
**Recomendação de Estratégias Pedagógicas
Baseada em Emoções e Perfis de Personalidade
em Ambientes Virtuais 3D**

Adilmar Coelho Dantas



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE COMPUTAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Adilmar Coelho Dantas

**Recomendação de Estratégias Pedagógicas
Baseada em Emoções e Perfis de Personalidade
em Ambientes Virtuais 3D**

Dissertação de mestrado apresentada ao Programa de Pós-graduação da Faculdade de Computação da Universidade Federal de Uberlândia como parte dos requisitos para a obtenção do título de Mestre em Ciência da Computação.

Área de concentração: Inteligência Artificial

Orientador: Márcia Aparecida Fernandes

Uberlândia
2016

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Bibliotecas da UFU, MG, Brasil.

D192r
2016

Dantas, Adilmar Coelho, 1992-
Recomendação de estratégias pedagógicas baseada em emoções e
perfis de personalidade em ambientes virtuais 3D / Adilmar Coelho
Dantas. - 2016.
97 f. : il.

Orientadora: Márcia Aparecida Fernandes.
Dissertação (mestrado) - Universidade Federal de Uberlândia,
Programa de Pós-Graduação em Ciência da Computação.
Inclui bibliografia.

1. Computação - Teses. 2. Inteligência emocional - Teses. 3. Ensino
auxiliado por computador - Teses. I. Fernandes, Márcia Aparecida. II.
Universidade Federal de Uberlândia. Programa de Pós-Graduação em
Ciência da Computação. III. Título.

CDU: 681.5

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE COMPUTAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Os abaixo assinados, por meio deste, certificam que leram e recomendam para a Faculdade de Computação a aceitação da qualificação de doutorado intitulada "**Recomendação de Estratégias Pedagógicas Baseada em Emoções e Perfis de Personalidade em Ambientes Virtuais 3D**", por **Adilmar Coelho Dantas**, como parte dos requisitos exigidos para a obtenção do título de **Mestre em Ciência da Computação**.

Uberlândia, 15 de dezembro de 2016.

Orientador: _____

Prof.^a Dra. Márcia Aparecida Fernandes
Universidade Federal de Uberlândia

Banca Examinadora:

Prof. Dr. Renan Gonçalves Cattelan
Universidade Federal de Uberlândia

Prof. Dr. Sergio Crespo Pinto
Universidade Federal Fluminense

À minha mãe pelo amor incondicional, apoio e carinho em todos os momentos de minha vida.

Agradecimentos

Inicio meus agradecimentos primeiramente a Deus por ter me proporcionado esse feito em minha vida, à minha mãe, **Márcia**, por sempre ter acreditado e me dado forças sempre que precisei.

Ao professor **Eduardo Takahashi**, que sempre me guiou através de seus conselhos, tanto academicamente como na vida, sempre me ouvindo e me ajudando quando necessário, que disponibilizou suas aulas para que muitos dos testes nelas fossem realizados.

Ao meu grande amigo **Marcel Klammer**, da Universidade Leipzig na Alemanha, que sempre me ajudou solucionando minhas dúvidas de programação, mesmo que a distância, e as vezes até mesmo atrapalhando seus projetos.

À minha orientadora **Márcia Fernandes** por ter acreditado em mim e nas minhas potencialidades acadêmicas e por ter me guiado neste e em outros tantos projetos de forma direta e indireta.

Agradeço à **Faculdade de Computação (FACOM)** por ter sempre disponibilizado os melhores professores, funcionários para que este trabalho ocorresse com sucesso, ao funcionário **Erisvaldo**, pela paciência e agilidade sempre que precisei.

A todos meus amigos do **NUTEC** que sempre me suportaram em especial ao meu grande amigo **Hermes**; aos meus amigos do **PET Biomédica** e minha amiga **Núbia** que sempre esteve ao meu lado me apoiando e dando total apoio. A minha amiga de mestrado **Sara** com a qual passei boa parte do tempo, do início ao fim, nas vitórias e nas dificuldades, a **Mayumi** por todo apoio e compreensão dedicados no início deste trabalho.

Agradeço, também, à **CAPES** pelo apoio financeiro dedicado a este projeto, mesmo em momentos de crise em nosso país e com tantos cortes na Educação.

Finalmente, gostaria de agradecer à **Universidade Federal de Uberlândia** por ter me proporcionado amplo acesso aos laboratórios, espaço físico e todo apoio acadêmico necessário para o desenvolvimento deste trabalho.

“Faça o dia valer as lembranças”
(Bill Gates)

Resumo

As emoções produzem interferências de maneira direta e indireta no processo de aprendizagem. Estudantes que estão em uma emoção desfavorável ao aprendizado tendem a ter dificuldades de absorção do conteúdo que é proposto naquele momento. Neste sentido, esse trabalho propõe um módulo capaz de detectar e classificar essas emoções e, através de um segundo módulo de raciocínio baseado em casos, sugerir recomendações pedagógicas através dos perfis de personalidades com a finalidade de desenvolver o perfil afetivo do estudante em Ambientes Virtuais de Aprendizagem. Para validar computacionalmente o trabalho, primeiro verificou-se qual técnica obteria melhores resultados para detectar os movimentos da face e, em seguida, qual algoritmo classificador obteria melhores resultados para esta classificação. Nesse caso, a técnica Árvore de Decisão se demonstrou eficiente com uma taxa média de 86,4% de acurácia. O mesmo foi avaliado em imagens e em vídeos para garantir a aplicabilidade do mesmo. Após este processo, utilizou-se dos perfis de personalidade junto com a técnica de Raciocínio Baseado em Casos para sugerir recomendações pedagógicas através da associação das emoções e dos perfis de personalidade durante o processo de ensino e aprendizagem dos estudantes. Assim, a todo momento o estudante está sendo acompanhado e, ao detectar uma emoção prejudicial ao aprendizado, são executadas essas instruções vistas nos módulos propostos para que se forneça recomendações pedagógicas. A partir dessas informações adquiridas do estudante, é possível oferecer a ele o estímulo e/ou motivação de acordo com suas características individuais, consequentemente, aproximando-o da emoção que promova a aprendizagem de maneira significativa.

Palavras-chave: Computação Afetiva. Inteligência Emocional. Personalidade. Emoções. Ambientes Virtuais de Aprendizagem.

Abstract

Emotions are key part of the process of teaching and learning in general, directly or indirectly. Students with an unfavorable emotion to learning tend to have difficulties in absorbing the content that is suggested at that time. This work proposes an module that is able to detect and classify those emotions and, through a second logic module based on facts, suggests educational recommendations using Personality Profiles in order to develop the student affective profile in Virtual Learning Environments (VLE). To computationally validate this work, first, it was observed which technique would present better results to detect the Action Units and then, which algorithm would show better results for this classification. In this last case, the decision tree showed itself as an effective method with an average rate of 86,4%. This method was evaluated by images and videos to ensure its applicability. After this process, it was used the Personality Profiles along with the Case-Based Reasoning to suggest pedagogical recommendations through emotions association and the personality profiles during the process of teaching and student learning. In this way, the student is being monitored all the time and, when a harmful emotion is detected, these instructions proposed in this work are executed in order to provide educational recommendation and offer him encouragement and/or motivation according to his individual characteristics. This brings the student closer to his emotions and improves learning significantly .

Keywords: Affective computing. Emotional Inteligence. Personality. Emotions. Virtual Learning Environments.

Listas de ilustrações

Figura 1 – Emoção surpresa classificada por (KANADE; COHN, 2005) com as combinações das UA's 1+2+5+27.	28
Figura 2 – Representação das Unidades de Movimento a partir das Unidades de Ação.	29
Figura 3 – Ramificação para o cálculo de ganho do atributo Distância3.	35
Figura 4 – Árvore de decisão final para a classificação da emoção alegria.	36
Figura 5 – Modelo de um RBC	37
Figura 6 – Exemplo de uma base de casos	38
Figura 7 – Ambiente Virtual de Aprendizado 3D <i>River City</i> da Universidade de Harvard.	40
Figura 8 – Estrutura geral do EPEP para a recomendação de estratégias pedagógicas em ambientes virtuais de aprendizagem.	48
Figura 9 – Características Haar Cascade	49
Figura 10 – Representação do modelo em cascata com Adaboost	50
Figura 11 – Máscara facial com os 12 pontos inseridos nas regiões de interesse	50
Figura 12 – Representação da Árvore de Decisão para classificação das emoções.	52
Figura 13 – Diagrama: Módulo de detecção de emoções integrado ao ambiente Moodle	53
Figura 14 – Módulo de detecção de emoções integrado ao Moodle.	54
Figura 15 – Relatório gráfico das emoções gerado no ambiente.	54
Figura 16 – Ambiente inicial com as ilhas baseadas em inteligências múltiplas.	55
Figura 17 – Ilha desenvolvida para a inteligência múltipla textual.	56
Figura 18 – Ilha desenvolvida para a inteligência múltipla visual.	56
Figura 19 – Ilha desenvolvida para a inteligência múltipla lógico-matemática.	56
Figura 20 – Ilha desenvolvida para a inteligência corporal-cinestésica.	57
Figura 21 – Diagrama: Modelagem dos objetos de aprendizagem em 3D.	58
Figura 22 – Lousa digital para o ambiente virtual 3D.	59
Figura 23 – Sala de aula modelada em 3D.	59
Figura 24 – Vestuário desenvolvido para o ambiente.	60

Figura 25 – Interface para a visualização da base do Raciocínio Baseado em Casos (RBC).	63
Figura 26 – Interface de entrada de dados para o RBC.	63
Figura 27 – Interface de entrada de dados para o RBC.	64
Figura 28 – Taxa de Reconhecimento usando Árvore de Decisão e Unidades de Movimento (UM) na base de imagens Cohn Kanade.	66
Figura 29 – Taxa de Reconhecimento usando contorno facial e Support Vector Machine (SVM) na base de imagens Cohn Kanade.	67
Figura 30 – Taxa de Reconhecimento usando Árvore de Decisão e UM na base de imagens MUG.	68
Figura 31 – Taxa de Reconhecimento usando contorno facial e SVM na base de imagens MUG.	68
Figura 32 – Taxa de Reconhecimento em vídeos usando UM e Árvore de Decisão na base Cohn Kanade.	70
Figura 33 – Taxa de Reconhecimento em vídeos usando contorno facial e SVM na base Cohn Kanade.	70
Figura 34 – Taxa de Reconhecimento em vídeos usando contorno facial e SVM na base MUG.	71
Figura 35 – Taxa de Reconhecimento em vídeos usando contorno facial e SVM na base MUG.	71
Figura 36 – Taxa de Reconhecimento em imagens usando UM na base MUG sem tratamento de oclusões.	72
Figura 37 – Resultado da classificação de perfil para 300 simulações no módulo RBC.	74
Figura 38 – Resultado da classificação da inteligência múltipla para 300 simulações no módulo RBC.	74
Figura 39 – Regras associadas ao perfil para a base de casos retida no RBC.	75
Figura 40 – Inteligências múltiplas associadas ao perfil para a base de casos retida no RBC.	75
Figura 41 – Regras associadas ao perfil para 300 simulações no RBC.	76
Figura 42 – Inteligências múltiplas associadas ao perfil para 300 simulações no RBC.	76

Lista de tabelas

Tabela 1 – Exemplo de treino para classificar a emoção alegria.	35
Tabela 2 – Ganhos obtidos a partir dos atributos.	35
Tabela 3 – Principais trabalhos correlatos e suas contribuições.	44
Tabela 4 – Unidades de Movimento associadas a Unidades de Ação. (AZCARATE et al., 2005)	51
Tabela 5 – Pontos utilizados para o cálculo das distâncias euclidianas para cada uma das emoções.	51
Tabela 6 – Resumo de características e atividades para estimular as inteligências Múltiplas.	57
Tabela 7 – Base de conhecimentos inicial	61
Tabela 8 – Condições para o cálculo da distância usando Lógica Fuzzy.	62
Tabela 9 – Exemplo de execução RBC	62
Tabela 10 – Total de imagens por emoção da base Cohn Kanade.	66
Tabela 11 – Total de imagens por emoção da base MUG.	67
Tabela 12 – Quantidade de vídeos gerados a partir das bases de imagens Cohn Kanade e MUG.	69
Tabela 13 – Total de imagens por emoção obtidas para o treinamento de oclusões .	72
Tabela 14 – Total de casos retidos por perfil na base do RBC.	73

Lista de siglas

AVA Ambientes Virtuais de Aprendizagem

EAD Educação a Distância

FACS Facial Action Coding System

IM Inteligência Múltipla

JSF JavaServer Faces

LSL Linguagem de Scripts do Second Life

RBC Raciocínio Baseado em Casos

RIA Rich Internet Applications

SVM Support Vector Machine

UA Unidades de Ação

UM Unidades de Movimento

Sumário

1	INTRODUÇÃO	23
1.1	Motivação	24
1.2	Objetivos e Desafios da Pesquisa	25
1.3	Hipóteses	25
1.4	Contribuições	26
1.5	Organização da Dissertação	26
2	FUNDAMENTAÇÃO TEÓRICA	27
2.1	Emoções Através de Expressões Faciais	27
2.2	Técnicas de Inteligência Artificial	29
2.2.1	Indução de Árvores de Decisão	29
2.2.2	Construção de Árvore de Decisão	31
2.2.3	Algoritmo <i>ID3</i>	33
2.2.4	Raciocínio Baseado em Casos (RBC)	35
2.3	Ambientes Virtuais de Aprendizagem 3D	38
2.4	Trabalhos Correlatos	41
3	PROPOSTA	47
3.1	Estrutura do (EPEP)	47
3.2	Módulo Detecção de Emoções	48
3.2.1	Detecção da Face	48
3.2.2	Detecção das Unidades de Movimento	50
3.2.3	Classificação das Emoções	52
3.2.4	Integração ao Ambiente Moodle	53
3.3	Ambiente Virtual de Aprendizagem 3D	55
3.3.1	Modelagem dos Objetos 3D	58
3.4	Módulo Raciocínio Baseado em Casos	60
3.4.1	Desenvolvimento da Base de Conhecimentos	60

3.4.2	Cálculo da Similaridade	61
3.4.3	Interface de comunicação com o RBC	63
4	EXPERIMENTOS E ANÁLISE DOS RESULTADOS	65
4.0.1	Testes de acurácia com imagens na base Cohn Kanade e MUG.	65
4.0.2	Testes de acurácia em vídeos gerados a partir da base Cohn Kanade e MUG.	69
4.0.3	Testes em ambientes reais para o tratamento de oclusões	70
4.0.4	Testes realizados no módulo RBC	72
5	CONSIDERAÇÕES FINAIS	79
5.1	Principais Contribuições	80
5.2	Trabalhos Futuros	81
REFERÊNCIAS		83
APÊNDICES		89
APÊNDICE A	– CASOS RETIDOS COM A SIMULAÇÃO PARA O PERFIL	91
APÊNDICE B	– CASOS RETIDOS COM A SIMULAÇÃO PARA AS INTELIGÊNCIAS MÚLTIPLAS	93

CAPÍTULO 1

Introdução

Em meio a uma sociedade cada vez mais interconectada tecnologicamente, onde as informações são facilmente acessíveis, os cursos de Educação a Distância (EAD) e ambientes virtuais tridimensionais são criados e difundidos rapidamente por meio da internet (ALVES, 2003), levando conhecimento para as regiões mais afastadas do mundo. Até mesmo instituições conceituadas aderiram a esse novo conceito e passaram a oferecer esse tipo de ambiente tridimensional de estudo, de maneira parcial ou integral. O desenvolvimento e o acesso a ambientes tridimensionais atualmente vêm se tornando comum, principalmente entre adolescentes, graças aos avanços exponenciais dos recursos computacionais e da velocidade de conexão (SANCHES; SILVA; TORI, 2010).

Embora o interesse maior das comunidades online esteja voltado ao entretenimento, algumas iniciativas procuram explorar o fato de pessoas compartilharem um espaço, mesmo que virtual, para produzir alternativas aos métodos tradicionais de EAD. Esse fato, somado a pesquisas que apontam para a viabilidade da utilização de recursos computacionais (GRINGS; TREIN; OLIVEIRA, 2009), têm provocado o surgimento de um número cada vez maior de ferramentas de apoio ao ensino e aprendizagem, baseadas em ambientes 3D multiusuários.

Uma série de vantagens cognitivas podem ser obtidas quando se utilizam ambientes virtuais tridimensionais como interface para acesso a objetos de aprendizagem. Entre elas, cabe destacar o fato de estruturas espaciais serem mais facilmente interpretadas pela maioria das pessoas; a maior facilidade de orientação em navegações baseadas em ambientes 3D (em comparação com estruturas baseadas em ícones e menus convencionais) e a interação direta com objetos (o usuário pode pegá-los, como se faz no mundo real) (TORI, 2002).

Essa maior naturalidade na realização de tarefas no ambiente pode evitar uma sobrecarga cognitiva do usuário (TORI, 2002). Segundo (HAANS; IJSELSTEIJN, 2007), o cérebro humano assimila facilmente objetos externos como extensões de si próprio, o que explica a maior sensação de presença do usuário no ambiente de ensino comparado com as interfaces convencionais, quando esse controla um avatar (TORI, 2002).

A computação afetiva investiga como extrair características emocionais e sociais de indivíduos, tais como, reconhecer automaticamente as emoções, e, por conseguinte, permitem reagir a essas emoções de maneira positiva. Assim, pesquisas sobre a detecção, e classificação, das emoções dos estudantes em sistemas tutores inteligentes (STI) vêm sendo desenvolvidas com o objetivo de observar o estudante, motivando-o com base nas emoções. Os STIs e a computação Afetiva podem auxiliar em propostas de soluções, para os grandes desafios em educação, através de métodos e técnicas que permitem desenvolver programas para assistência individualizada e inteligente ao estudante, proporcionando maior interação social (JAQUES et al., 2012).

As emoções podem ser utilizadas para proporcionar melhores formas de efetuar uma comunicação humano-computador. Nessa perspectiva, a computação afetiva pode aprimorar esse processo em várias dimensões. Um exemplo de aplicabilidade em um curso voltado a computador, onde os estudantes, com o auxílio de uma *webcam*, que captura as expressões faciais deles, mapeando suas emoções. Dessa maneira é possível inferir como será um melhor método de ensino aplicado ao estudante, adaptando o conteúdo para o estudante, baseado em seu perfil emocional num determinado momento.

1.1 Motivação

De acordo com (ARRUDA, 2012) é a emoção que desencadeia uma ação do sujeito, ao se constituir no fundamento da razão, determinando a “estratégia em relação à construção de nossos argumentos e de nossas conversações”. Ainda, segundo Arruda (2012), o papel mediador do professor no processo de ensino-aprendizagem atribui maior ênfase ao processo dialógico (conversação), no qual são produzidos novos conhecimentos de forma conjunta entre educador e educando. Assim, cabe ao professor o papel de mediador de emoções em um processo interativo e o reconhecimento das manifestações emotivas do estudante pode contribuir para explorar aspectos que interferem no sucesso ou fracasso de uma aprendizagem.

Os trabalhos de (GOLEMAN, 1995) e (CHABOT, 2005) presentam as relações das emoções com a cognição, atenção, sucesso profissional e aprendizagem. Tomando como base o trabalho de (KORT; REILLY; PICARD, 2001) que apresenta um modelo do estudante, levando em consideração as emoções básicas, indicando assim um estado emocional favorável para o processo de ensino e aprendizagem. Com o objetivo de incorporar os aspectos motivacionais, tomando como base as emoções, o trabalho de (JAQUES; VICARI, 2005) propõe um modelo que leva em consideração as emoções apresentadas pelo estudante no sistema. Assim, ao se detectar uma emoção desfavorável ao processo de aprendizagem, é ativado um agente pedagógico, o qual através de mensagens irá encorajar o estudante durante o processo de ensino e aprendizagem. A todo momento essas mensagens são exibidas para o estudante de forma generalizada, tomando como base seus próprios aspectos

emocionais.

Com essas observações, tem-se a chance de trabalhar individualmente os estímulos/motivações fornecidos ao estudante, através da relação entre seu perfil de personalidade e suas emoções e assim, consequentemente, aproximar o mesmo da emoção favorável ao aprendizado (alegria). Assim, este trabalho propõe a recomendação de estratégias pedagógicas baseadas em emoções e perfis de personalidade, objetivando identificar o perfil do estudante, levando em consideração seus aspectos emocionais que serão incorporados aos ambientes virtuais de aprendizagem.

1.2 Objetivos e Desafios da Pesquisa

O objetivo deste trabalho é desenvolver um ambiente virtual 3D com suporte para a detecção dinâmica das emoções inferidas pelo estudante. Além disso, realizar a integração em ambiente virtual de aprendizagem para que, de acordo com as interações do usuário e suas emoções, seja capaz de identificar o modelo do estudante durante o processo de aprendizagem.

Para que esse objetivo seja alcançado será necessário satisfazer os seguintes objetivos específicos:

1. Desenvolver um módulo classificador de emoções (alegria, tristeza, raiva, medo, desgosto, surpresa) com técnicas de aprendizagem de máquina que sejam capazes de classificar as emoções em tempo real.
2. Integrar o módulo classificador de emoções ao Moodle.
3. Desenvolver e integrar o mundo virtual 3D ao ambiente virtual Moodle.
4. Desenvolver e integrar objetos de aprendizagem ao mundo virtual 3D.
5. Desenvolver um módulo de Raciocínio Baseado em Casos (RBC) para recomendações pedagógicas baseadas em emoções e perfis de personalidade.
6. Testar e avaliar o módulo de classificação de emoções e o módulo RBC integrado ao ambiente virtual 3D.

1.3 Hipóteses

- ❑ É possível classificar dinamicamente as emoções em ambientes virtuais de aprendizagem, utilizando as expressões faciais.
- ❑ É possível desenvolver um mundo virtual 3D onde se é capaz de analisar as emoções dos usuários e ao mesmo tempo verificar as inteligências múltiplas inferidas durante o processo de aprendizagem.

