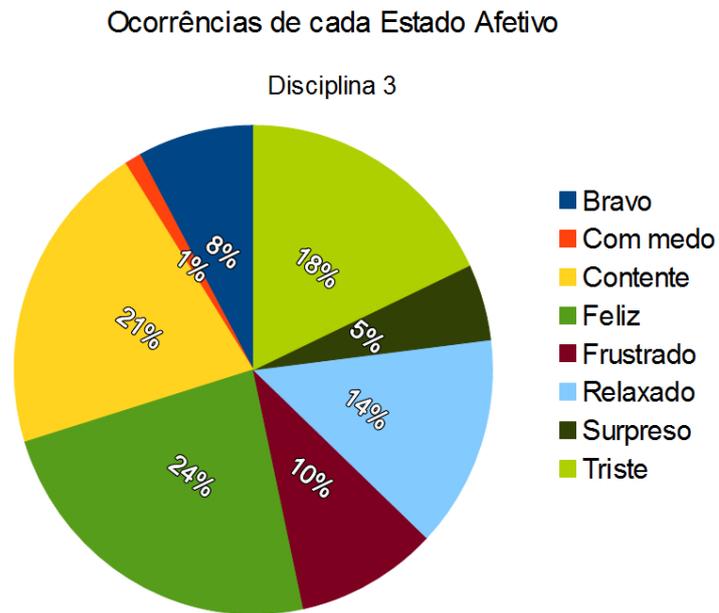


Figura D.3 – Ocorrências de Cada Estado Afetivo - *Disciplina 3*: Informática Aplicada a Processos Químicos, do Curso Superior de Tecnologia em Processos Químicos.

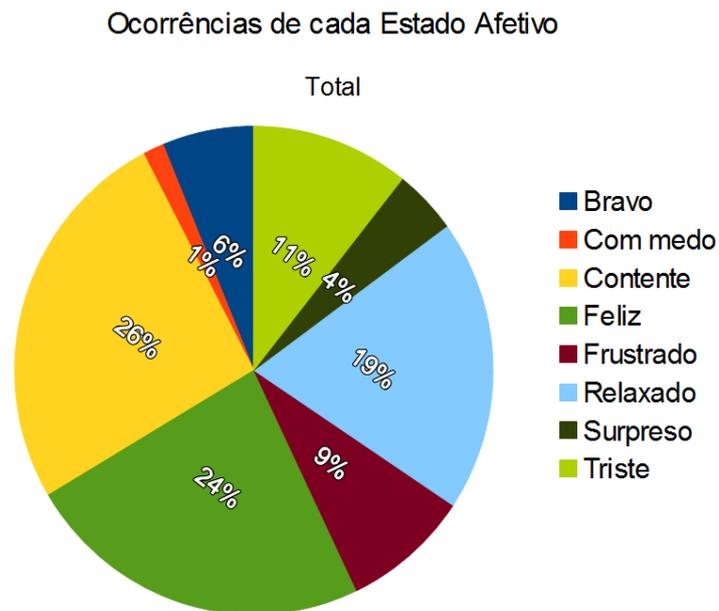


Figura D.4 – Ocorrências de Cada Estado Afetivo - Total

APÊNDICE E – Número de Reações para cada Estado

Tabela E.1 – Número de Reações por Estado Afetivo - *Disciplina 1*: Educação em Ciências Agrárias Mediada por TCI, do Curso de Medicina Veterinária

	Bravo	Com medo	Contente	Feliz	Frustrado	Relaxado	Surpreso	Triste
Bravo	0	0	0	0	0	0	0	0
Com medo	0	0	0	1	0	0	0	0
Contente	0	0	1	1	1	0	0	1
Feliz	0	1	2	5	1	0	1	0
Frustrado	0	0	0	0	0	0	0	0
Relaxado	0	0	0	1	0	1	0	0
Surpreso	0	0	1	0	1	0	0	0
Triste	0	0	0	0	0	0	0	0

Tabela E.2 – Número de Reações por Estado Afetivo - *Disciplina 2*: Educação em Ciências Agrárias Mediada por TIC, do Curso Superior de Tecnologia em Alimentos

	Bravo	Com medo	Contente	Feliz	Frustrado	Relaxado	Surpreso	Triste
Bravo	3	0	1	1	4	0	0	2
Com medo	0	0	0	0	0	0	1	0
Contente	2	0	20	4	6	11	2	0
Feliz	1	0	5	18	2	0	1	0
Frustrado	0	0	6	0	0	2	0	6
Relaxado	1	0	6	0	2	16	2	3
Surpreso	0	0	1	2	1	1	0	0
Triste	0	2	0	0	2	2	0	3

Tabela E.3 – Número de Reações por Estado Afetivo - *Disciplina 3: Informática Aplicada a Processos Químicos*, do Curso Superior de Tecnologia em Processos Químicos.

	Bravo	Com medo	Contente	Feliz	Frustrado	Relaxado	Surpreso	Triste
Bravo	4	0	0	1	1	2	0	0
Com medo	0	0	1	1	0	0	0	1
Contente	2	0	7	3	2	0	1	1
Feliz	1	0	7	13	2	1	2	2
Frustrado	2	1	0	0	0	4	0	1
Relaxado	0	0	2	0	1	2	4	9
Surpreso	0	0	0	2	1	4	0	0
Triste	3	0	0	3	4	4	0	4