- Através de técnicas de inteligência artificial será possível classificar automaticamente as emoções durante o processo de ensino e aprendizagem, além de fornecer recomendações pedagógicas adequadas para o aluno, com o objetivo de estimular suas habilidades de aprendizagem.

1.4 Contribuições

Uma vez que os objetivos descritos na Seção 1.2 forem alcançados, bem como a confirmação das hipóteses apresentadas na Seção 1.3, as principais contribuições deste trabalho são:

- Um módulo classificador de emoções para ambientes virtuais de aprendizagem, que possa colaborar de maneira significativa para a construção do modelo do estudante baseado em suas emoções durante o processo de aprendizagem e levando em consideração seu perfil de personalidade.
- A avaliação de técnicas computacionais para a detecção e classificação de emoções em ambientes virtuais de aprendizagem.
- Um módulo de RBC, que baseado nas emoções forneça recomendações pedagógicas em ambientes virtuais de aprendizagem, sendo também capaz de construir e reter novos casos a partir da base inicial para o crescimento da base de conhecimento do RBC.

1.5 Organização da Dissertação

- **Capítulo 2:** Introduz os principais conceitos para a compreensão e validação do trabalho proposto e apresenta os trabalhos correlatos com a proposta do mesmo.
- **Capítulo 3:** Descreve o trabalho proposto para se chegar à recomendação de estratégias pedagógicas baseadas nas emoções e perfis de personalidade em ambientes virtuais de aprendizagem.
- **Capítulo 4:** Apresenta os resultados e as respectivas análises do módulo responsável pela detecção e classificação automática de emoções, e para o módulo de Raciocínio Baseado em Casos a partir das emoções e perfis de personalidade, propostos neste trabalho.
- **Capítulo 5:** São apresentados os principais resultados, considerações finais e trabalhos futuros.

CAPÍTULO 2

Fundamentação Teórica

Neste trabalho foram desenvolvidos três módulos: o primeiro, responsável por detectar e classificar as emoções inferidas do estudante em ambientes virtuais de aprendizagem; o segundo módulo é um ambiente virtual de aprendizagem 3D projetado e desenvolvido para capturar as emoções do estudante e extrair características; o terceiro é composto por um Raciocínio Baseado em Casos (RBC) para que a partir das emoções adquiridas no primeiro processamento possa ser combinado com outras características propostas por outros autores como, por exemplo, o perfil de personalidade do estudante, para que então ele possa determinar recomendações pedagógicas dentro dos ambientes virtuais de aprendizagem.

Assim, a Seção 2.1 descreve as teorias emocionais utilizadas neste trabalho. Na Seção 2.2 são descritas as técnicas de inteligência artificial utilizadas para o desenvolvimento e validação deste trabalho. A Seção 2.3 apresenta o ambiente virtual de aprendizagem 3D utilizado nesta pesquisa. E por fim, na Seção 2.4 são apresentados os trabalhos correlatos com a proposta deste trabalho.

2.1 Emoções Através de Expressões Faciais

As emoções são a chave para proporcionar melhores formas de efetuar uma comunicação humano-computador. Nessa perspectiva, a computação afetiva pode aprimorar esse processo em várias dimensões. Um exemplo de aplicabilidade é em cursos a distância, onde as emoções dos estudantes, com o auxílio de uma webcam, podem ser reconhecidas através das expressões faciais. Dessa maneira é possível inferir como será um melhor modelo de ensino aplicado ao aluno, adaptando o conteúdo ao modelo do estudante, baseado em seu perfil emocional num determinado momento.

Darwin foi um dos primeiros naturalistas a estudar reconhecimento facial com seres humanos como fator social. Essas ideias de Darwin fizeram com que fossem desenvolvidas teorias sobre o reconhecimento de padrões com finalidade de auxiliar o ser humano em suas atividades (GARCIA, 2009). A partir destas ideias surgiu a teoria Facial Action

Coding System (FACS) (EKMAN; FRIESEN, 1978a). Nessa teoria comprova-se que existem emoções universais, expressas pelos seres humanos entre grupos sociais e raças distintas.

A teoria *FACS* criada por Ekman e Friesen (EKMAN; FRIESEN, 1978a) é um sistema abrangente, com base anatômica e menos sobrecarregado de noções teóricas do que os outros sistemas existentes. Ele descreve todos os possíveis movimentos faciais distintos visíveis, baseado em quarenta e quatro Unidades de Ação (UA). Cada UA tem seu código numérico e seus respectivos músculos, que são contraídos para cada movimento da face, onde cada UA foi cuidadosamente estudada, sendo que cada músculo representa uma ação facial que é mapeada através das UA's enumeradas de 1 a 44 (Exemplo: UA1 significa o levantamento da sobrancelha interna), sendo que a Tabela com a associação completa dessas UA's pode ser vista em (EKMAN; FRIESEN, 1978a).

Os eventos faciais codificados pelo FACS podem ser classificados em categorias emocionais e não-emocionais. O *EMotion FACS* (EMFACS) foi então criado para classificar os movimentos faciais em expressões faciais da emoção, baseado nas UA's do FACS (EKMAN; FRIESEN, 1978a). Tem-se na Figura 1 um exemplo de expressões frontais vistas a partir do banco de dados Cohn Kanade (KANADE; COHN, 2005). Cada sequência começa com uma expressão neutra e procede a uma expressão alvo. No exemplo da Figura 1, a expressão alvo é a *surpresa*.

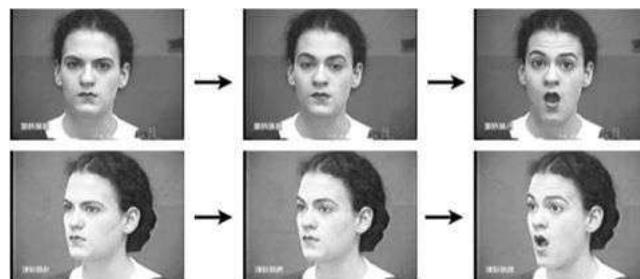


Figura 1 – Emoção surpresa classificada por (KANADE; COHN, 2005) com as combinações das UA's 1+2+5+27.

O EMFACS é um método objetivo que usa o FACS para responder somente às ações faciais relevantes para detectar uma emoção, mas possui um número menor de combinações de UA's, além de possuir uma versão modificada de regras e procedimentos de medição, provindas intencionalmente para diminuir o tempo de resposta quando o interesse é somente classificar as emoções da face.

No trabalho de (AZCARATE et al., 2005) é feita uma associação entre as UA's e Unidades de Movimento (UM), porém, as UM's reconhecidas neste trabalho são semelhantes às UA's propostas por (EKMAN; FRIESEN, 1978a) e não equivalentes. Assim, o módulo de detecção de pontos na face para o reconhecimento das emoções terá como base as UM's expostas no trabalho de (AZCARATE et al., 2005).

Segundo (AZCARATE et al., 2005) as Unidades de Movimento (UM) são pontos associados com as Unidade de Ação propostas por (EKMAN; FRIESEN, 1978a). Esses pontos projetados na face do estudante possuem coordenadas (x , y , z), as quais podem ser utilizadas para realizar cálculos para se obter uma determinada informação. Neste trabalho essas coordenadas foram utilizadas para o cálculo das distâncias euclidianas para saber se uma determinada UM foi ativada durante o processo de ensino e aprendizagem. A Figura 2 mostra as Unidades de Ação associadas às Unidades de Movimento de maneira comparativa, demonstrando como o autor chegou a essa representação corretamente.



Figura 2 – Representação das Unidades de Movimento a partir das Unidades de Ação.

Adaptado de: (SAHYOUN, 2016).

Observando a Figura, nota-se que os pontos são projetados na face utilizando as Unidades de Movimento, e estas estão localizadas em regiões dos respectivos músculos presentes nas Unidades de Ação, explicando assim a sua equivalência com as mesmas.

2.2 Técnicas de Inteligência Artificial

2.2.1 Indução de Árvores de Decisão

O processo de indução em árvores de decisão é uma das formas mais simples e mais bem-sucedidas de algoritmos de aprendizagem. Uma árvore de decisão toma como entrada um objeto ou situação descrita por um conjunto de atributos e retorna uma decisão, ou seja, o valor de saída previsto, de acordo com sua entrada. Uma árvore de decisão alcança sua decisão executando uma sequência de testes. Cada nó interno na árvore corresponde a um teste do valor de uma das propriedades e as ramificações, a partir do nó, são identificadas como os valores possíveis do teste. Cada nó de folha na árvore especifica o valor a ser retornado se aquela folha for alcançada. A representação de árvores de decisão parece ser muito natural para os seres humanos e utilizada em diversas áreas do conhecimento (RUSSELL; NORVIG, 2004).

Um ponto interessante sobre os seres humanos está relacionado à sua habilidade de fazer generalizações precisas a partir de fatos. O ser humano é capaz de encontrar estruturas ou padrões apenas observando um processo do mundo real. Em ciência da computação, essa habilidade pode ser obtida a partir de um conjunto de exemplos, fornecido pelo usuário ou um processo do mundo real, e por meio da inferência indutiva, a qual, mesmo sendo o recurso mais utilizado pelo cérebro na produção de um novo conhecimento, deve ser utilizada cuidadosamente (REZENDE, 2003).

Em sistemas orientados ao conhecimento, os resultados da indução por computador devem ser descrições simbólicas das entidades fornecidas sendo semântica e estruturalmente similares àquelas que um especialista humano poderia produzir observando as mesmas entidades. Os componentes dessas descrições devem ser compreensíveis como simples “pedaços” de informação, diretamente interpretáveis em linguagem natural, bem como reportar conceitos qualitativos e quantitativos de maneira integrada (REZENDE, 2003).

Sistemas de Aprendizagem de Máquina que induzem classificadores podem descrever exemplos, hipóteses e conhecimento do domínio. Os algoritmos que induzem Árvores de Decisão pertencem à família de algoritmos *Top Down Induction of Decision Trees*(TDIDT). Uma Árvore de Decisão (AD) é uma estrutura de dados definida recursivamente como (REZENDE, 2003):

- Um nó folha que corresponde a uma classe ou
- Um nó de decisão que contém um teste sobre algum atributo. Para cada resultado do teste existe uma aresta para uma subárvore. Cada subárvore tem a mesma estrutura da árvore geradora.

Para (DURKIN, 1991), indução é o processo de raciocínio de um dado conjunto de fatos para princípios gerais ou regras. Indução é preciosa se existem exemplos para criar um processo decisório padrão. Como representação de hipótese, (QUINLAN, 1986) descreve a tarefa de indução como a capacidade de desenvolver regras de classificação que determinam a classe de qualquer objeto através dos valores de seus atributos. Os objetos são descritos em termos de uma coleção de atributos. Cada atributo mede alguma característica importante do objeto.

Cada objeto no universo (domínio da aplicação) pertence a um conjunto de classes mutuamente exclusivas e a classe de qualquer objeto do conjunto de treinamento é conhecida. Se o conjunto de treinamento contém dois objetos que têm valores idênticos para cada atributo e pertencem a classes diferentes, é claramente impossível a diferenciação entre esses objetos com referência somente aos seus dados atributos. E nesse caso, os atributos serão considerados inadequados para o conjunto de treinamento e, consequentemente, para a tarefa de indução (OLIVEIRA, 2001).

Segundo Thompson e Thompson (1986), um conflito ocorre quando dois exemplos contêm valores idênticos para todos os seus atributos, mas valores de classes diferentes.

Um conflito normalmente significa que os atributos escolhidos são inadequados para a tarefa de classificação. Pode-se remover esse problema introduzindo atributos adicionais, o que é uma tarefa para o especialista do domínio. Assim, indução de Árvores de Decisão consiste em exibir regras de classificação a serem expressas através de uma árvore de decisão, sendo a representação em árvore de decisão equivalente às regras de classificação (OLIVEIRA, 2001).

Dessa forma, segundo o mesmo autor, as folhas da árvore de decisão são os nomes de classe, os nós representam testes baseados nos atributos com ramos rotulados, com os possíveis valores do atributo, para um resultado de classificação. Para classificar um objeto, começa-se da raiz da árvore. Avalia-se o teste, ou seja, o nó da árvore é comparado com o respectivo atributo do objeto em questão, partindo pelo ramo determinado pelo valor do atributo do objeto que se pretende classificar, e o processo continua até que uma folha seja encontrada, evidenciando que o objeto pertence à classe nomeada pela folha.

Assim, a essência da indução é mover além do conjunto de treinamento, isto é, construir uma árvore de decisão que corretamente classifica não só objetos do conjunto de treinamento, mas outros (não vistos) objetos, sendo que para fazer isso, a árvore de decisão tem que capturar alguma relação significante entre a classe de um objeto e os valores de seus atributos.

2.2.2 Construção de Árvore de Decisão

O método para construção de uma árvore de decisão a partir de um conjunto de treinamento T é descrito a seguir. Assumindo que as classes sejam denotadas por C_1, C_2, \dots, C_k , os seguintes passos devem ser seguidos (REZENDE, 2003):

1. T contém um ou mais exemplos, todos pertencentes à mesma classe C_j . Nesse caso, a árvore de decisão T é um nó folha identificando a classe C_j ;
2. T não contém exemplos. Novamente, nessa situação, a árvore é uma folha mas a classe associada à folha deve ser determinada a partir de informação além de T . Por exemplo, a classe mais frequente para o nó pai desse nó pode ser utilizada;
3. T contém exemplos que pertencem a várias classes. Nesse caso, a ideia é refinar T em subconjuntos de exemplos que são – ou aparentam ser – conjuntos de exemplos pertencentes a uma única classe.

Normalmente, um teste é escolhido baseado em um único atributo ao qual possui resultados mutuamente exclusivos (na realidade, cada indutor tem sua própria forma de escolher o atributo que será utilizado no teste). Sejam os possíveis resultados do teste denotados por O_1, O_2, \dots, O_r . T é então partitionado em subconjuntos T_1, T_2, \dots, T_r , nos quais cada T_i contém todos os exemplos em T que possuem como resultado daquele teste o valor O_i . Assim, a árvore de decisão consiste em um nó

interno, identificado pelo teste escolhido, e uma aresta para cada um dos resultados possíveis.

4. Os passos 1, 2 e 3 são aplicados recursivamente para cada subconjunto de exemplos de treinamento de maneira que, em cada nó, as arestas levam para as subárvores construídas a partir do subconjunto de exemplos T_i ;

O que difere os algoritmos de árvore de decisão é o método pelo qual é feita a seleção do melhor atributo para ser utilizado em cada nó da árvore. (REZENDE, 2003) descreve algumas possibilidades utilizadas para efetuar essa escolha e particionar o conjunto de exemplos em cada iteração:

- ❑ Aleatória: Nesse caso, seleciona qualquer atributo aleatoriamente;
- ❑ Menos Valores: Seleciona o atributo com a menor quantidade de valores possíveis;
- ❑ Mais Valores: Seleciona o atributo com a maior quantidade de valores possíveis;
- ❑ Ganhão Máximo ou Ganhão de Informação: Seleciona o atributo que possui o maior ganho de informação esperado, ou seja, seleciona o atributo que resultará no menor tamanho esperado das subárvores, assumindo que a raiz seja o nó atual;
- ❑ Índice Gini (BREIMAN et al., 1984): Medida estatística para dispersão dos dados na qual mede-se o grau de impureza de cada nó. Nesse caso, seleciona o atributo resultante do melhor valor de Gini;
- ❑ Razão do Ganhão (QUINLAN, 2014): Seleciona o atributo com a melhor Razão de Ganhão comparado com aqueles que obtiveram a Razão do Ganhão acima da média.

De acordo com (REZENDE, 2003), após a construção da Árvore de Decisão, uma simplificação (poda) pode ser realizada para melhorar a capacidade de generalização da árvore e solucionar problemas de superajuste dos dados. Em geral, os indutores de Árvore de Decisão separam por si próprios os conjuntos de exemplos em um conjunto de exemplos de treinamento (que é utilizado para construir a árvore) e também um conjunto de exemplos de poda, o qual é efetivamente utilizado para realizar o processo de poda.

Esse tipo é chamado de *pós-poda* e pode ser feita por vários métodos para medir o grau de impureza dos nós, incluindo a complexidade do erro (BREIMAN et al., 1984) e o método do erro pessimista (QUINLAN, 2014). Além disso, é possível evitar que determinados tipos de conjunções apareçam na árvore, para isso, basta utilizar o método *pré-poda*, no qual a poda é feita enquanto a Árvore de Decisão é induzida.

2.2.3 Algoritmo ID3

Algoritmos padrões de árvore de decisão, tais como ID3 (QUINLAN, 1986), C4.5 (QUINLAN, 2014), CART (BREIMAN et al., 1984), funcionam como preditores de regras que representam explicitamente a estrutura de um conjunto de dados, onde as regras de decisão são inferidas através da abordagem *Top-Down*, ou seja, são construídas na ordem de profundidade dos nós da árvore, utilizando a estratégia de recursividade *dividir para conquistar*. O teste envolve apenas um único atributo e o valor deste atributo é comparado a uma constante. A ideia básica desses algoritmos é que, após selecionar o atributo e inseri-lo no nó raiz, sejam feitas ramificações na árvore de acordo com os critérios pré-estabelecidos tendo como base esse atributo. (SHI, 2007).

O ID3 é um algoritmo extensamente estudado pelo fato de gerar árvores relativamente pequenas quando comparado com outras técnicas. Esse método também está entre os mais conhecidos e bem sucedidos algoritmos de inferência indutiva (GUARDA, 2016), aplicado nas mais diversas áreas do conhecimento.

O algoritmo básico do ID3 constrói árvores de decisão partindo da raiz, esta raiz é determinada avaliando cada atributo através de um método estatístico para determinar como esse classifica os exemplos de treinamento. O melhor atributo é então selecionado como nó raiz da árvore.

Um descendente do nó raiz é criado para todos os possíveis valores desse atributo, os exemplos de treinamento são particionados e associados a cada nó descendente com a finalidade de selecionar o melhor atributo. Essa característica gera uma procura de uma árvore de decisão aceitável no qual o algoritmo nunca retrocede às escolhas feitas anteriormente, conforme o pseudocódigo abaixo (GUARDA, 2016).

Para que seja possível a geração da árvore de decisão a partir do algoritmo ID3, é necessário obter o ganho de informação definido por $Entropia(C) = -\sum_{i=1}^n p_i \log_2 p_i$ (KURETZKI, 2009), onde:

- ❑ C = é o conjunto de classes
- ❑ n = é o número de classes
- ❑ p_i = é a frequência da classe i

O ganho é calculado por $Ganho(C, A) = Entropia(C) - \sum_{i=1}^n p(t_I^A) Entropia(C|t_I^A)$, onde:

- ❑ Entropia(C) = é o cálculo da entropia das classes antes da participação, conforme a equação anterior
- ❑ n = é o número de classes
- ❑ i = é a i -ésima partição, correspondente ao i -ésimo valor do atributo A

Algoritmo 1 ID3 (D, A, Atributos)

com **D** o conjunto de exemplos, **A** o atributo alvo, e **Atributos** a lista de atributos que caracteriza as entidades;

criar um nó raiz da árvore;

se todos os exemplos são positivos, **então**

rotular o nó como positivo (+) e devolver à árvore;

se todos os exemplos são negativos, **então**

rotular o nó como negativo (-) e devolver à árvore;

se a lista de atributos está vazia, **então**

devolver à árvore, com um rótulo idêntico ao valor assumido pela maioria dos exemplos;

senão

$A \leftarrow$ o atributo da lista de atributos, que melhor classifique os exemplos;
usa-se o Ganho de Informação para escolher o atributo que melhor classifique os exemplos; o nó recebe A , como rótulo;

para cada valor possível vi de Valores(A) **faça**

adicionar um novo ramo, a partir do nó, correspondente ao teste $A = vi$;

$Dvi \leftarrow$ o subconjunto de D , com $A = vi$;

se $Dvi = \{\}$: **então**

devolver à árvore, com um rótulo idêntico ao valor assumido pela maioria dos exemplos

senão

abaixo desse ramo adicionar a subárvore ID3 (Dvi , A , Atributos- $\{A\}$)

□ $p(t_I^A)$ = é a frequência da i-ésima partição baseada no atributo A

□ $Entropia(C|t_I^A)$ = é a entropia da i-ésima partição

Vejamos um exemplo para a execução do algoritmo para classificar a emoção alegria, tendo como treinamento os dados: imagem, distância1, distância2, distância3, distância4, alegria, conforme exibidos na Tabela 1.

O primeiro passo a ser realizado utilizando o algoritmo ID3 é escolher o melhor atributo. Para isso, calcula-se, o ganho para todos os atributos, em cada iteração do algoritmo, é escolhido o atributo que apresente um maior ganho, veja o exemplo partindo do atributo Distância3 conforme a Figura 3.

O ganho é obtido usando as fórmulas mencionadas acima:

$S = [9+, 5-]$, $E = 0.940 = -9/14 \log_2 9/14 - 5/14 \log_2 5/14$, onde $Ganho(S, Umidade) = 0.940 - (7/14) * 0.985 - (7/14) * 0.592 = 0.151$.

Calculando o ganho para todos os atributos, verificamos que o possui maior ganho é a Distância1, conforme a Tabela 2.

Quando a entropia for nula para todos os nós no algoritmo obtém-se a seguinte árvore de decisão, conforme a Figura 4.

Tabela 1 – Exemplo de treino para classificar a emoção alegria.

Imagen	Distância1	Distância2	Distância3	Distância4	Alegria
IM1	0.5	1.5	1.0	0.5	NÃO
IIM2	0.5	1.5	1.0	1.5	NÃO
IIM3	1.0	1.5	1.0	0.5	SIM
IIM4	1.5	1.0	1.0	0.5	SIM
IIM5	1.5	0.5	0.5	0.5	SIM
IIM6	1.5	0.5	0.5	1.5	NÃO
IIM7	1.0	0.5	0.5	0.5	SIM
IIM8	0.5	1.0	1.0	0.5	NÃO
IIM9	0.5	0.5	0.5	0.5	SIM
IIM10	1.5	1.0	0.5	1.5	SIM
IIM11	0.5	1.0	0.5	1.5	SIM
IIM12	1.0	1.0	1.0	1.5	SIM
IIM13	1.0	1.5	0.5	0.5	SIM
IIM14	1.5	1.0	1.0	1.5	NÃO

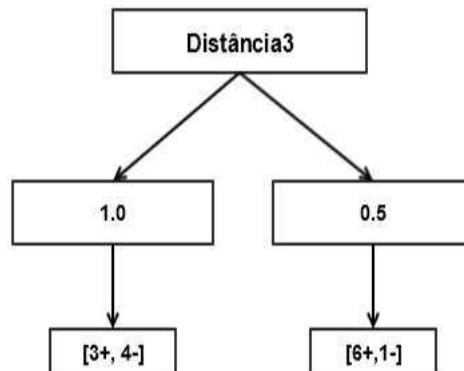


Figura 3 – Ramificação para o cálculo de ganho do atributo Distância3.

Tabela 2 – Ganhos obtidos a partir dos atributos.

Atributo	Ganho
Ganho(S,Distância3)	0.151
Ganho(S,Distância4)	0.048
Ganho(S,Distância1)	0.247
Ganho(S,Distância2)	0.029

2.2.4 Raciocínio Baseado em Casos (RBC)

Atualmente, o RBC (WESS, 1995) tem se apresentado como uma técnica eficiente para solução automática de problemas. RBC é aplicável de forma simples e direta atendendo uma ampla gama de tarefas, todas ligadas diretamente ou indiretamente à Inteligência Artificial. A ideia básica de um RBC está em resolver novos problemas, relembrando de uma situação anterior similar, podendo reutilizar a informação e conhecimento daquela determinada situação. O RBC pode ser aplicado a um grande número de problemas do

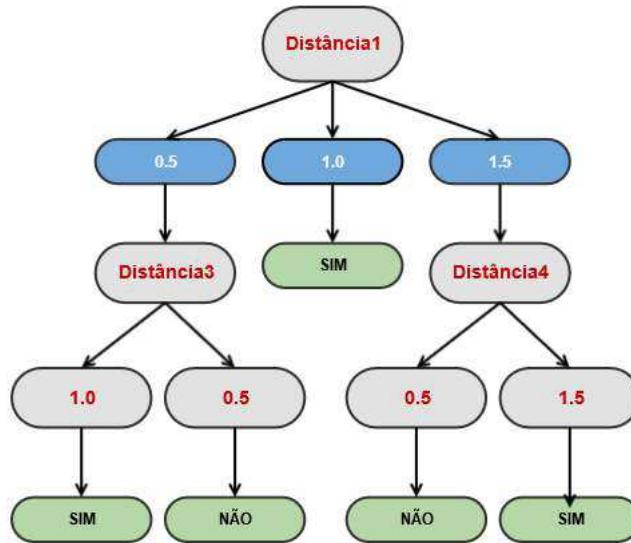


Figura 4 – Árvore de decisão final para a classificação da emoção alegria.

Fonte: O Autor

cotidiano, de certa maneira, os seres humanos utilizam esses casos de forma intuitiva. Vejamos alguns desses exemplos:

- O médico, ao atender um novo paciente com suspeita de dengue, procura primeiro os sintomas comuns de outros pacientes que foram diagnosticados com a mesma doença. No momento de administrar a medicação para esse paciente ele também pode se utilizar desses casos para prescrever o devido tratamento.
- Um técnico em informática, ao atender um novo cliente que está com problemas em seu equipamento, analisa os erros e de acordo com suas experiências e casos semelhantes, consegue rapidamente diagnosticar o defeito do aparelho e qual a solução para o devido problema.
- Um profissional da engenharia utiliza um projeto similar por ele desenvolvido para servir de base para um novo caso proposto, como por exemplo, a planta de uma casa, uma instalação elétrica semelhante, etc.

Essas três e diversas outras situações do dia a dia possuem em comum o fato de que a solução para o novo problema foi encontrada guiando-se pelas soluções apresentadas no passado. O RBC pode ser entendido como a tecnologia de Inteligência Artificial inspirada nesse modelo de cognição e no comportamento humano (WESS, 1995).

A tecnologia RBC pode ser analisada sob dois pontos de vista distintos: pode ser entendida como uma metodologia para modelar o raciocínio e o pensamento humano e como uma metodologia capaz de construir sistemas computacionais dotados de inteligência (WANGENHEIM; WANGENHEIM, 2013).

O RBC pode ser compreendido como um novo modelo para a resolução de problemas que em vários aspectos se diferencia da forma clássica de Inteligência Artificial (AAMODT; PLAZA, 1994), ao invés de se basear em um único pensamento generalizado acerca de um domínio, mostra que o RBC é capaz de utilizar as soluções de problemas objetos anteriormente resolvidos, que são denominados como casos.

Um sistema baseado em casos deve conter os seguintes elementos básicos para seu correto funcionamento:

- **Representação do conhecimento:** As representações desses conhecimentos são os casos concretos existentes e conhecidos para elaboração do sistema.
- **Medida de similaridade:** Para todo e qualquer problema deve ser possível encontrar um caso relevante ou equivalente para a solução do novo problema apresentado.
- **Adaptação:** Em geral, as situações passadas dificilmente serão idênticas às do problema atual (WANGENHEIM; WANGENHEIM, 2013). Sistemas RBC avançados possuem capacidade de adaptar os casos recuperados a partir da base, com a finalidade de verificar se esses satisfazem o problema que está sendo avaliado.
- **Aprendizado:** Para que o sistema evolua constantemente, sempre que é resolvido um novo problema, deverá ser capaz de relembrar dessa solução no futuro como mais um caso novo.

A Figura 5 exemplifica um sistema RBC com todos os seus componentes necessários para construção do conhecimento baseado em casos.

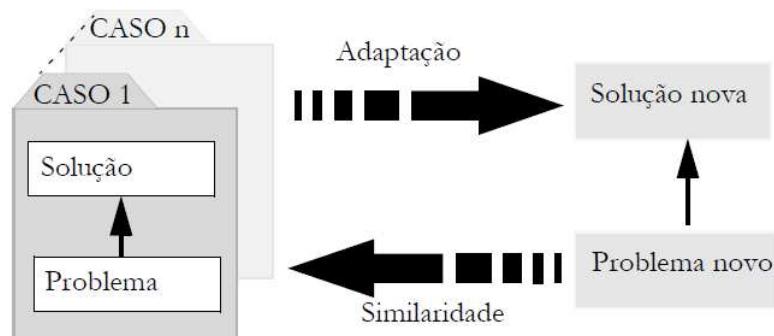


Figura 5 – Modelo de um RBC

Fonte: (WANGENHEIM; WANGENHEIM, 2013)

A maneira de representar o conhecimento em sistemas RBC são os casos. Um caso é um registro de um problema resolvido ou parcialmente resolvido no passado. Esses casos podem também conter itens como os efeitos das soluções propostas, ou até mesmo a justificativa da solução apresentada (KOLODNER, 1993). A Figura 6 demonstra um

exemplo simplificado de uma base de casos de um sistema RBC para solução de um problema.

CASO 1	
Problema/ Sintomas	Problema: Impressora não funciona Modelo: Robotron Matrix 600 Luz de estado do papel: apagada Luz de estado da tinta colorida: apagada Luz de estado da tinta preta: apagada
Solução	Diagnóstico: Curto-circuito Ação: Troca da fonte de alimentação
CASO 2	
Problema/ Sintomas	Problema: Não imprime em preto Modelo: Robotron Matrix 800 Luz de estado do papel: apagada Luz de estado da tinta colorida: apagada Luz de estado da tinta preta: aceso
Solução	Diagnóstico: Cartucho de tinta preta vazio Ação: Troca do cartucho de tinta preta

Figura 6 – Exemplo de uma base de casos

Fonte: (WANGENHEIM; WANGENHEIM, 2013)

Atualmente, o modelo mais aceito para sistemas RBC é o ciclo proposto por (AMODT; PLAZA, 1994), composto por quatro tarefas principais, são elas:

- **Recuperar:** os casos similares existentes na base;
- **Reutilizar** os casos presentes na base para resolver novos problemas;
- **Revisar** a solução proposta e, por fim,
- **Reter** essa nova experiência ou solução apresentada para o caso atual, para que a mesma possa ser reutilizada no futuro.

2.3 Ambientes Virtuais de Aprendizagem 3D

O termo Ambientes Virtuais de Aprendizagem (Ambientes Virtuais de Aprendizagem (AVA) é amplo e diversificado devido ao fato da maioria dos desenvolvedores de *software* e pesquisadores definirem o termo com base em suas próprias experiências vivenciadas, gerando assim diversas definições na literatura, e ocasionando ambiguidade com o termo realidade virtual. Em (MOORE et al., 1995) o autor afirma que a realidade virtual se divide-se em três aspectos principais, baseados em: textos, computador e sensores

de imersão. Atualmente o termo ambiente virtual de aprendizagem tem sido utilizado para caracterizar qualquer recurso de aprendizagem baseado na web, consequentemente, o termo 3D aplica-se a para esses ambientes desenvolvidos computacionalmente de forma tridimensional.

Os educadores de forma geral têm passado por uma crescente demanda de flexibilidade na maneira pela qual as informações são expostas e repassadas aos estudantes por meio da tecnologia (DALGARNO, 2002). Juntamente com o crescimento dessa demanda surgiram novas teorias construtivistas de aprendizagem que enfatizam a importância dos alunos na interpretação ativa e na construção de representações do conhecimento individual (DALGARNO, 2002).

O uso de tecnologias de informação e comunicação constitui-se em um forte potencial para tornar os recursos de aprendizagem mais acessíveis, possibilitando um processo de ensino e aprendizagem mais ativo e construtivo (DALGARNO, 2002). Atualmente, devido ao grande avanço tecnológico dos últimos anos, principalmente nas redes de computadores e na capacidade de processamento gráfico de ambientes tridimensionais (3D), estes estão presentes indústrias de jogos, filmes e simuladores em terceira dimensão. Todos esses recursos podem ser utilizados para fornecer aos ambientes virtuais de aprendizagem sejam 3D ou não uma maior interação entre estudantes e estudantes-computador durante todo processo de aprendizagem, colaborando de maneira significativa para esse processo.

Segundo (DILLENBOURG; SCHNEIDER; SYNTETA, 2002), o termo ambiente virtual de aprendizagem não pode ser empregado para referenciar qualquer website educacional disponível. Os AVA podem ser identificados por certas características em comum que proporcionam um maior nível de interação entre os alunos e o ambiente, que geralmente não são encontradas em ambientes educacionais simples, que são:

- ❑ Um ambiente virtual de aprendizagem é um espaço com informações;
- ❑ Um ambiente virtual de aprendizagem é um espaço social, ou seja, permite que interações educacionais ocorram no ambiente, transformando espaços em lugares;
- ❑ O ambiente virtual de aprendizagem é representado através das informações espaciais e sociais;
- ❑ Os alunos são usuários ativos e atores co-constutores do ambiente virtual de aprendizagem;
- ❑ Ambientes virtuais de aprendizagem não estão restritos somente à educação a distância, eles colaboram de maneira significativa para o enriquecimento das atividades em salas de aula;
- ❑ Os ambientes virtuais de aprendizagem integram diversas tecnologias heterogêneas e várias abordagens pedagógicas;

- A maioria dos ambientes virtuais se sobrepõe aos ambientes físicos.

Um projeto desenvolvido pela Universidade de Harvard traz um ambiente virtual de aprendizagem chamado *River City Interface*. Trata-se de um ambiente semelhante a alguns jogos multijogadores online, que permitem vários estudantes acessarem esse ambiente, comunicarem-se e interagirem com os objetos virtuais de aprendizagem 3D de maneira interativa (RIVER, 2016). A Figura 7 demonstra o ambiente desenvolvido e suas respectivas interfaces.



Figura 7 – Ambiente Virtual de Aprendizado 3D *River City* da Universidade de Harvard.

Fonte:(RIVER, 2016)

Note na imagem que o ambiente possui quatro interfaces principais, as quais procuramos implementar neste trabalho proposto. São elas:

- Barra de ferramentas de ações, que permite ao estudante controlar os movimentos do personagem e as posições da câmera;
- Espaço virtual, onde se encontra o ambiente virtual 3D redenrizado graficamente;
- Janela de chat, permitindo aos estudantes se comunicarem entre si através de mensagem em grupo ou publicamente com todos os estudantes;
- Espaço do estudante, contendo o material didático proposto em forma de textos.

Para proporcionar uma integração flexível entre o ambiente de aprendizagem Moodle e o ambiente virtual de aprendizagem 3D, foi utilizado o Sloodle, um plug-in que permite a integração síncrona com outras tecnologias web (KIRRIEMUIR, 2007), facilitando assim a importação de objetos e conteúdos criados dentro da plataforma Moodle para o ambiente virtual.

2.4 Trabalhos Correlatos

O trabalho de (AZCARATE et al., 2005) propõe um sistema para detecção das sete emoções básicas (Neutro, Alegria, Tristeza, Raiva, Desgosto e Medo) em tempo real, utilizando o modelo Piecewise Volume Deformation (PVBD), baseado na teoria FACS. O autor propõe também a criação de um conjunto denominado Unidades de Movimento para uma melhor interpretação das Unidades de Ação no aspecto computacional, facilitando a interpretação e localização das regiões de interesse. Para a classificação foram utilizadas técnicas de aprendizagem de máquina, como Naive Bayes, e uma variação deste, o TAN. Os resultados para o Naive Bayes foram considerados relativamente bons se comparados com outros trabalhos da literatura, enquanto os resultados apresentados para o TAN não foram relativamente bons quando comparados com outros trabalhos que utilizaram a mesma técnica, conforme mencionado pelo próprio autor.

Em (PANTIC; ROTHKRANTZ, 2000) efetuou-se um estado da arte relacionado ao reconhecimento automático de expressões faciais e técnicas computacionais utilizadas para classificação, das emoções. Nesse trabalho afirma-se que a detecção dinâmica das emoções através das UA's é um problema desafiador devido à complexidade de detectar todas as 44 UA's expressas no sistema FACS. Assim, (AZCARATE et al., 2005), desenvolveu um sistema computacional para reconhecimento das sete emoções básicas, baseado na teoria FACS. A detecção dos pontos da face foi feita através de Unidades de Movimento (UM's), que estão associadas a determinadas UA's reconhecidas por (EKMAN; FRIESEN, 1978a). Porém, as UM's não são equivalentes às UA's.

No trabalho de (.C AHMED .W, 2014) foi proposto um sistema capaz de avaliar e classificar as expressões faciais em diferentes etnias. Sendo o principal objetivo demonstrar o reconhecimento dessas emoções mesmo em etnias diferentes. Foi utilizado o fluxo óptico para extrair os movimentos e as regiões de interesse correlacionadas com as Unidades de Ação; as regras foram geradas utilizando uma árvore de decisão para a classificação. Neste sentido foi observado que a classificação melhora quando se leva em consideração a etnia do usuário.

Em (VALSTAR; PANTIC, 2012) foi apresentado um sistema que permite a detecção de uma gama muito maior do comportamento facial, a partir do movimento dos músculos (Unidades de Ação), assim, além de reconhecer 22 dessas UA's, apresenta também seus comportamentos temporais, ou seja, uma sequência de segmentos que levaram até a emoção e, então, até sua classificação final. Para a localização correta das unidades de ação foi utilizado o filtro Gabor, para localização dos pontos, permitindo a construção de uma máscara facial. Na classificação foi utilizada uma máquina de vetores de suporte (SVM). Os testes com o reconhecimento das unidades de ações nas duas bases de dados conceituadas se mostraram satisfatórios; os resultados para a classificação das emoções, apesar de inferior aos resultados apresentados para as unidades de ações, são também relativamente bons. Os testes realizados levaram em consideração emoções espontâneas

e não espontâneas, outro aspecto de grande relevância.

No trabalho de (AO et al., 2012) é apresentado um sistema capaz de detectar as emoções básicas a partir da abordagem do fluxo óptico, este utilizado para detecção e rastreamento dos pontos após a localização da face. A técnica foi apresentada de maneira clara e bem informada, permitindo sua fácil compreensão. Para classificação, foram implementados os classificadores Naive Bayes e TAN. Seus resultados são insuficientes, pois ainda não foram testados em bases de dados desenvolvidas para esse propósito.

Em (.Z, 2014) é apresentado um novo método para o reconhecimento de várias expressões faciais em imagens e vídeos: para extrair essas características, o autor utilizou a Análise de Componentes Independentes Aprimoradas (EICA), a partir da análise das Componentes Independentes (IC) e classificadas pelo modelo estatístico de Análise Discriminate Linear (FLDA), que com essas características utiliza o modelo Hidden Markov (HMMs) para modelar diferentes expressões faciais, e então, classificar as seis emoções básicas. Os testes realizados pelo autor são comparados a outras abordagens como: a Análise de Componentes Principais (PCA), Componentes Independentes (ICA), o que permitiu demonstrar que a taxa de reconhecimento melhorou significadamente, quando combinado com o modelo Hidden Markov proposto pelo autor.

O artigo de (RÁZURI et al., 2013) centra-se em um sistema de reconhecimento de emoção do ser humano a partir da detecção da face. A informação é analisada e transmitida pelas regiões do olho e da boca, em uma nova imagem mesclada em várias expressões faciais pertencentes às seis emoções faciais básicas universais. A informação de saída alimenta a entrada para uma “máquina”, capaz de interagir com as habilidades sociais, no contexto da construção social de sistemas inteligentes. A metodologia faz uso de uma técnica de classificação de informações para uma nova imagem fundida, que é composta de dois blocos integrados pelas áreas dos olhos e da boca, que são consideradas áreas muito sensíveis às mudanças de expressão do ser humano e que são particularmente relevantes para a decodificação de expressões emocionais. (RÁZURI et al., 2013) usam a imagem mesclada como uma entrada, que foi propagada usando *feed-forward* de uma rede neural treinada por *backpropagation*. Tal análise de imagens fundidas tornou possível obter informações relevantes - através da combinação dos dados apropriados da mesma imagem - e reduzir o tempo de treinamento, enquanto fora preservada a taxa de classificação. Foi demonstrado por (RÁZURI et al., 2013) que o algoritmo proposto pode detectar a emoção com boa precisão.

No trabalho de (.I BALLANO .S, 2014) é desenvolvido um sistema integrado ao ambiente Moodle, capaz não simplesmente de analisar as emoções do estudante em um dado instante, mas também durante variações de tempo no decorrer do processo de aprendizagem. Através de uma formulação matemática, o autor cria um modelo 2D do caminho emocional. Esse modelo 2D é capaz de representar visualmente a evolução emocional do estudante durante esse processo, tal representação permite descobrir as possíveis poten-

cialidades e pontos fracos do estudante. O sistema foi validado com a aplicação de testes com diversos colaboradores em um ambiente virtual implementado em Moodle.

Em (SOLIMAN; GUETL, 2013) é desenvolvido um agente pedagógico, aplicado a um mundo virtual de código aberto. São descritos os passos para o desenvolvimento do ambiente. Outro fato que também é bastante comentado no trabalho é sobre a dificuldade de projetar e implantar esses agentes pedagógicos inteligentes nos mundos virtuais, o que pode acabar desmotivando alguns pesquisadores da área. No trabalho foi desenvolvido e implantado esse agente, baseado na técnica Artificial Intelligence Markup Language (AIML) no ensino de ciências.

No trabalho de (IGLESIAS; LUENGO, 2004) é apresentado um mundo virtual 3D com diversas técnicas de inteligência artificial, como: Redes Neurais, Sistemas Especialistas e Lógica Fuzzy, com o objetivo de fornecer inteligência aos agentes virtuais, criando comportamentos diversos, de modo que eles procedam de maneira mais realista possível. Para desenvolver o trabalho, simulou-se um mundo virtual 3D composto por módulos que permitem a esses agentes terem comportamento natural assim como os seres humanos, quando inseridos nos mundos virtuais 3D.

Em (SALEEB; DAFOULAS, 2013) são investigadas as oportunidades disponíveis da aprendizagem em ambientes virtuais 3D, são apresentadas também propostas de criação de *e-learning* com o apoio de avatares robóticos, dotados de inteligência. No trabalho, fica claro que o uso de tecnologias em si não causam a aprendizagem e, sim, o conjunto de tarefas executadas que resultam em uma aprendizagem. Para que essa aprendizagem ocorra, são considerados sete princípios que esses ambientes devem possuir.

No trabalho de (BLAIR; LIN, 2011) é apresentada uma abordagem sobre a integração de ambientes virtuais 3D com sistemas pedagógicos multiagentes, fornecendo assim uma forma mais envolvente para os ambientes virtuais de aprendizagem. No trabalho é explorada também a viabilidade dessa integração e o desenvolvimento de um sistema de código aberto em forma de jogo de competição amigável. Essas integrações proporcionam uma imersão na aprendizagem de conteúdo, contribuindo satisfatoriamente para o processo de aprendizagem.

Em (AQUINO; SOUSA; FRERY, 2005) é apresentada uma arquitetura multi-agente para o gerenciamento de objetos de aprendizagem, uma vez que ambientes virtuais 3D, capazes de acompanhar as ações dos usuários e se adaptar ao perfil do usuário podem mesmo, contribuir satisfatoriamente para o processo de aprendizagem. Para alcançar esse objetivo, os ambientes virtuais devem trabalhar em tempo real e capturar as adaptações e evoluções de forma cognitiva. Além disso, essa arquitetura é responsável por analisar as informações coletadas e decidir que modificações serão feitas no ambiente. O uso de agentes permite aumentar a capacidade de análise do meio ambiente, através da distribuição de tarefas e a incorporação de técnicas de inteligência artificial no processo de criação do Modelo de Usuário. O modelo de usuário é usado para armazenar as informações

existentes sobre o usuário, como por exemplo, suas preferências e comportamento.

Em (HERPICH et al., 2014) é apresentada uma proposta para o desenvolvimento de um ambiente imersivo para o ensino Redes de Computadores, para isso, foi desenvolvido um mundo virtual 3D, utilizada a ferramenta *OpenSim*. Esse mundo virtual foi integrado ao Moodle, permitindo assim a integração dos objetos de aprendizagem propostos no Moodle ao ambiente virtual 3D. Foram utilizados também agentes, que oferecem apoio aos alunos de acordo com as características cognitivas e seu nível de especialização. Esses agentes têm a função de apoiar o estudante no ambiente em que está situado, fornecendo assim uma aprendizagem personalizada.

No trabalho de (DREHER et al., 2009) é feito um estudo de caso de trabalhos que utilizaram mundos virtuais 3D na educação e ambientes colaborativos, destacando suas principais vantagens e benefícios adquiridos. De acordo com o (DREHER et al., 2009), esses mundos virtuais simulam a vida real com fidelidade e de forma dinâmica, tanto nos aspectos econômicos como sociais dos usuários, além disso, os mundos virtuais 3D fornecem o enriquecimento de conteúdo, uma vez que esses mundos são gerados pelo próprio usuário, promovendo assim um ecossistema rico de culturas e inovações, um fator importante para a educação atual, na qual o estudante deve ser capaz de gerar conhecimento a partir do que foi adquirido. Esses mundos virtuais são ótimos para o estudo colaborativo, uma vez que a maioria desses ambientes possuem fóruns e *blogs* para ajudar os usuários de alguma forma e até mesmo a interação com outros usuários presentes no ambiente.

O trabalho de (JOHN; CHINNASA et al., 2014) apresenta um sistema que, através da técnica de RBC, é capaz de detectar o temperamento e humor de usuários, funcionando como um psicólogo autônomo que, a partir de uma base de casos, consegue fornecer para os usuários um *feedback* sobre seu tipo de temperamento e seu respectivo humor expressado. Essa ferramenta permite aos usuários que não estão ao alcance de um psicólogo, identificar esses dois fatores que influenciam diretamente em nossas reações, na saúde mental e na forma como reagimos ao mundo em geral, conforme demonstrado pelo autor.

A Tabela 3 apresenta os trabalhos correlatos fundamentais para o desenvolvimento deste trabalho, bem como quais foram suas principais contribuições para cada uma das etapas desenvolvidas.

Tabela 3 – Principais trabalhos correlatos e suas contribuições.

Trabalho	Principais contribuições para o trabalho
(AZCARATE et al., 2005)	Técnicas para detecção dos movimentos faciais (Unidades de Movimento) e classificação das emoções.
(PANTIC; ROTHKRANTZ, 2000)	Técnicas para a detecção e classificação das expressões faciais.
(VALSTAR; PANTIC, 2012)	Fundamentação teórica e a detecção de maneira precisa das Unidades de Ação em imagens e vídeos.
(AO et al., 2012)	Fundamentação teórica e aplicação da técnica de fluxo óptico em vídeos para o correto rastreamento dos pontos projetados na face.
(.Z, 2014)	Fundamentação teórica e aplicação da técnica de fluxo óptico em vídeos para o correto rastreamento dos pontos projetados na face.
(.I BALLANO .S, 2014)	Avaliação de diversos algoritmos de aprendizagem de máquina para a classificação das emoções em tempo real.
(SALEEB; DAFOULAS, 2013)	São apresentadas as características e técnicas para integração de sistemas na plataforma Moodle de maneira correta.
(BLAIR; LIN, 2011)	Fundamentação teoria e principais contribuições dos Ambientes Virtuais de Aprendizagem 3D no processo de ensino e aprendizagem.
(HERPICH et al., 2014)	Técnicas para a correta integração de dos Ambientes Virtuais de Aprendizagem com sistemas pedagógicos multiagentes.
(JOHN; CHINNASA et al., 2014)	Principais detalhes técnicos para o desenvolvimento de um Ambiente Virtual de Aprendizagem 3D.
	Fundamentação teórica para a técnica de Raciocínio Baseado em Casos e sua correta implementação em ambientes reais.

Ao analisar a literatura correlata foi possível perceber que as emoções representam um fator importante no processo de ensino e aprendizagem. Além disso, que o reconhecimento

de emoções em ambientes educacionais a distância de forma geral, tem sido objeto de estudo de diversos pesquisadores da área de inteligência artificial (SUN; PEI; ZHOU, 2008).

Com base na literatura indentifica-se que é possível a criação que permitem o rastreamento e acompanhamento dos estudantes durante o processo de aprendizagem, permitindo assim que os ambientes virtuais de aprendizagem se adaptem de acordo com essas características emocionais, adquiridas durante o processo de ensino, de forma significativa para o estudante e professor.

CAPÍTULO 3

Estratégias Pedagógicas Baseadas em Emoções e Perfis de Personalidade (EPEP)

Neste capítulo é apresentando o **EPEP**, um sistema responsável por recomendar estratégias pedagógicas baseadas em emoções e perfis de personalidade em ambientes virtuais de aprendizagem 3D.

O foco principal deste trabalho é um módulo capaz de reconhecer emoções e, juntamente com os perfis de personalidade, gerar recomendações em ambientes virtuais de aprendizagem. Essas recomendações são geradas através de RBC. Sendo assim, a seção 3.1 descreve a arquitetura proposta, a seção 3.2 apresenta o *facial e-motion*, a seção 3.3 descreve o ambiente virtual 3D e por fim na seção 3.4 é descrito o RBC.

3.1 Estrutura do (EPEP)

O **EPEP** é composto por três módulos principais: o *facial e-motion*, responsável pela detecção e classificação das emoções do estudante, um ambiente virtual de aprendizagem modelado tridimensionalmente com objetos de aprendizagem 3D, e o RBC responsável por processar as emoções com outros atributos como, por exemplo, os perfis de personalidade e as inteligências múltiplas, com a finalidade de simular estratégias pedagógicas favoráveis para o estudante durante o processo de ensino e aprendizagem.

Durante todo o processo cognitivo, as emoções do estudante são observadas com intuito de verificar o seu estado afetivo durante o processo de aprendizagem. É considerada, de forma geral para todos os indivíduos, a emoção “alegria” como o estado afetivo ideal para o aprendizado, de acordo com o trabalho de (CHABOT, 2005), a Figura 8 exibe a estrutura geral desenvolvida neste trabalho.

Observando a Figura 8, nota-se que as recomendações pedagógicas serão inferidas tomando como base as emoções e os perfis de personalidade, gerenciados por dois principais

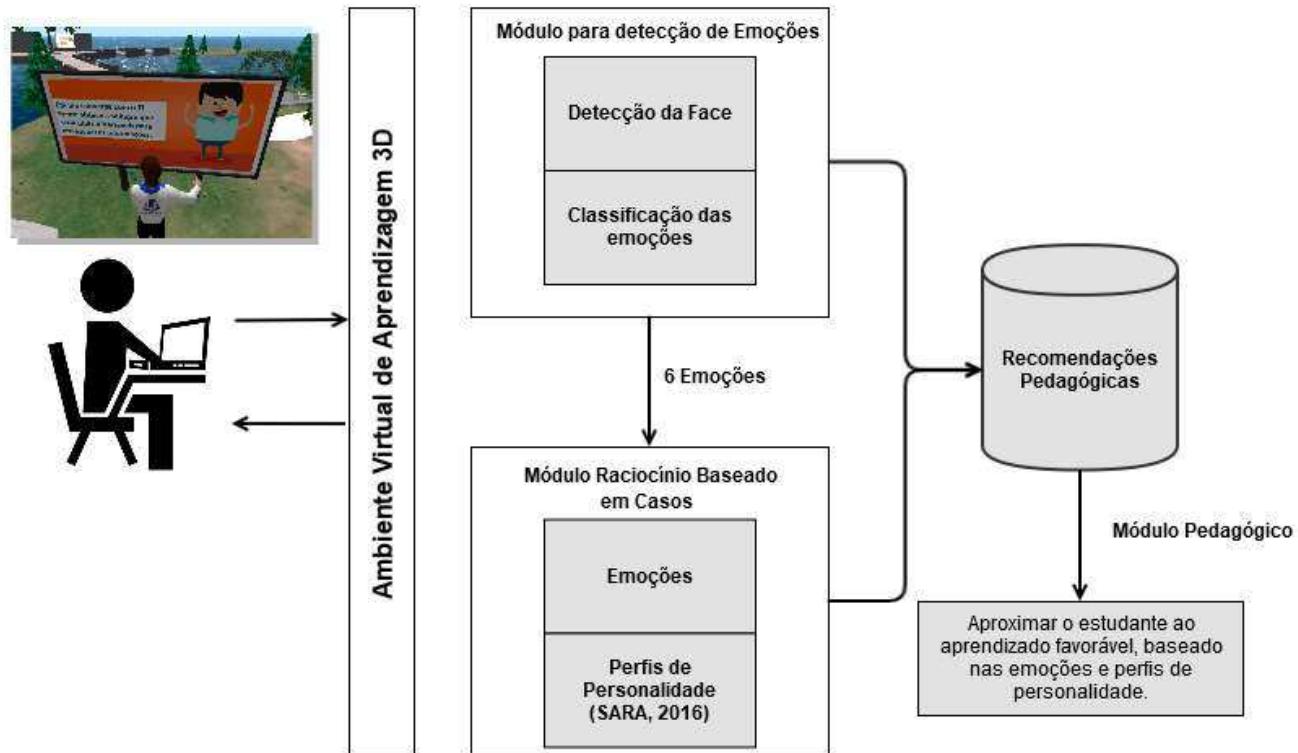


Figura 8 – Estrutura geral do **EPEP** para a recomendação de estratégias pedagógicas em ambientes virtuais de aprendizagem.

módulos: um, responsável pela detecção e classificação das emoções, e outro, responsável pela parte do raciocínio baseado em caso, que através das emoções e dos perfis é capaz de prover essas recomendações. Assim, com a obtenção dessas informações é possível fornecer ao estudante um controle das suas emoções, validando computacionalmente a pedagogia emocional proposta por (CHABOT, 2005).

3.2 Módulo Detecção de Emoções

A partir da face capturada através de uma câmera este módulo retorna as emoções observadas no estudante durante o processo de ensino e aprendizagem. Para que isso seja possível são necessários os seguintes passos: Detecção da face, detecção das unidades de movimento, classificação das emoções e por último a integração desde módulo ao ambiente virtual de aprendizagem.

3.2.1 Detecção da Face

Antes de qualquer processamento a ser realizado neste trabalho, deve-se primeiramente realizar a detecção da face do estudante e das regiões de interesse (olhos, boca,

nariz e contorno da face). O classificador “em cascata” proposto por (VIOLA; JONES, 2004) é um dos mais utilizados para localizar faces em imagens e vídeos de forma rápida, devido ao uso do algoritmo *Adaboost* (SCHAPIRE, 1990) em seu treinamento, sendo esse computacionalmente otimizado.

A detecção da face neste trabalho é tão importante quanto a detecção das unidades de ação, pois sem essa etapa não seria possível realizar a detecção dos pontos, uma vez que vamos extrair essas informações das expressões faciais inferidas pela face do estudante. Por se tratar de uma etapa extremamente importante, realizamos o tratamento de oclusões como, por exemplo: barba, bigode e óculos, que poderiam interferir na detecção da face, para isso, construímos classificadores “em cascata” para tratamento exclusivo dessas oclusões, com a finalidade de minimizar esses possíveis ruídos.

Os classificadores Haar cascade são em forma de árvore de decisão com pelo menos duas folhas. As características utilizadas para entrada estão descritas na Figura 9, através do cálculo da integral de imagens definida por:

$$I(x, y) = i(x, y) + I(x - 1, y) + I(x, y - 1) - I(x - 1, y - 1) \quad (1)$$

sendo, $I(x, y)$ o valor correspondente na imagem integral e $i(x, y)$, na imagem.

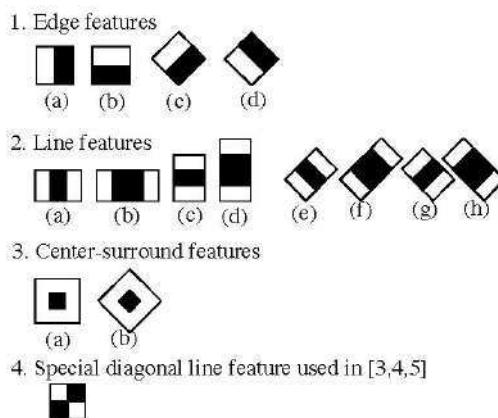


Figura 9 – Características Haar Cascade

Fonte:(OPENCV, 2015)

A classificação em todas as etapas é um processo computacionalmente complexo, sendo necessário impulsionador este processo. Atualmente são suportados quatro algoritmos: *Adaboost*, *Real Adaboost*, *Gentil Adaboost* e *Logitboost*. Para este trabalho utilizamos o *Adaboost*.

O *Adaboost* foi utilizado tanto para o treinamento dos classificadores quanto para a detecção nas imagens, sua principal função está na seleção das regiões com características relevantes para a construção do classificador. Antes do algoritmo “em cascata”, essa classificação era realizada, analisando pixel a pixel de uma imagem, o que consequentemente demandava mais tempo computacional, dependendo das dimensões da imagem.

O Adaboost chama um classificador repetidamente em iterações $j = 1, \dots, J$. Para cada uma dessas chamadas, a distribuição de pesos D_j é constantemente atualizada para indicar a sua importância, comparada com todo o conjunto de dados utilizado na classificação. A cada iteração, os pesos dos exemplos classificados incorretamente são incrementados para que o classificador trabalhe em mais exemplos. Esse processo é representado na Figura 10.

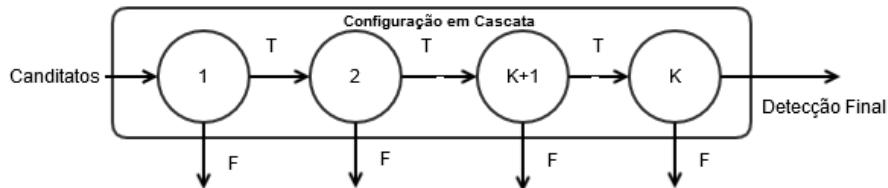


Figura 10 – Representação do modelo em cascata com Adaboost

Adaptado de:(HAPPYMAN, 2014)

3.2.2 Detecção das Unidades de Movimento

Após a detecção da face descrita no capítulo anterior, partimos então para o processamento das regiões de interesse. Nessas regiões de interesse devemos extrair como conhecimento as unidades de ação propostas por (EKMAN; FRIESEN, 1978b). Para localização e mapeamento dessas regiões utilizamos pontos projetados na face. Esses pontos são mapeados na face através da técnica de fluxo óptico (BARRON; FLEET; BEAUCHEMIN, 1994), responsável por manter o acompanhamento cinematográfico dessas regiões.

Após essa detecção, foram identificados e mapeados 12 pontos nas regiões de interesse da face adquirida. Esses pontos foram inseridos conforme as 12 unidades de movimento UM's propostas por (AZCARATE et al., 2005), exibidos na Figura 11.

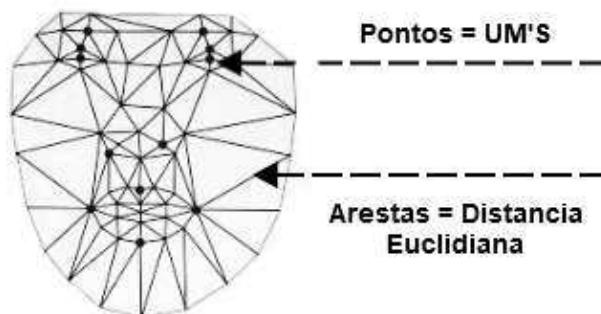


Figura 11 – Máscara facial com os 12 pontos inseridos nas regiões de interesse

Os pontos foram inseridos na face, conforme detalhados na Figura 11, sendo assim, ao detectar a face, são inseridos 4 pontos na região da boca, 2 pontos na região do nariz,

Tabela 4 – Unidades de Movimento associadas a Unidades de Ação. (AZCARATE et al., 2005)

UM	UM Contraída	Ponto Associado
1	O movimento vertical superior do centro do lábio	P51
2	O movimento vertical inferior do centro do lábio	P57
3	Movimento horizontal do canto esquerdo da boca	P48
4	Movimento vertical do canto esquerdo da boca	P54
5	Movimento horizontal do canto direito da boca	P40
6	Movimento vertical do canto direito da boca	P42
7	Movimento vertical da sobrancelha direita	P19
8	Movimento vertical da sobrancelha esquerda	P25
9	Levantamento da bochecha esquerda	P36
10	Levantamento da bochecha direita	P31
11	Piscar olho direito	P33
12	Piscar olho esquerdo	P28

4 pontos na região dos olhos e 2 pontos na região da sobrancelha. Através desses pontos calculou-se a Distância Euclidiana entre os pontos referentes às UM's. Esse cálculo é utilizado para determinar se uma determinada UM, que está relacionado à UA, foi inferida em um dado instante. A associação das UA's através das UM's estão descritas na Tabela 4.

Ao observar a Tabela 4, nota-se que a Unidade de Movimento 1 está associada com ao ponto 51 na face e representa o movimento vertical superior do centro do lábio. Sendo assim, 12 principais movimentos faciais foram associados aos 12 pontos inseridos na face, tendo como base algumas UA's que representam as seis emoções. Através da detecção e inferência das UM's e dos cálculos das Distâncias Euclidianas referentes a cada movimento, o próximo passo a ser feito é a classificação das sete emoções através dessas características. As distâncias euclidianas foram calculadas para cada uma das emoções, levando em consideração a tabela 5, que traz os determinados pontos associados às suas respectivas UM's.

Tabela 5 – Pontos utilizados para o cálculo das distâncias euclidianas para cada uma das emoções.

Emoção	Pontos
Alegria	48,54,31,36
Tristeza	48,54,31,36 40,42
Raiva	40,42,48,54 57,51
Supresa	28,25,19,33
Desgosto	40,42,57,51,48,54
Medo	48,54,31,36,28,25 19,33 40,42,57,51

Nota-se que a emoção “medo” possui em comum todas as coordenadas de pontos, sendo a emoção mais difícil para a classificação final, devido a esta particularidade. Essa característica ocorre, pois, no momento de inferência dessa emoção, diversos músculos

presentes na face são ativados de maneira simultânea, gerando uma alta correlação entre as distâncias.

3.2.3 Classificação das Emoções

Para a classificação das emoções foi utilizada a técnica Árvore de Decisão, como classificador para o reconhecimento das emoções, pelo fato da árvore gerar uma melhor compreensão visual da sua estrutura. Uma Árvore de Decisão é uma estrutura composta por três elementos básicos, sendo eles: nós de decisão, que correspondem aos atributos; bordas ou ramos, que correspondem aos diferentes valores de atributos possíveis e as folhas, que incluem objetos que pertencem à mesma classe ou que são muito semelhantes. Assim, é possível induzir regras de decisão que serão usadas para classificar novas instâncias. Cada um dos caminhos, a partir da raiz para uma determinada folha, corresponde a um conjunto de atributos de teste. A maioria das árvores de decisão é composta por dois procedimentos principais: a construção (de indução) e os procedimentos de classificação (inferência)(JENHANI; AMOR; ELOUEDI, 2008).

Para a classificação das emoções através dessa técnica computacional, cada nó corresponde a determinada emoção que se deseja classificar; os ramos são compostos pelo cálculo das distâncias euclidianas referentes às seis emoções básicas e, por fim, as folhas representam as emoções induzidas a partir dos ramos da árvore. A Figura 12 mostra a Árvore de Decisão para a classificação das emoções “desgosto” e “raiva”.

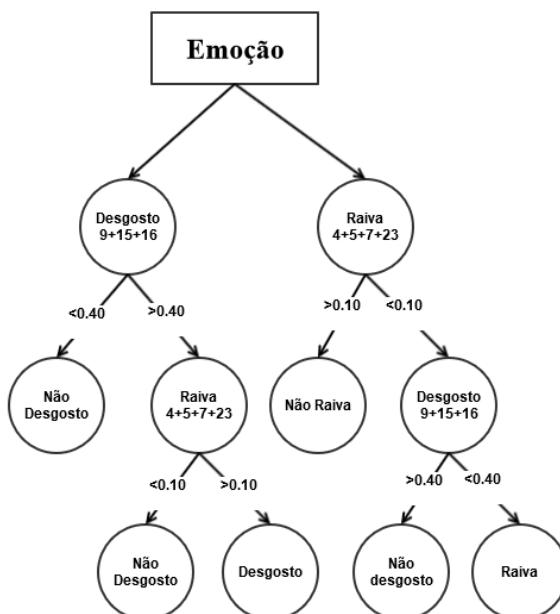


Figura 12 – Representação da Árvore de Decisão para classificação das emoções.

Nessa ramificação da árvore, o nó principal é a emoção que se deseja classificar, os

ramos são as Distâncias Euclidianas obtidas através das unidades de movimento, assim, essas distâncias são conduzidas até as folhas - através dos arcos que contêm os pesos - que satisfazem determinada condição. Algumas emoções possuem mais ramificações do que outras, pelo fato dessas emoções possuírem unidades de movimento semelhantes em emoções diferentes.

Para o treinamento da árvore, foi desenvolvido um conjunto de testes compostos por 20 imagens extraídas da base de dados (KANADE; COHN, 2005), relacionadas a cada uma das seis emoções. Essa base possui imagens de diferentes etnias e sexos. Além disso, essas imagens estão em sequências que representam cada emoção no seu estado inicial até o máximo da emoção.

A seleção das imagens foi feita utilizando um agrupamento das imagens, com início, meio e fim da sequência que representa a emoção. Essa escolha foi utilizada para evitar que árvore de decisão gerasse pesos somente para a emoção em seu estado máximo ou mínimo, resultando assim uma classificação errônea.

3.2.4 Integração ao Ambiente Moodle

A plataforma Moodle é uma plataforma de aprendizagem projetada para fornecer aos educadores, administradores e estudantes um único sistema robusto, seguro e integrado para criar ambientes de aprendizagem personalizados (MOODLE, 2015).

Para realizar a integração foi desenvolvido um pequeno módulo (pacotes de configurações específicas) no qual o administrador do ambiente virtual é capaz de instalar o módulo responsável pela detecção das emoções. Esse módulo consiste em pequenas alterações realizadas para permitir que os *scripts* de detecção e classificação de emoções possam comunicar, armazenar e compartilhar informação com a base de dados do ambiente Moodle. Essa integração é exemplificada pelo diagrama na figura 13.



Figura 13 – Diagrama: Módulo de detecção de emoções integrado ao ambiente Moodle

A segunda parte desse módulo é responsável pela geração de relatórios, que podem ser personalizados de acordo com a necessidade do instrutor do curso, tais como: relatório emocional da turma ou relatório por aluno, em forma de gráficos, gerados dinamicamente a partir da base de dados em comum com o ambiente virtual de aprendizagem.

A Figura 14 mostra o módulo de detecção de emoções integrado ao ambiente Moodle e acionado com a permissão do usuário quando se iniciam as atividades na plataforma virtual sem demais detalhes técnicos.



Figura 14 – Módulo de detecção de emoções integrado ao Moodle.

Na Figura 15 temos um gráfico gerado a partir da ferramenta de geração de relatórios disponível para os tutores do ambiente virtual. Esses relatórios em forma de gráficos podem ser gerados, por estudante ou por turma, com a finalidade de analisar o perfil emocional do estudante e/ou turma durante o processo de ensino aprendizagem.

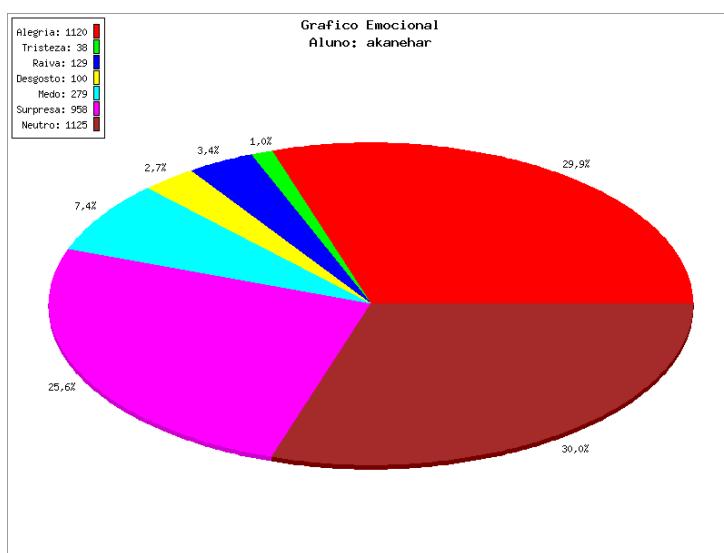


Figura 15 – Relatório gráfico das emoções gerado no ambiente.

3.3 Ambiente Virtual de Aprendizagem 3D

Segundo (BLAIR; LIN, 2011), Ambientes Virtuais de Aprendizagem 3D têm sido aliados de muitas universidades e centros educacionais, pois oferecem oportunidades inovadoras para a pedagogia, promovendo a realização e satisfação do estudante.

O desenvolvimento desse mundo virtual 3D utilizou um ambiente de código aberto denominado *OpenSimulator*. O OpenSimulator é um Servidor de Mundos Virtuais com Licença *opensource* (código aberto) que pode ser utilizado para criar e desenvolver Ambientes Virtuais em 3D, que vem sendo aprimorado por vários desenvolvedores.

Pronto para uso, o *OpenSimulator* pode ser utilizado para criar um ambiente semelhante ao *Second Life(tm)*, capaz de rodar em modo *standalone* ou conectado às outras instâncias de *OpenSimulator* através da tecnologia de processamento paralelo embutida. Também pode ser facilmente extendido para produzir aplicações interativas em 3D mais especializadas (OPENSIMULATOR, 2015).

Como proposta para esse ambiente foram desenvolvidas quatro ilhas dotadas das seguintes inteligências múltiplas (textual, visual, lógico-matemática e corporal-cinestésica) propostas por (GARDNER, 1994). Todo o desenvolvimento visual dessas ilhas se deu com base em recomendações propostas por (VALENTINI; SOARES, 2010), tais como: formato das ilhas, disposição dos objetos, quais cenários e onde inseri-los.

O ambiente principal com as quatro ilhas é apresentado na Figura 16, esse é o ponto inicial dos estudantes, onde é possível escolher e visitar as ilhas que melhor atendam às necessidades dos estudantes de acordo com as inteligências múltiplas.



Figura 16 – Ambiente inicial com as ilhas baseadas em inteligências múltiplas.

Em todas as quatro ilhas o conteúdo a ser aprendido foi: “tipos de variáveis da disciplina de introdução a programação”. Na ilha textual os alunos encontram textos explicativos nas salas projetadas especialmente para receberem esse tipo de objetos de aprendizagem, conforme exibido na Figura 17. Esses objetos foram projetados para serem de fácil manipulação e permitirem o máximo de interação entre os alunos e os mesmos.

A ilha referente á inteligência visual traz como objeto de aprendizagem o conteúdo em forma de vídeos interativos conforme a Figura 18, nessa ilha é possível que os estudantes



Figura 17 – Ilha desenvolvida para a inteligência múltipla textual.

vejam os vídeos quantas vezes forem necessárias, além de possibilitar uma discussão entre eles.



Figura 18 – Ilha desenvolvida para a inteligência múltipla visual.

Para a Inteligência Múltipla lógico-matemática, foram utilizadas como objetos de aprendizagem, fluxogramas e desenhos lógicos de forma a levar o estudante ao raciocínio lógico e à resolução de problemas para a compreensão do conteúdo, veja na Figura 19.

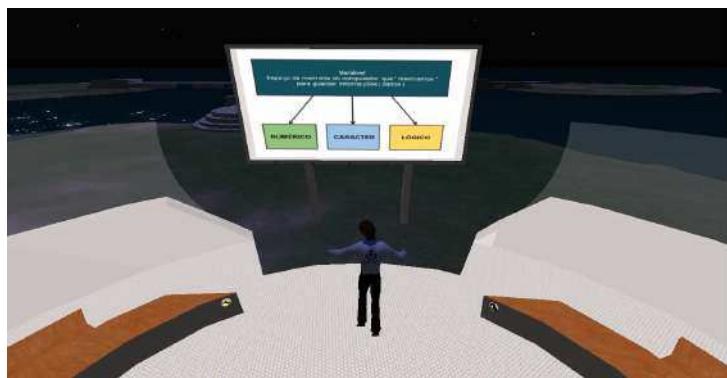


Figura 19 – Ilha desenvolvida para a inteligência múltipla lógico-matemática.

A ilha onde a Inteligência Múltipla (IM) predominante é a corporal-cinestésica, o ob-

jeto de aprendizagem é uma animação com o respectivo conteúdo abordado de maneira interativa e dinâmica, conforme a Figura 20. No desenvolvimento dessa animação foram utilizados recursos como música e movimentos bastante relevantes para esse tipo de inteligência.

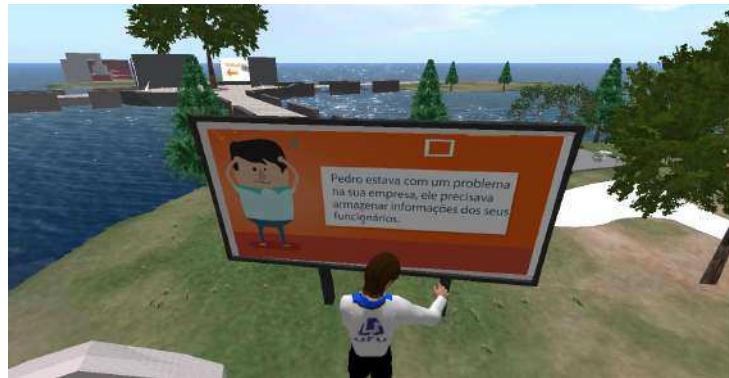


Figura 20 – Ilha desenvolvida para a inteligência corporal-cinestésica.

Todos os objetos de aprendizagem aplicados nas quatro ilhas desenvolvidas foram projetados observando as recomendações propostas por (SALDÍAS; AZEVEDO, 2002), recomendações estas que fornecem as características do aluno e quais atividades utilizar para cada uma das IM, conforme a Tabela 6.

Tabela 6 – Resumo de características e atividades para estimular as inteligências Múltiplas.

Modificado de: (SALDÍAS; AZEVEDO, 2002).

Inteligência Múltipla	Características do Aluno	Atividades ou ações estimuladoras
Linguístico-Verbal	Capacidade de se expressar usando a linguagem a aprender utilizando escuta, leitura e escrita. O aluno lê, fala e tem facilidade para memorizar o que foi ouvido ou falado.	Utilizar atividades que contenham discussões, texto, som falado e comunicações verbais em geral.
Lógico-matemática	Capacidade para manipular números, conceitos abstratos e resolver problemas de maneira lógica. Utiliza símbolos e hipóteses para representar objetos ou conceitos.	Utilizar atividades com exercícios, jogos lógicos, quebra-cabeças e fluxogramas. Estimulando a resolução de problemas por meio da previsão e verificação.
Visual-espacial	Capacidade de formar modelos mentalmente do mundo espacial. Aprende pela observação (fisionomia, formas, cores, cenas, etc) e pensa através de imagens.	Utilizar atividades que ofereçam estímulos visuais. Representações gráficas, mapas, cores, formas, desenhos, vídeos e realidade virtual.
Cinestésico-corporal	Capacidade para resolver problemas utilizando o corpo ou parte do corpo. Prefere para aprender atividades onde se utiliza o corpo do que ouvindo.	Utilizar atividades que possibilitem observações espaciais na tela, animações e realidade virtual e comunicação não verbal. Atividades que envolvam simulações e jogos.

A programação desse ambiente foi realizada através da Linguagem de Scripts do Second Life (LSL), uma linguagem interpretada e orientada a eventos. Sua sintaxe assemelha-se à C, C++ e Java. O LSL permite aos usuários (chamados residentes dentro do simulador), editar objetos diversos, atitudes (ações) do avatar (personagem, dentro do simulador), além de uma infinidade de funcionalidades dentro do mundo virtual. É uma linguagem de fácil aprendizado, embora não exista muito disponível na internet ou na literatura até o momento (SECOND LIFE, 2015).

O mundo virtual possui um ou mais personagens não jogadores com scripts, com o propósito de auxiliar o estudante na interação com o ambiente virtual e com os respectivos objetos de aprendizagem implementados no mesmo. Com o uso de IA é possível que esses

personagens desenvolvam habilidades similares às ações de um humano dentro do ambiente virtual 3D.

3.3.1 Modelagem dos Objetos 3D

A modelagem de objetos consiste em reconstruir os objetos de aprendizagem utilizados no ambiente Moodle tais como livros, vídeos em modelos 3D, de forma que possam ser inseridos no ambiente virtual 3D. Para realizar essa modelagem, o software utilizado foi o Google Sketchup, um software projetado para desenhos em terceira dimensão e com licença gratuita (SKETCHUP, 2016).

A Figura 21 ilustra esse processo de transformação do objeto de aprendizagem real em 3D. Esse é um processo que demanda bastante tempo, pois envolve a criação de formas, objetos, personagens e cenários tridimensionais, através de representações matemáticas, além disso esse processo requer grandes recursos computacionais de hardware para o processamento das informações, o que pode ocasionar o aumento no tempo de execução. Outro fator que provoca o aumento no tempo de execução dessa etapa é a riqueza de detalhes de cada objeto de aprendizagem, uma vez que o ambiente virtual 3D deve tentar reproduzir o objeto da forma mais real possível.

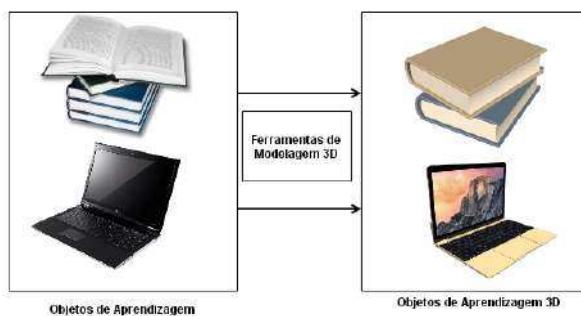


Figura 21 – Diagrama: Modelagem dos objetos de aprendizagem em 3D.

O processo de modelagem é basicamente dividido em três etapas, sendo que cada uma delas possui etapas mais específicas conforme abaixo:

- ❑ Modelagem
- ❑ Configuração do layout da cena (Mapeamento, iluminação, geração de câmeras)
- ❑ Geração de cena (Renderização, animação)
- ❑ Prototipagem

A modelagem em 3D conta com uma enorme variedade de ferramentas genéricas, que permite a comunicação entre dois programas distintos e usuários iguais, usando as técnicas mais conhecidas como: técnica por polígonos, técnica por vértices e técnica por bordas.

Todas elas são elaboradas através da criação de malhas de segmentos que dão a forma final ao objeto.

Para que a modelagem dos objetos fosse concluída de maneira significativa, alguns objetos padrões foram modelados para serem aproveitados em todo o ambiente, evitando a remodelagem. Dentre esses objetos, temos a lousa digital apresentada na Figura 22, utilizada no ambiente para proporcionar aos estudantes interatividade com o ambiente em forma de vídeo, imagens, jogos e qualquer outro meio multimídia.

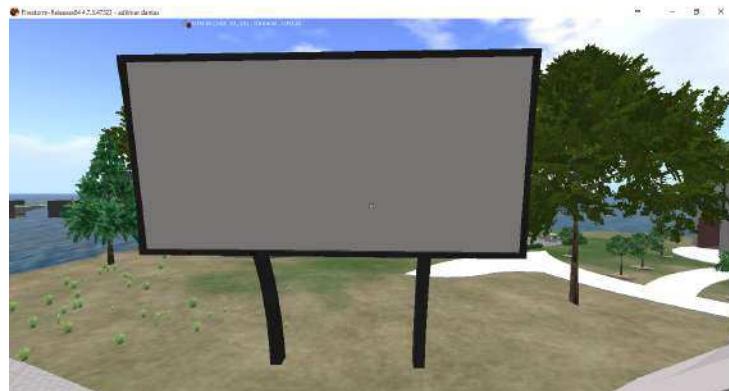


Figura 22 – Lousa digital para o ambiente virtual 3D.

Após a finalização dessas etapas, temos como produto o objeto de aprendizagem modelado tridimensionalmente para ser inserido no ambiente virtual, com a utilização de linguagens de programação específicas com a plataforma utilizada para execução e gerenciamento do ambiente virtual de aprendizagem.

O ambiente de estudo também foi modelado tridimensionalmente, através de salas elaboradas com conceitos modernos, propondo uma interação entre o ambiente e os estudantes, permitindo o estudo individual ou em grupos conforme, a necessidade da atividade proposta, veja a Figura 23. A arquitetura do ambiente também foi modelada incluindo elementos como prédios, bancos, mesas, elementos comuns encontrados em ambientes educacionais e em universidades, em geral.



Figura 23 – Sala de aula modelada em 3D.

A modelagem gráfica do vestuário dos alunos também foi desenvolvida, objetos como camisa, calças personalizadas com a logo da universidade estão presentes no ambiente, conforme na Figura 24. O objetivo de utilizar esses elementos reais no momento da modelagem é que para no final o estudante tenha a sensação de estar presente no ambiente virtual, de maneira natural.



Figura 24 – Vestuário desenvolvido para o ambiente.

Esses objetos desenvolvidos são fixos na plataforma, de maneira que o usuário não possa alterá-los, mas o ambiente virtual de aprendizagem oferece total liberdade para que os alunos desenvolvam e personalizem seus próprios objetos de maneira interativa, integrada na própria plataforma.

3.4 Módulo Raciocínio Baseado em Casos

Este módulo é responsável por gerar recomendações pedagógicas para o estudante, ele é composto por uma base de conhecimento inicial contendo informações a respeito do conhecimento e operações para calcular a similaridade do caso proposto com os presentes na base inicial. Uma interface visual foi desenvolvida para facilitar a utilização do mesmo.

3.4.1 Desenvolvimento da Base de Conhecimentos

Para o desenvolvimento da base de dados para a representação do conhecimento inicial, utilizamos como conhecimento inicial as seguintes informações armazenadas na base: percentual das emoções (alegria, tristeza, raiva, medo, desgosto, surpresa, neutro), a inteligência múltipla do usuário, o perfil emocional do usuário e a devida regra associada a esse perfil emocional fornecidas por (MELO, 2016). Dentre todas as informações contidas na base, com exceção da inteligência múltipla que foi simulada aleatoriamente, as demais foram adquiridas em experimentos durante um semestre nas aulas do curso de Física pela Universidade Federal de Uberlândia, dentro da plataforma Moodle, integrado com o módulo de detecção de emoções. Essa base é apresentada na Tabela 7.

Tabela 7 – Base de conhecimentos inicial

Perfil	% Alegria	% Tristeza	% Raiva	% Medo	% Desgosto	% Surpresa	% Neutro	IM	Regra
Astucioso	46.1	21.0	1.4	15.7	0.8	7.7	7.3	textual	R16
Excessivo	27.3	44.9	19.2	1.0	0.1	0.3	7.2	visual	R13
Meticuloso	4.9	15.9	28.8	9.2	5.2	5.2	30.7	lógico	R20
Dócil	30.9	10.9	3.1	12.1	1.5	4.7	36.7	corporal	R33
Teatral	6.8	23.3	20.7	11.5	1.0	2.9	33.9	textual	R7
Temerário	15.5	7.3	14.1	14.4	1.8	4.8	42.1	visual	R1
Flexível	13.9	21.8	27.8	5.5	0.0	3.9	27.1	lógico	R42
Afetivo	13.0	12.7	14.1	6.4	4.8	27.7	21.3	corporal	R29
Eremita	27.2	2.7	2.6	32.3	0.8	17.0	17.3	textual	R39

Os percentuais presentes na base, referentes às emoções básicas, foram obtidos através do módulo desenvolvido e integrado na plataforma, conforme proposto neste trabalho. O perfil e as regras presentes na Tabela 7 foram identificados através da aplicação de um questionário com essa finalidade e propostos por (MELO, 2016), as IM foram simuladas para que fosse possível analisar alguma relação entre essas informações.

3.4.2 Cálculo da Similaridade

Após a definição da base de casos inicial apresentada no capítulo anterior, tem-se a formalização da função responsável pelo cálculo de similaridade. Essa similaridade tem como função indicar o grau de semelhança entre o problema presente e os casos existentes na base de conhecimento. Para isso devemos calcular a correspondência mais próxima entre os casos e a base de casos predefinida, cada caso é caracterizado por um nome e tipo, onde o tipo de dados pode ser qualquer um, por exemplo: *String*, *int*, *float*, *bool*, *etc*.

Essa correspondência mais próxima é calculada, utilizando-se a distância euclidiana ponderada, onde a porcentagem retornada ou “hit” é calculado como:

$$100 * (1 - \sqrt{distancia dos casos / sum(weights)})) \quad (2)$$

retornando assim um valor entre 0 e 100, correspondente à porcentagem de similaridade da pesquisa com os casos presentes na base.

A distância entre a pesquisa e um caso é um número de ponto flutuante entre 0 e 1 e é calculado como:

$$casedistance = weight_1 * dist_1^2 + weight_2 * dist_2^2 + .. + weight_n * dist_n^2 \quad (3)$$

onde $dist_i$ é a distância entre o recurso procurado e o recurso na base de casos, esse valor é um ponto flutuante entre 0 e 1, onde 0 significa que são iguais e, 1 a distância máxima entre os dois. Os pesos $weights$ é um número inteiro ≥ 0 (maior ou igual), para a aplicação foi definido o valor 5 como padrão para a maioria dos casos, obtido empiricamente por testes realizados.

A distância entre o recurso procurado e o caso real é calculado como: Se o valor do caso ou do recurso procurado for igual a ?, então o mesmo é desqualificado e a sua distância

não é incluída nos resultados. O algoritmo que usamos para calcular a distância, vamos chamá-lo de *NormalDistance*, é definido como:

$$distância = \min(1, diferença(valor procurado, caso base) / (valor máximo - valor mínimo)) \quad (4)$$

Esses cálculos retornam no final da execução à similaridade do novo caso apresentado em relação aos casos presentes na base.

Para realizar a correspondência entre o caso procurado e os casos presentes na base foi utilizada a lógica Fuzzy Linear, com a finalidade de realizar essa avaliação para as seguintes situações: igualdade, desigualdade, maior, maior igual, menor, menor igual, máximo e mínimo ($=, \neq, >, \geq, <, \leq, \max, \min$), entre o caso procurado e os casos presentes na base, essa avaliação é apresentada na Tabela 8 para cada uma das situações.

Tabela 8 – Condições para o cálculo da distância usando Lógica Fuzzy.

Condição	Decisão
Se valor procurado = valor na base	distância = 0, então usar o algoritmo <i>NormalDistance</i>
Se valor procurado \neq valor na base	distância = 1, então usar o algoritmo <i>NormalDistance Invertido</i>
Se valor procurado $>$ valor na base	distância = 0, senão usar o algoritmo <i>NormalDistance</i>
Se valor procurado \geq valor na base	distância = 0, senão usar o algoritmo <i>NormalDistance</i>
Se valor procurado $<$ valor na base	distância = 0, senão usar o algoritmo <i>NormalDistance</i>
Se valor procurado \leq valor na base	distância = 0, senão usar o algoritmo <i>NormalDistance</i>

A Tabela 9 demonstra uma execução do RBC para as seguintes entradas: (Perfil: não conhecemos identificado pelo sinal ?; Alegria: 22.5%; Tristeza: 19.0%; Raiva: 10.0%; Medo: 9.0%; Desgosto: 8.0%; Surpresa: 10.5%; Neutro: 21.0%; Inteligência Múltipla: Textual; Regra: Não conhecemos ?).

Tabela 9 – Exemplo de execução RBC

Rank	Hit %	Perfil	Alegria%	Tristeza%	Raiva%	Medo%	Desgosto%	Surpresa%	Neutro%	IM	Regra
Valores pesquisados											
	?		22.5	19.0	10.0	9.0	8.0	10.5	21.0	Textual	?
Resultados											
1	72.96 %	Teatral	6.8	23.3	20.7	11.5	1.0	2.9	33.9	textual	R7
2	71.74%	Astucioso	46.1	21.0	1.4	15.7	0.8	7.7	7.3	textual	R16
3	70.56%	Eremita	27.2	2.7	2.6	32.3	0.8	17.0	17.3	textual	R39

Como dito anteriormente, o RBC deve apresentar como resultado a similaridade a partir dos casos bases presentes na base de conhecimento, e se esse conhecimento for relevante para a base, armazená-lo para consultas futuras. Para esse exemplo, o caso com maior similaridade apresentou uma taxa de 72.96% com o perfil teatral e aplicado à regra R7.

3.4.3 Interface de comunicação com o RBC

Para acessar o sistema RBC de maneira integrada foi desenvolvida uma interface escrita em JavaServer Faces (JSF), uma tecnologia que permite criar aplicações Java para Web utilizando componentes visuais (CAELUM, 2015). Essas tecnologias permitem aos desenvolvedores criarem aplicações Rich Internet Applications (RIA).

Essas aplicações possibilitam maior nível de interação com os usuários, aumenta a produtividade, além de ser suportada por todos os tipos de navegadores existentes hoje no mercado (ADOBE, 2015). Dentre os benefícios de se utilizar esse tipo de tecnologia, podemos citar: oferecer aos usuários uma interface mais rica em detalhes e mais intuitiva, simular elementos desktop em ambientes web.

A interface desenvolvida conta com duas telas principais: uma, responsável por gerar a visualização da base inicial e quais os respectivos atributos pertencentes à mesma, exibidos na Figura 25. Essa interface é importante pois nela é possível ver os casos retidos na base a partir da execução do RBC.



INTELIGÊNCIA ARTIFICIAL
Universidade Federal de Uberlândia - FAQUIM

Características			Casos presentes na base											
Número de Características presentes na Base:			Total: 85											
Característica №	Característica - Nome	Característica - Tipo	Avaliação Ponderada											
Característica №	Característica - Nome	Característica - Tipo	Avaliação Ponderada	Perfil	Alegria	Tristeza	Raiva	Média	Desgosto	Surpresa	Neutro	IM	Regras	
0	Perfil	String	0.0000000000000001	String	Float	Float	Float	Float	Float	Float	Float	String	String	
1	Alegria	Float	0.71 - 46.1	0	21.6	2.4	25.3	0.6	2.7	1.2	1.6	81.6		
2	Tristeza	Float	0.0 - 44.9	1	Excessivo	27.3	44.5	19.2	1.0	0.1	0.3	17.2	visual	R13
3	Raiva	Float	0.5 - 28.8	2	Moderado	13.5	28.3	9.2	3.2	5.2	10.7	10.7	visual	R20
4	Medo	Float	0.0 - 35.64	3	Normal	39.9	10.5	31.1	12.1	1.5	4.7	36.7	visual	R33
5	Desgosto	Float	0.0 - 43.22	4	Tensa	6.8	29.3	30.7	11.3	1.0	2.0	33.9	visual	R7
6	Surpresa	Float	0.0 - 35.94	5	Tensionada	15.1	7.3	14.1	14.1	1.8	4.8	42.1	visual	R1
7	Neutro	Float	0.0 - 42.1	6	Tensid.	13.3	21.8	27.3	5.5	0.9	5.9	27.1	visual	R47
8	IM	String	numerico -	7	Aberta	11.9	12.7	14.1	8.4	4.8	27.7	21.3	visual	R29
9	Regra	String	0.0 - -	8	Entusias.	27.2	2.7	2.6	12.3	0.8	17.0	17.3	visual	R38
				9	Tensionada	11.7	3.64	0.73	35.64	10.35	11.64	6.55	visual	R7

Figura 25 – Interface para a visualização da base do RBC.

A segunda tela principal é responsável por receber as entradas informadas pelo usuário - Figura 26 - e repassá-las para o módulo RBC para que este processe as entradas e retorne as informações desejadas de maneira significativa.

Procurar caso na base

Feature	Search weight	Search scale	Search options	Search term	Search value
Perfil [String]	5	Fuzzy linear	<input type="checkbox"/> Inverted	=	?
Alegria [Float]	5	Fuzzy linear	<input type="checkbox"/> Inverted	=	?(0.71 - 46.1)
Tristeza [Float]	5	Fuzzy linear	<input type="checkbox"/> Inverted	=	?(0.0 - 44.9)
Raiva [Float]	5	Fuzzy linear	<input type="checkbox"/> Inverted	=	?(0.5 - 28.8)
Medo [Float]	5	Fuzzy linear	<input type="checkbox"/> Inverted	=	?(0.0 - 35.64)
Desgosto [Float]	5	Fuzzy linear	<input type="checkbox"/> Inverted	=	?(0.0 - 43.22)
Surpresa [Float]	5	Fuzzy linear	<input type="checkbox"/> Inverted	=	?(0.0 - 35.94)
Neutro [Float]	5	Fuzzy linear	<input type="checkbox"/> Inverted	=	?(0.0 - 42.1)
IM [String]	5	Fuzzy linear	<input type="checkbox"/> Inverted	=	?
Regra [String]	5	Fuzzy linear	<input type="checkbox"/> Inverted	=	?

Figura 26 – Interface de entrada de dados para o RBC.

Para que fosse possível visualizar as execuções realizadas no sistema RBC, uma interface foi desenvolvida para permitir o acompanhamento em tempo real dessas execuções em formato de registros. Assim, é possível consultar esse histórico no futuro para possíveis melhorias ou avaliações do próprio módulo. Esse tipo de funcionalidade gera uma redundância dos dados, uma vez que diariamente é realizada uma cópia de segurança dessas informações, sendo possível a restauração quando necessário. A Figura 27 apresenta um desses registros armazenados no módulo RBC.

Testes realizados
1-Afetivo,19.31,17.72,25.93,16.14,4.5,15.34,1.06,corporal,R20
2-Flexivel,3.79,25.36,23.91,12.24,27.99,4.08,2.62,logica,R33
3-Eremita,11.42,9.69,23.18,26.99,14.53,11.76,2.42,logica,R20
4-Flexivel,14.02,12.62,17.29,20.56,18.93,8.18,8.41,logica,R20
5-Flexivel,17.51,12.95,0.96,17.27,16.07,21.58,13.67,corporal,R33
6-Excessivo,3.64,20.15,11.17,22.57,4.61,16.02,21.84,corporal,R33
7-Eremita,10.34,20.94,19.95,10.1,14.04,20.94,3.69,visual,R39
8-Docil,10.46,5.23,17.65,20.92,5.23,32.03,8.5,corporal,R42
9-Eremita,6.8,15.57,21.71,12.94,10.96,21.05,10.96,logica,R20
10-Eremita,10.96,5.32,31.23,29.9,13.62,0.0,8.97,visual,R7
11-Astucioso,12.55,16.08,6.67,30.2,9.02,11.37,14.12,corporal,R33
12-Temerario,18.18,20.63,16.78,11.89,4.9,13.29,14.34,corporal,R29
13-Excessivo,21.97,17.46,4.51,3.38,13.24,11.55,27.89,visual,R13
14-Teatral,16.58,21.68,22.19,2.3,11.73,11.48,14.03,visual,R16
15-Excessivo,11.37,13.71,10.03,15.05,19.06,3.01,27.76,logica,R20
16-Eremita,11.09,12.47,20.09,2.08,23.09,9.47,21.71,visual,R16
17-Docil,1.09,15.76,21.2,8.42,25.82,17.66,10.05,corporal,R16

Figura 27 – Interface de entrada de dados para o RBC.

Uma das principais vantagens do desenvolvimento desse tipo de interface é a comunicação com outras aplicações, em específico, com o mundo virtual desenvolvido neste trabalho. Esse tipo de aplicação facilita a comunicação através de requisições pelo protocolo HTTP, bastante utilizado por sistemas de informação do tipo hipermídia, de forma distribuída e colaborativos (BERNERS-LEE et al., 2001), sendo a principal base de comunicação de dados da World Wide Web.

CAPÍTULO 4

Experimentos e Análise dos Resultados

Neste capítulo, serão apresentados os resultados obtidos para o sistema de detecção e classificação de emoções, a partir das expressões faciais em duas bases de imagens com características distintas. Esse processo é uma comparação com outras técnicas semelhantes, para a detecção e classificação das emoções utilizadas por outros pesquisadores da mesma área, a fim de validar a acurácia de se utilizar as UM's criadas com base nas UA's propostas por (EKMAN; FRIESEN, 1978a). Em seguida, serão apresentados os resultados e análises observadas a partir do RBC proposto neste trabalho, responsável por realizar as recomendações necessárias para os ambientes virtuais de aprendizagem.

4.0.1 Testes de acurácia com imagens na base Cohn Kanade e MUG.

Para o desenvolvimento do módulo capaz de reconhecer as emoções do estudante em tempo real, primeiramente foi necessária a escolha de algoritmos de aprendizagem de máquina, para que fosse possível a classificação correta das emoções nos ambientes virtuais de aprendizagem. A técnica utilizada neste trabalho, Árvore de Decisão, foi comparada à técnica SVM, em duas bases de dados de imagens de emoções.

A Cohn Kanade (KANADE; COHN, 2005), é uma base de dados com 1452 imagens com seis emoções (Alegria, Tristeza, Raiva, Surpresa, Medo, Desgosto) em escala de cinza, com pessoas de diversas etnias. As emoções estão distribuídas de forma temporal, do seu estado inicial até o ponto máximo da emoção, contendo em geral uma sequência de 3 a 5 imagens. A base de imagens MUG (GROUP, 2014) contem 376 imagens coloridas com seis emoções (Alegria, Tristeza, Raiva, Surpresa, Medo, Desgosto), também com uma variação de etnias e distribuídas de modo temporal.

Esse primeiro teste consiste em avaliar a acurácia do algoritmo classificador para as duas bases citadas acima, utilizando a Árvore de Decisão com as UM's e SVM aplicadas sobre o contorno facial. A Tabela 10 demonstra o total de imagens por emoção para a base de dados Cohn Kanade que foi testada com as duas técnicas.

Tabela 10 – Total de imagens por emoção da base Cohn Kanade.

Emoção	Imagens
Alegria	324
Desgosto	182
Raiva	183
Surpresa	328
Tristeza	253
Medo	182
Total	1452

A Figura 28 exibe o gráfico para os testes realizados com a base de imagens Cohn Kanade, utilizando a técnica baseada nas UM's para a classificação das emoções em tempo real. Esse teste apresenta como objetivo verificar a acurácia e a eficácia de se utilizar as Unidades de Movimento baseadas nas Unidades de Ação para a classificação das emoções em tempo real.

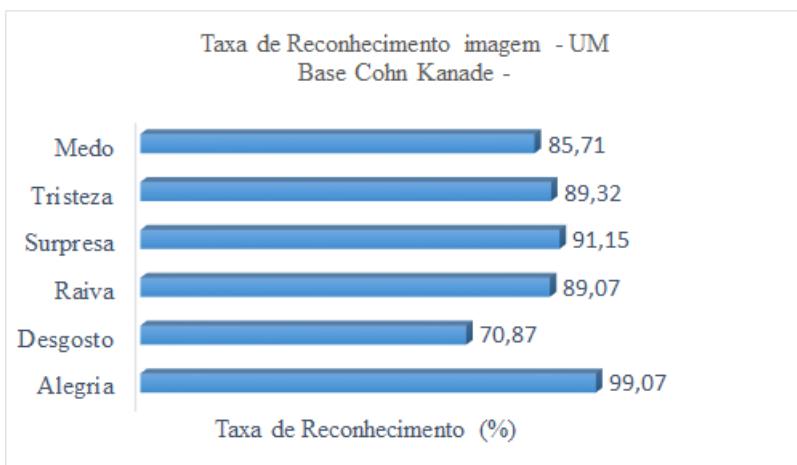


Figura 28 – Taxa de Reconhecimento usando Árvore de Decisão e UM na base de imagens Cohn Kanade.

Na execução desse teste algumas análises importantes foram observadas dos resultados apresentados. Ao compararmos as taxas de reconhecimento de algumas emoções como desgosto e medo, com a taxa das demais emoções, observa-se que as primeiras são baixas. Isto se deve ao fato que desgosto e medo estão altamente correlacionadas com outras emoções. Isso quer dizer que, para inferir essas emoções, várias Unidades de Movimento UM em comum são ativadas, pelo fato dessas serem elaboradas com base nas Unidades de Ação UA, que levam em consideração os músculos faciais, gerou uma classificação errônea para emoções altamente correlacionadas.

Para que avaliar a acurácia da classificação a técnica utilizando as UM's foi comparada com o sistema de classificação de emoções a partir do contorno facial e o algoritmo classificador SVM. Esses resultados são apresentados na Figura 29.

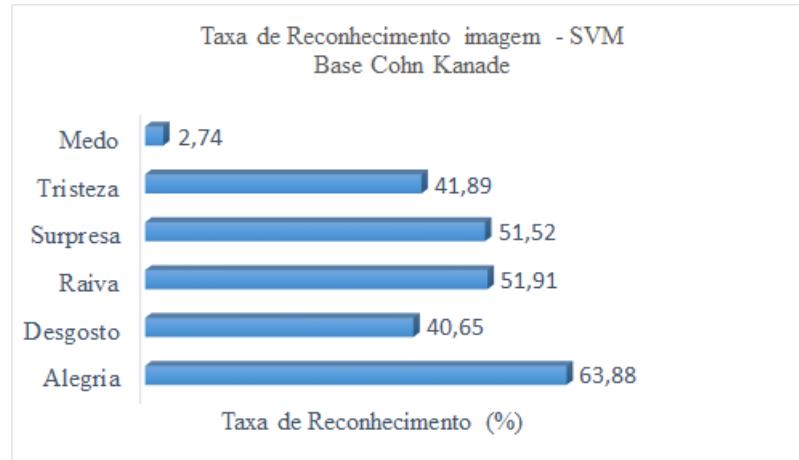


Figura 29 – Taxa de Reconhecimento usando contorno facial e SVM na base de imagens Cohn Kanade.

Observando os gráficos das Figuras 28 e 29, podemos concluir que os resultados obtidos com o contorno facial e SVM são inferiores aos apresentados pelas Unidades de Movimento, principalmente nas emoções altamente correlacionadas.

Essa observação nos permitiu analisar que as UM's, para a classificação das emoções, é uma boa proposta uma vez que, aplicada com a técnica árvore de decisão - que utiliza como entrada as distâncias euclidianas - ela consegue reconhecer movimentos mínimos da face, o que não acontece quando se utiliza o contorno facial, onde essas informações são perdidas, e essas informações são cruciais para o processo de classificação das emoções.

Como a base Cohn Kanade é composta por imagens em escala de cinza, decidimos testar os mesmos algoritmos em uma base com imagens coloridas - a base MUG - conforme dito anteriormente, com a finalidade de comprovar os primeiros resultados obtidos e verificar em qual delas a classificação é mais satisfatória.

A Tabela 11 demonstra o total de imagens por emoção (Alegria, Desgosto, Raiva, Surpresa, Tristeza, Medo), totalizando 376 imagens. A Figura 30 mostra os resultados obtidos com a base MUG, utilizando as UM's e árvore de decisão para a classificação das emoções em tempo real.

Tabela 11 – Total de imagens por emoção da base MUG.

Emoção	Imagens
Alegria	87
Desgosto	71
Raiva	57
Surpresa	66
Tristeza	48
Medo	47
Total	376

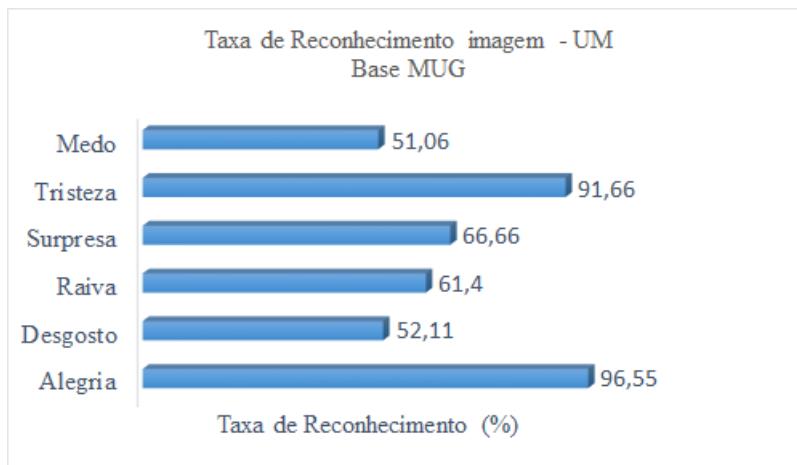


Figura 30 – Taxa de Reconhecimento usando Árvore de Decisão e UM na base de imagens MUG.

Com esta base foi realizado o teste para a técnica do contorno facial e SVM com a finalidade de verificar novamente se a técnica utilizando as Unidades de Movimento seria superior ao mesmo. O gráfico na Figura 31 descreve os resultados obtidos.

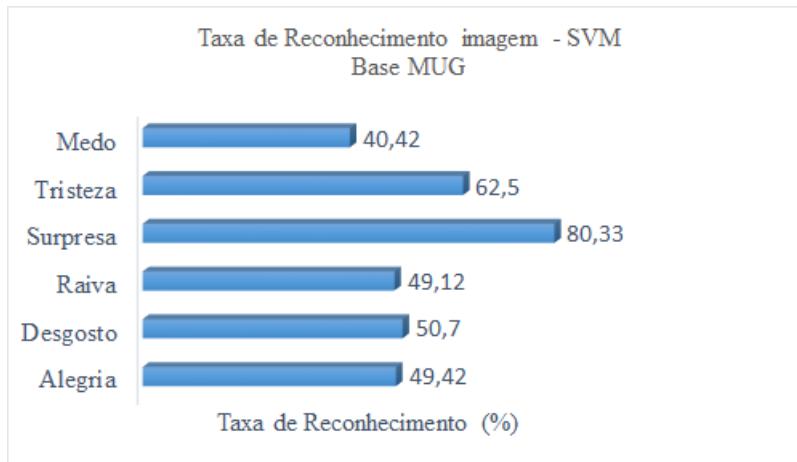


Figura 31 – Taxa de Reconhecimento usando contorno facial e SVM na base de imagens MUG.

Novamente os resultados apresentados com a técnica utilizando as UM's foram superiores, mesmo havendo uma queda em algumas emoções quando comparadas com os resultados obtidos na base Cohn Kanade. Essa análise permitiu verificar que a transformação das imagens em escala de cinza, antes de sua classificação, é uma boa proposta. A mesma foi realizada para garantir uma melhor classificação das emoções.

4.0.2 Testes de acurácia em vídeos gerados a partir da base Cohn Kanade e MUG.

A segunda parte dos testes foi realizada com vídeos gerados a partir das duas bases de imagens: a Cohn Kanade e a MUG. Para a geração desses vídeos foi realizado um trabalho minucioso, que consiste na separação da sequência de imagens para a elaboração dos vídeos no *software* (FFMPEG, 2016), um programa capaz de criar, converter e gerar vídeos em diversos formatos, pelo fato de ser composto por diversas bibliotecas de código aberto. Esse teste foi realizado para verificar as taxas de acerto para vídeos transmitidos em tempo real, diferente das imagens estáticas que estão menos sujeitas a interferências, já que o trabalho aqui proposto tem como um dos objetivos classificar essas emoções em tempo real nos ambientes virtuais de aprendizagem.

A Tabela 12 demonstra o total de vídeos gerados a partir das imagens presentes na base Cohn Kanade e MUG para cada uma das emoções.

Tabela 12 – Quantidade de vídeos gerados a partir das bases de imagens Cohn Kanade e MUG.

Emoção	Vídeos - Cohn Kanade	Vídeos - MUG
Alegria	43	25
Desgosto	26	24
Raiva	22	20
Surpresa	43	24
Tristeza	34	18
Medo	26	13
Total	194	124

O gráfico exibido na Figura 32 mostra os resultados obtidos nos testes realizados nos vídeos gerados a partir da base Cohn Kanade, conforme a Tabela 12, utilizando a técnica apresentada neste trabalho, utilizando as UM's e Árvore de Decisão. Na Figura 33 temos o gráfico com os resultados obtidos, utilizando contorno facial e SVM.

Assim como os testes com imagem a partir das duas bases Cohn Kanade e MUG, repetimos a mesma sequência com os vídeos gerados a partir da base MUG. Na Figura 34, temos os resultados para o teste com vídeos, utilizando as UM's e Árvore de Decisão, e no gráfico da Figura 35, os resultados para contorno facial e SVM.

Um detalhe interessante observado para os testes com vídeos foi o aumento na taxa de classificação apresentada para algumas emoções que se apresentam altamente correlacionadas como, por exemplo, as emoções “medo” e “desgosto”. Essas emoções tiveram um aumento significativo porque em vídeos há uma variabilidade maior das distâncias euclidianas processadas, ou seja, movimentos mí nimos geram distâncias euclidianas que podem contribuir favoravelmente para a classificação final das emoções altamente correlacionadas.

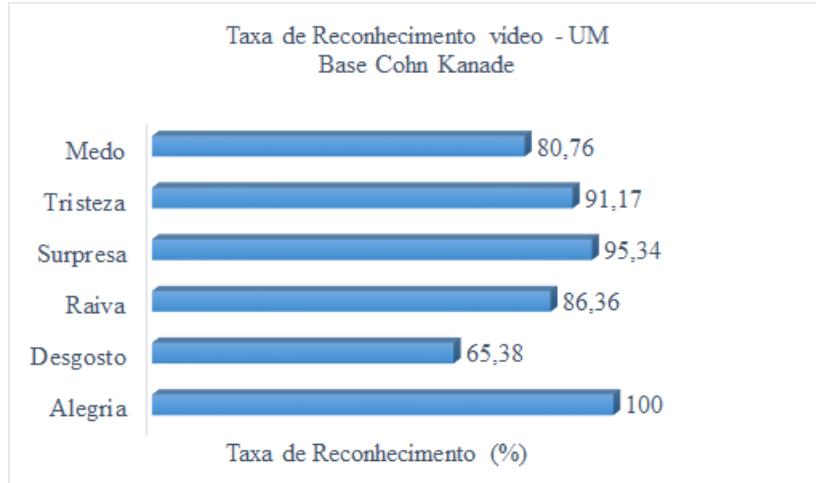


Figura 32 – Taxa de Reconhecimento em vídeos usando UM e Árvore de Decisão na base Cohn Kanade.

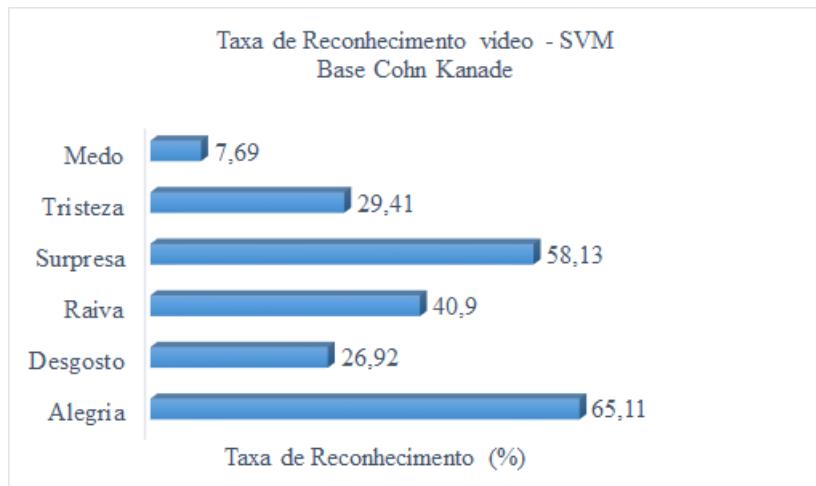


Figura 33 – Taxa de Reconhecimento em vídeos usando contorno facial e SVM na base Cohn Kanade.

4.0.3 Testes em ambientes reais para o tratamento de oclusões

Para que fosse possível obter todos os resultados acima, antes de tudo, houve a necessidade de aperfeiçoar os classificadores para que os mesmos fossem capazes de reconhecer a face mesmo com oclusões. Para isso, o classificador responsável pela localização da face foi treinado com um conjunto de imagens reais, que foram obtidas experimentalmente através de um experimento liberado na internet, por meio de uma página web, onde os usuários eram convidados a demonstrar as seis emoções básicas de forma livre para que o sistema fosse capaz de capturar essas imagens e armazena-las corretamente.

Nesse experimento, os usuários, estavam em ambientes reais e suscetíveis a maiores oclusões. As imagens geradas a partir desses experimentos foram então armazenadas para que fosse possível utilizá-las para o aperfeiçoamento dos classificadores responsáveis pela localização da face e, respectivamente dos pontos presentes na mesma. No total

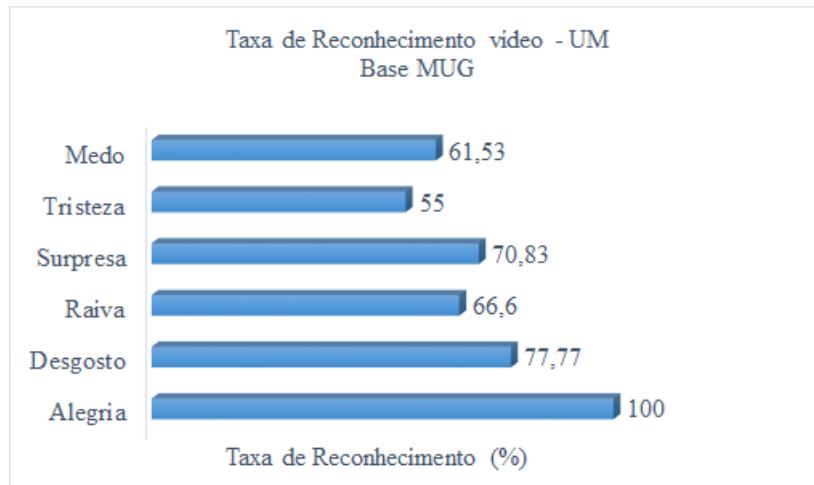


Figura 34 – Taxa de Reconhecimento em vídeos usando contorno facial e SVM na base MUG.

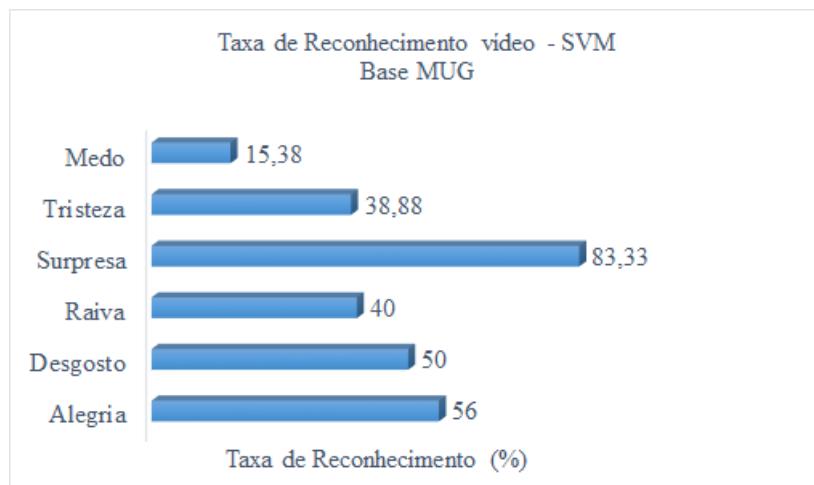


Figura 35 – Taxa de Reconhecimento em vídeos usando contorno facial e SVM na base MUG.

foram coletadas 3185 imagens de pessoas de diversas etnias, pois o mesmo foi divulgado mundialmente nas redes sociais.

Essas oclusões são, por exemplo: presença de pouca luminosidade, barba, bigode, óculos, presença de certos acessórios como boné, piercing, dentre outros. A quantidade de imagens obtidas para cada uma das emoções básicas estão exibidas na Tabela 13. Um teste de classificação na base de imagens MUG e usando as UM's antes do aperfeiçoamento dos classificadores foi executado, a fim de verificar os ganhos realizados após esse aperfeiçoamento. Os resultados obtidos podem ser observados no gráfico da Figura 36.

Analizando o gráfico e comparando com os resultados obtidos na Figura 30, pode-se notar que houve um aumento significativo na taxa de reconhecimento das emoções. Esse ganho acontece, pois, antes que ocorra a classificação das emoções, deve ocorrer a correta localização da face para então a plotagem dos pontos, conforme mencionado

Tabela 13 – Total de imagens por emoção obtidas para o treinamento de oclusões

Emoção	Imagens
Alegria	1042
Desgosto	41
Raiva	313
Surpresa	318
Tristeza	768
Medo	703
Total	3185

anteriormente.

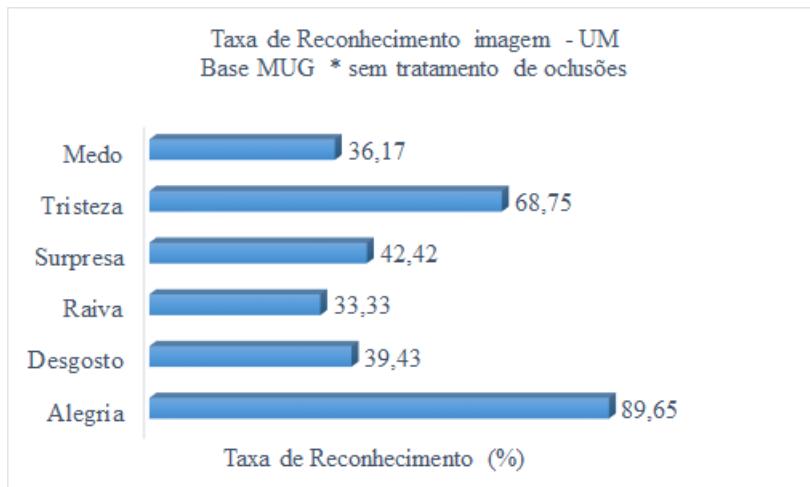


Figura 36 – Taxa de Reconhecimento em imagens usando UM na base MUG sem tratamento de oclusões.

4.0.4 Testes realizados no módulo RBC

A realização dessa etapa de testes se deu em ambiente real, o módulo de detecção de emoções proposto neste trabalho foi integrado ao ambiente virtual de aprendizagem do Curso de Física pela Universidade Federal de Uberlândia, na disciplina de Introdução ao Eletromagnetismo.

Esta foi escolhida por ser tida como uma disciplina em que os estudantes tem muita dificuldade. O professor Eduardo Kojo Takahashi, responsável pela disciplina, apresentou como proposta atividades interativas dentro do ambiente virtual de aprendizagem, para que fosse possível analisar as emoções dos estudantes durante o curso.

Para a aplicação desse teste, houve a necessidade da submissão do projeto ao conselho de ética da universidade, o mesmo encontra-se aceito sob o número CAAE: 43620215.7.0000.5152. Esses testes foram importantes, pois eles forneceram as informações necessárias para a construção da base do RBC, conforme exibido na Tabela 7. Tomando esses dados iniciais

para realização dos testes com o módulo RBC, foram simulados 300 dados aleatórios, com os seguintes atributos: porcentagem das emoções (alegria, tristeza, raiva, medo, desgosto, surpresa, neutro), uma das inteligência múltipla e uma regra, para que o RBC determinasse o perfil do aluno com base nessas informações e gerasse novos casos para a base, retendo os casos relevantes.

Essas simulações foram necessárias para que fosse possível avaliar esse módulo proposto e verificar quais desses atributos possuem maior relevância no momento da geração das recomendações pedagógicas nos ambientes virtuais de aprendizagem.

A partir de 300 dados simulados, o módulo RBC foi capaz de gerar e reter 56 novos casos para a base, antes com apenas nove casos presentes na base inicial. Os casos gerados estão exibidos no Anexo A deste trabalho, a Tabela 14 exibe o total de casos por perfil retidos na base do módulo RBC.

Tabela 14 – Total de casos retidos por perfil na base do RBC.

Perfil	Quantidade
Afetivo	7
Astucioso	4
Dócil	9
Eremita	6
Excessivo	7
Flexível	7
Meticuloso	4
Teatral	8
Temerário	4
Total	56

Dessas 300 simulações para determinar o perfil do estudante, os resultados obtidos foram: 63 delas classificaram o perfil como afetivo; 20 como astucioso; 21 como dócil; 27 como eremita; 19 como excessivo; 26 flexível; 47 meticuloso; 37 teatral e 40 como temerário, conforme o gráfico exibido na Figura 37.

Essa simulação demonstrou que o módulo RBC está funcionando adequadamente, retendo os novos casos importantes para a construção da base. Com a intenção de verificar quais dos atributos construiriam mais possíveis casos para serem retidos, um novo teste com 300 simulações foi executado, dessa vez, para que o módulo RBC determinasse a inteligência múltipla a partir das emoções e o perfil do estudante.

Das 300 simulações executadas para a classificação das inteligências múltiplas, os resultados foram os seguintes: 86 deles para o perfil cenestésico-corporal; 68 lógico-matemático; 101 como textual e 45 para visual-espacial, conforme o gráfico exibido na Figura 38.

Com essas simulações o RBC foi capaz de reter e acrescentar na sua base de conhecimento 91 novos casos relevantes, isto é, 35 casos a mais quando comparado com o resultado anterior. Esses casos gerados e retidos estão exibidos no Anexo B deste trabalho.

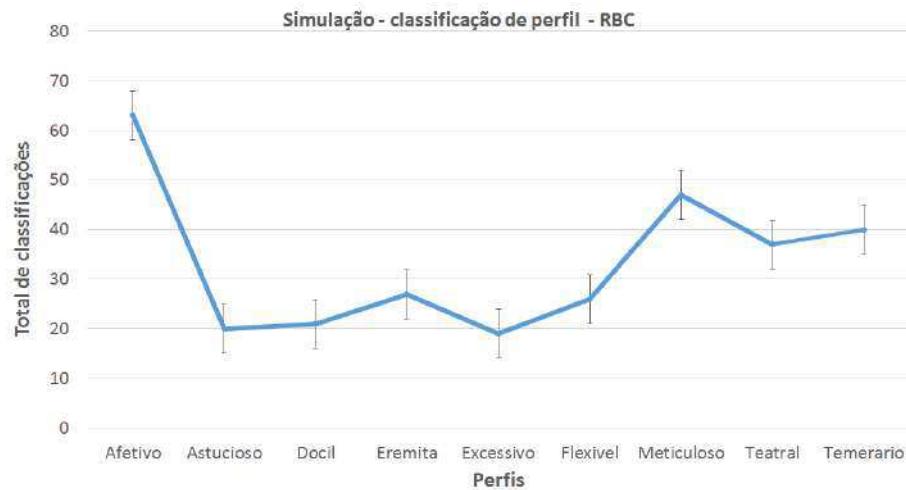


Figura 37 – Resultado da classificação de perfil para 300 simulações no módulo RBC.

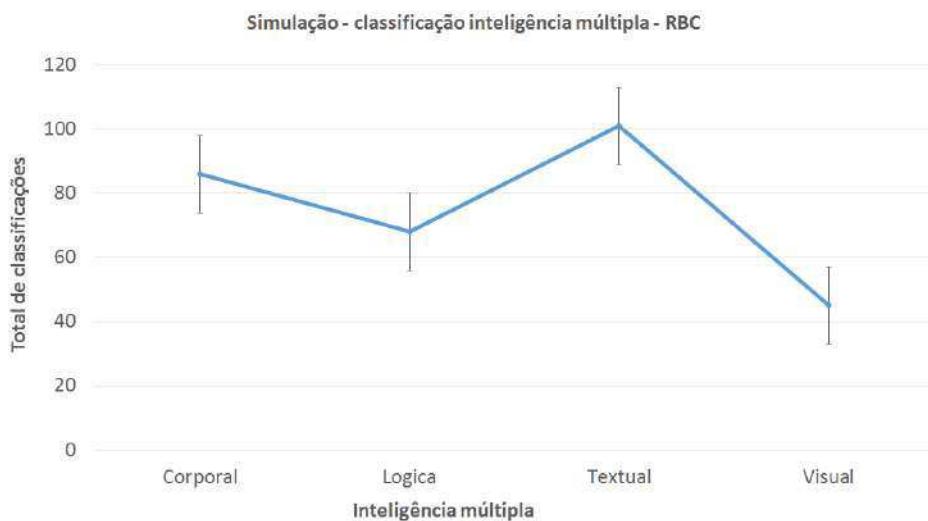


Figura 38 – Resultado da classificação da inteligência múltipla para 300 simulações no módulo RBC.

Analizando esses resultados foi possível observar que as inteligências múltiplas, quando combinadas com as emoções, colaboram de maneira significativa para a determinação do perfil do estudante, e que essas informações podem ser utilizadas para realizar recomendações para o estudante durante o processo de ensino e aprendizagem.

Como as regras estão associadas ao perfil do estudante, foi realizada uma análise das regras associadas ao perfil retido na primeira bateria de testes, verificando a qual perfil a regra foi recomendada. Os resultados apresentados para os 56 casos retidos na base estão no gráfico da Figura 39.

Analizando os resultados referentes às regras recomendadas para os perfis, eles se apresentaram relativamente satisfatórios quando analisada a teoria referente a essas recomendações propostas para cada um dos perfis.

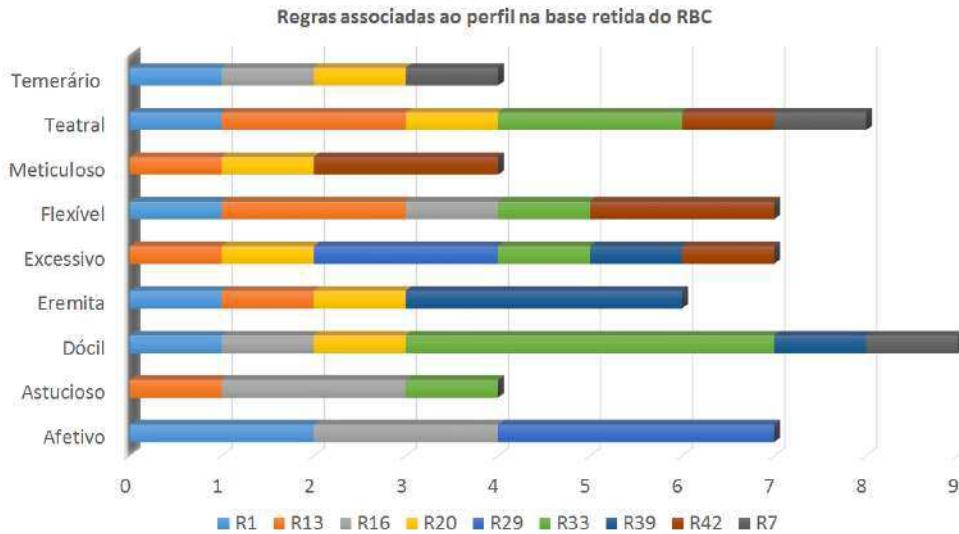


Figura 39 – Regras associadas ao perfil para a base de casos retida no RBC.

Para verificar a relação que existe entre os perfis e as inteligências múltiplas, os 91 casos retidos foram analisados para cada um dos perfis. Os resultados obtidos dessa análise estão presentes no gráfico da Figura 40.

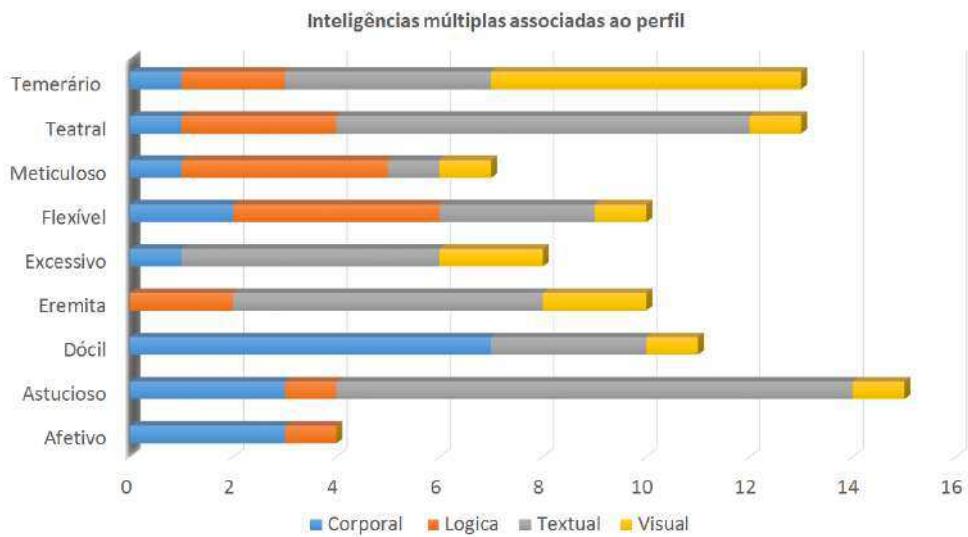


Figura 40 – Inteligências múltiplas associadas ao perfil para a base de casos retida no RBC.

O fato das inteligências múltiplas terem sido simuladas neste trabalho inviabiliza uma análise mais criteriosa, mas é possível observar com esses resultados a predominância de certas IM para alguns perfis e até mesmo a inexistência de algumas delas para outros perfis, aumentando assim a expectativa de uma relação entre as IM e os perfis de personalidade.

Para finalizar as avaliações dos resultados obtidos com as simulações do módulo RBC, foram analisadas as regras recomendadas para cada um dos perfis nas 300 simulações executadas conforme o gráfico da Figura 41. Após essa análise os resultados foram compa-

rados com a proposta de (MELO, 2016), verificando assim que as recomendações geradas pelo RBC então dentro do recomendado, satisfazendo assim a abordagem proposta pela autora do trabalho.

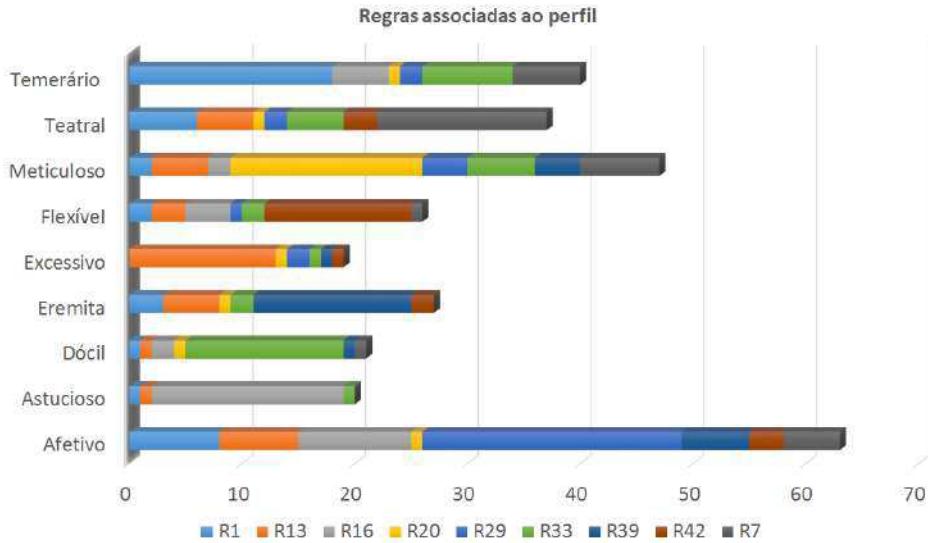


Figura 41 – Regras associadas ao perfil para 300 simulações no RBC.

A mesma observação foi realizada para identificar quais inteligências múltiplas foram associadas para cada um dos perfis de personalidade nas 300 simulações executadas. Esses resultados são exibidos no gráfico da Figura 42.

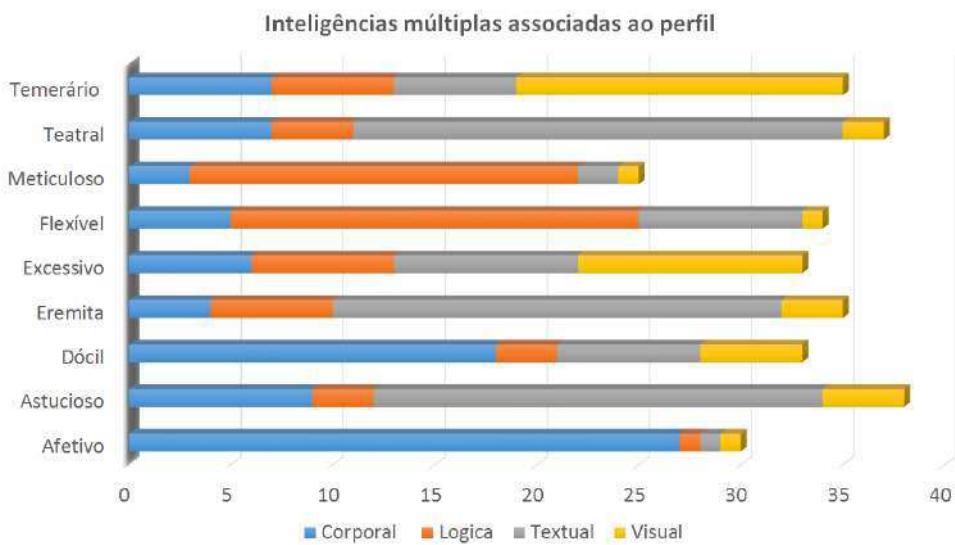


Figura 42 – Inteligências múltiplas associadas ao perfil para 300 simulações no RBC.

Analizando esses resultados, podemos observar um certo padrão para as IM, onde determinadas inteligências são predominantes em alguns perfis. No futuro essas observações poderão ser confirmadas com testes realizados em ambientes virtuais de aprendizagem, conforme mencionado em trabalhos futuros.

Também foram realizados testes para que o módulo RBC aprendesse e reteze novos casos ocultando as regras, foram realizadas um total de 100 simulações, mas os resultados não foram bons devido ao fato das regras estarem altamente correlacionadas com o perfil no momento da criação da base inicial do módulo RBC, o que inviabiliza que o mesmo seja usado para a geração de novas regras para a base.

Para concluir a análise dos resultados foi verificado a taxa de acerto dos resultados obtidos da simulação na Figura 41, onde foi observado uma taxa de acerto de 53.35% de acordo com a proposta de (MELO, 2016). Considerado relativamente bom uma vez que os percentuais das emoções foram simulados aleatoriamente. Em testes reais espera-se que este percentual aumente, pois, as emoções são capturadas em situações reais nos ambientes virtuais de aprendizagem.

CAPÍTULO 5

Considerações Finais

Este trabalho apresentou um módulo para a detecção e classificação automática de emoções através das expressões faciais do estudante baseado na teoria FACS (EKMAN; FRIESEN, 1978a). Além disso, foram realizados experimentos com a técnica a partir do contorno facial para detecção das expressões e SVM para a classificação das emoções. Estes resultados também foram comparados com a técnica que utiliza a teoria de de (AZCARATE et al., 2005) para a detecção das Unidade de Movimento na face detectada e a técnica Árvore de Decisão para a classificação. Através dos experimentos realizados, a técnica que utiliza as UM e Árvore de Decisão para o reconhecimento automático de emoções obteve melhores resultados.

Após a identificação da melhor técnica para a detecção e classificação das emoções, o módulo proposto foi integrado ao ambiente virtual de aprendizagem Moodle, para que fosse possível o acompanhamento em tempo real das emoções dos estudantes durante o processo de ensino e aprendizagem.

Posteriormente com a finalidade de acompanhar o perfil emocional do estudante, também em ambientes virtuais 3D, foi desenvolvido um mundo virtual 3D contendo quatro ilhas pedagógicas com o intuito de acompanhar suas emoções e respectivas inteligências múltiplas.

Além disso, esse trabalho apresentou uma arquitetura para a verificação de recomendações pedagógicas, a partir das emoções e perfis de personalidade, denominada **EPEP**. O **EPEP** apresenta esses dois grandes momentos para a detecção e a recomendação pedagógica em ambientes virtuais de aprendizagem através da técnica de Raciocínio Baseado em Casos.

No decorrer deste trabalho foram apresentados os principais conceitos relacionados à computação afetiva e suas aplicações na educação. Hoje a computação afetiva é a base de estudo para diversos grupos de pesquisa ligados à informática na educação, pois associada a técnicas de computação como a inteligência artificial, é capaz de oferecer soluções eficazes para aprimorar o processo de ensino e aprendizagem.

O desenvolvimento deste trabalho resultou em uma API que possibilita de maneira

simples e rápida que desenvolvedores e pesquisadores de todo o mundo possam utilizar os recursos produzidos para desenvolverem novas pesquisas ou realizar testes. Atualmente a aplicação vem sendo utilizada como projeto para trabalho de conclusão de curso (TCC) de um estudante da Universidade Federal do Oeste do Pará do curso de Engenharia Física.

Esta API permite que os desenvolvedores de maneira fácil e descomplicada enviem imagem e obtenham como resultado as distâncias euclidianas para cada uma das Unidades de Movimento e então aplicar essas distâncias em alguma técnica para a classificação das emoções.

No decorrer deste trabalho foram escritos artigos científicos onde dois deles obtiveram aceite e foram publicados são eles: Reconhecimento dinâmico de emoções através de expressões faciais utilizando árvore de decisão, este trabalho tem como contribuição uma análise das técnicas utilizadas para a classificação das emoções em tempo real (DANTAS et al., 2015b).

O segundo Aplicação para reconhecimento dinâmico de emoções em ambientes virtuais de aprendizagem, descreve a integração do sistema de detecção e classificação de emoções em ambientes virtuais de aprendizagem e além disso a sua integração em dispositivos móveis (DANTAS et al., 2015a).

5.1 Principais Contribuições

As principais contribuições deste trabalho, através da confirmação das hipóteses de pesquisa foram:

- Um módulo para detecção e classificação automática de emoções utilizando as Unidades de Movimento baseadas nas Unidades de Ação.
- A integração do módulo de emoções no ambiente virtual de aprendizagem.
- O desenvolvimento de um ambiente virtual 3D para o acompanhamento das emoções e características cognitivas do estudante.
- A avaliação das estratégias pedagógicas relacionadas com os perfis de personalidade, emoções e inteligências múltiplas.
- Um módulo composto por um RBC capaz de fornecer recomendação de estratégias pedagógicas baseada em emoções e perfis de personalidade.
- Uma API na qual é possível que desenvolvedores e pesquisadores utilizem para o aperfeiçoamento das técnicas para detecção de classificação das emoções em tempo real.

5.2 Trabalhos Futuros

Através da análise computacional da relação existente entre as emoções e os perfis de personalidade no processo de ensino e aprendizagem, tem-se como futuros possíveis trabalhos:

- ❑ O desenvolvimento de um banco de imagens com emoções espontâneas, a partir das imagens adquiridas nos experimentos realizados de maneira geral.
- ❑ A realização e validação de testes reais no ambiente virtual 3D para a captura das inteligências múltiplas de cada aluno durante o processo de ensino e aprendizagem.
- ❑ A realização de uma avaliação no módulo RBC com percentuais nos perfis de personalidade ao invés de utilizar somente o estado máximo, conforme abordado neste trabalho.
- ❑ A inserção de aspectos colaborativos no ambiente virtual, para que seja possível analisar o comportamento emocional dos alunos em atividades colaborativas dentro desses ambientes.
- ❑ A incremetação do módulo RBC com informações colaborativas e análise dos possíveis resultados e recomendações produzidas a partir dessas modificações no módulo.
- ❑ A implementação e avaliação de outros métodos para captura de emoções e outras informações, tais como: análise de áudio, análise de textos dentro dos ambientes virtuais de aprendizagem 3D.

Referências

- AAMODT, A.; PLAZA, E. Case-based reasoning: Foundational issues, methodological variations, and system approaches. **AI communications**, v. 7, n. 1, p. 39–59, 1994.
- ADOBE. **About RIAs@ONLINE**. 2015. Disponível em: <https://www.adobe.com/resources/business/rich_internet_apps>.
- ALVES, L. Educação a distância: uma nova concepção de aprendizado e interatividade. **São Paulo: Futura**, p. 78–79, 2003.
- AO, L. P. L. et al. Detecção de expressões faciais: uma abordagem baseada em análise do fluxo óptico – facial expression detection: a technique for optical flow analysis. **Revista GEINTEC**, São Cristóvão, SE, Brasil, v. 2, n. 5, p. 472 – 489, 2012. ISSN 2237-0722.
- AQUINO, M. S.; SOUSA, F. F. de; FRERY, A. C. Multi-agent architecture for generating and monitoring adaptive virtual environments. In: IEEE. **Hybrid Intelligent Systems, 2005. HIS'05. Fifth International Conference on**. [S.l.], 2005. p. 3–pp.
- ARRUDA, M. P. O paradigma emergente da educação: o professor como mediador de emoções. **ETD-Educação Temática Digital**, v. 14, n. 2, p. 290–303, 2012.
- AZCARATE et al. **Automatic facial emotion recognition**. 2005.
- BARRON, J. L.; FLEET, D. J.; BEAUCHEMIN, S. S. Performance of optical flow techniques. **International journal of computer vision**, Springer, v. 12, n. 1, p. 43–77, 1994.
- BERNERS-LEE, T. et al. The semantic web. **Scientific american**, New York, NY, USA:, v. 284, n. 5, p. 28–37, 2001.
- BLAIR, J.; LIN, F. An approach for integrating 3d virtual worlds with multiagent systems. In: IEEE. **Advanced Information Networking and Applications (WAINA), 2011 IEEE Workshops of International Conference on**. [S.l.], 2011. p. 580–585.
- BREIMAN, L. et al. **Classification and regression trees**. [S.l.]: CRC press, 1984.
- .C AHMED .W, M. S. M. D. S. Facial expressions: A cross-cultural study. In: **Emotion Recognition: A Pattern Analysis Approach**. [S.l.: s.n.], 2014. p. 69–87.

- CAELUM. **Introdução ao JSF e Primefaces@ONLINE**. 2015. Disponível em: <<https://www.caelum.com.br/apostila-java-testes-jsf-web-services-design-patterns/>>.
- CHABOT, D. **Pedagogia emocional-sentir para aprender**. [S.l.]: Sa Editora, 2005.
- DALGARNO, B. The potential of 3d virtual learning environments: A constructivist analysis. **Electronic Journal of Instructional Science and Technology**, v. 5, n. 2, p. 3–6, 2002.
- DANTAS, A. et al. Aplicação para reconhecimento dinâmico de emoções em ambientes virtuais de aprendizagem. In: **Anais dos Workshops do Congresso Brasileiro de Informática na Educação**. [S.l.: s.n.], 2015. v. 4, n. 1, p. 390.
- DANTAS, A. C. et al. Reconhecimento dinâmico de emoções através de expressões faciais utilizando árvore de decisão. In: **Anais do Simpósio Brasileiro de Informática na Educação**. [S.l.: s.n.], 2015. v. 26, n. 1, p. 1102.
- DILLENBOURG, P.; SCHNEIDER, D.; SYNTETA, P. Virtual learning environments. In: KASTANIOTIS EDITIONS, GREECE. **3rd Hellenic Conference "Information & Communication Technologies in Education"**. [S.l.], 2002. p. 3–18.
- DREHER, C. et al. 3d virtual worlds as collaborative communities enriching human endeavours: Innovative applications in e-learning. In: IEEE. **Digital Ecosystems and Technologies, 2009. DEST'09. 3rd IEEE International Conference on**. [S.l.], 2009. p. 151–156.
- DURKIN, J. Designing an induction expert system. **AI EXPERT.**, v. 6, n. 12, p. 28–35, 1991.
- EKMAN, P.; FRIESEN, W. Facial action coding system. **Alto: Consulting Psychologist Press**, Palo, 1978.
- EKMAN, P.; FRIESEN, W. V. **Manual for the facial action coding system**. [S.l.]: Consulting Psychologists Press, 1978.
- FFMPEG. **FFmpeg framework @ONLINE**. 2016. Disponível em: <<https://www.ffmpeg.org/about.html>>.
- GARCIA, L. S. L. A expressão das emoções no homem e nos animais. In: **Traduzido por: Leon de Souza Lobo Garcia – A Origem das Espécies, publicado por Charles Darwin – 1859**. São Paulo, Brasil: Companhia de Bolso, 2009. p. 33–55. ISSN 978-85-3591-398-9. [Http://www.letras.ufmg.br/arquivos/matte/bib/darwin.pdf](http://www.letras.ufmg.br/arquivos/matte/bib/darwin.pdf).
- GARDNER, H. Estruturas da mente (sandra costa, trad.). **Porto Alegre: Artmed.(Obra original publicada em 1983)**, 1994.
- GOLEMAN, D. **Inteligência emocional: A teoria revolucionária que redefine o que é ser inteligente**. [S.l.]: Objetiva, 1995.
- GRINGS, E. S.; TREIN, D.; OLIVEIRA, C. The metaverse: Telepresence in 3d avatar-driven digital-virtual worlds. **@ tic. revista d'innovació educativa**, Centre de Formació i Qualitat "Manuel Sanchis Guarner", n. 2, p. 26–32, 2009.

- GROUP, M. U. **The MUG Facial Expression Database**. 2014. Disponível em: <<http://mug.ee.auth.gr/fed/>>.
- GUARDA, A. **Aprendizado de Máquina: Árvore de Decisão Indutiva @ONLINE**. 2016. Disponível em: <<http://www.cin.ufpe.br/~pacm/SI/ArvoreDecisaoIndutiva.pdf>>.
- HAANS, A.; IJSSELSTEIJN, W. A. Self-attribution and telepresence. **Proceedings of Presence**, p. 51–58, 2007.
- HAPPYMAN. **OpenCV Face Detection@ONLINE**. 2014. Disponível em: <<https://cg2010studio.wordpress.com/2011/04/26/opencv-%E4%BA%BA%E8%87%89%E5%81%B5%E6%B8%AC-face-detection>>.
- HERPICH, F. et al. Immersive virtual environment and artificial intelligence: A proposal of context aware virtual environment. In: **UBICOMM 2014, The Eighth International Conference on Mobile Ubiquitous Computing, Systems, Services and Technologies**. [S.l.: s.n.], 2014. p. 68–71.
- .I BALLANO .S, C. E. B. S. H. From a discrete perspective of emotions to continuous, dynamic, and multimodal affect sensing. In: **Emotion Recognition: A Pattern Analysis Approach**. [S.l.: s.n.], 2014. p. 461–491.
- IGLESIAS, A.; LUENGO, F. Intelligent agents in virtual worlds. In: **Proceedings of the 2004 International Conference on Cyberworlds**. Washington, DC, USA: IEEE Computer Society, 2004. (CW '04), p. 62–69. ISBN 0-7695-2140-1. Disponível em: <<http://dx.doi.org/10.1109/CW.2004.40>>.
- JAQUES, P. et al. Computacão afetiva aplicada a educacão: Dotando sistemas tutores inteligentes de habilidades sociais. In: **Anais do Workshop de Desafios da Computacão Aplicada a Educacão**. [S.l.: s.n.], 2012. p. 50–59.
- JAQUES, P.; VICARI, R. Pat: um agente pedagógico animado para interagir efetivamente com o aluno. **RENOTE**, v. 3, n. 1, 2005.
- JENHANI, I.; AMOR, N. B.; ELOUEDI, Z. Decision trees as possibilistic classifiers. **International Journal of Approximate Reasoning**, Elsevier, v. 48, n. 3, p. 784–807, 2008.
- JOHN, A. K.; CHINNASA, E. et al. Temperament and mood detection using case-based reasoning. **International Journal of Intelligent Systems and Applications (IJISA)**, v. 6, n. 3, p. 50, 2014.
- KANADE, T. C.; COHN, J. Au-coded facial expression database. 2005.
- KIRRIEMUIR, J. An update of the july 2007 ‘snapshot’of uk higher and further education developments in second life. **Eduserv Foundation**, p. 1–39, 2007.
- KOLODNER, J. **Case-based Reasoning**. [S.l.]: Morgan Kaufmann Publishers Inc, 1993.
- KORT, B.; REILLY, R.; PICARD, R. W. An affective model of interplay between emotions and learning – reengineering educational pedagogy-building a learning companion. **IEEE Computer Society**, Massachusetts, USA, p. 0043–0043, 2001.

KURETZKI, C. Técnicas de mineração de dados aplicadas em bases de dados para saúde a partir de protocolos eletrônicos [dissertação]. **Curitiba: Universidade Federal do Paraná**, 2009.

MELO, S. L. **Modelo do estudante baseado em emoções e perfis de personalidade para recomendação de estratégias pedagógicas personalizadas**. [S.l.]: Universidade Federal de Uberlândia, 2016.

MOODLE. **Moodle@ONLINE**. 2015. Disponível em: <https://docs.moodle.org/28/en/About_Moodle>.

MOORE, P. et al. Learning and teaching in virtual worlds: Implications of virtual reality for education. **Australian journal of educational technology**, Australasian Society for Computers in Learning in Tertiary Education, v. 11, n. 2, p. 91, 1995.

OLIVEIRA, A. F. N. de. **Uma metodologia de uso de técnicas de indução para criação de regras de sistemas especialistas**. Tese (Doutorado) — Universidade Federal de Santa Catarina, 2001.

OPENCV. **Cascade Classification@ONLINE**. 2015. Disponível em: <http://docs.opencv.org/modules/objdetect/doc/cascade_classification.html>.

OPENSIMULATOR. **Opensimulator@ONLINE**. 2015. Disponível em: <http://opensimulator.org/wiki/P%C3%A1gina_principal>.

PANTIC, M.; ROTHKRANTZ, L. J. M. Automatic analysis of facial expressions: The state of the art. **Pattern Analysis and Machine Intelligence, IEEE Transactions on**, IEEE, v. 22, n. 12, p. 1424–1445, 2000.

QUINLAN, J. R. Induction of decision trees. **Machine learning**, Springer, v. 1, n. 1, p. 81–106, 1986.

QUINLAN, R. **Programs for machine learning**. [S.l.]: Elsevier, 2014.

RÁZURI, J. G. et al. Automatic emotion recognition through facial expression analysis in merged images based on an artificial neural network. In: **MICAI (Special Sessions)**. IEEE, 2013. p. 85–96. ISBN 978-1-4799-2604-6. Disponível em: <<http://dblp.uni-trier.de/db/conf/micai/micai2013s.html#RazuriSRC13>>.

REZENDE, S. O. **Sistemas inteligentes: fundamentos e aplicações**. [S.l.]: Editora Manole Ltda, 2003.

RIVER, G. **The River City Project@ONLINE**. 2016. Disponível em: <<http://muve.gse.harvard.edu/rivercityproject/index.html>>.

RUSSELL, S.; NORVIG, P. **Inteligência artificial**. CAMPUS - RJ, 2004. ISBN 9788535211771. Disponível em: <<https://books.google.com.br/books?id=wBMvAAAACAAJ>>.

SAHYOUN, F. **Facial Action Coding System@ONLINE**. 2016. Disponível em: <<http://www.fadysahyoun.com/2015/11/27/facial-action-coding-system>>.

SALDÍAS, G. C.; AZEVEDO, F. M. de. Estratégias pedagógicas e interfaces inteligentes em sistemas tutores. In: **Anais do II Congresso Brasileiro de Computação**. [S.l.: s.n.], 2002.

- SALEEB, N.; DAFOULAS, G. A. Artificial intelligence in 3d virtual environments as technological support for pedagogy. In: **Intelligent Environments (Workshops)**. [S.l.: s.n.], 2013. p. 443–453.
- SANCHES, S. R. R.; SILVA, A. C.; TORI, R. Uma experiência de educação a distância realizada em um ambiente virtual tridimensional. **Revista Brasileira de Computação Aplicada**, v. 2, n. 2, p. 47–57, 2010.
- SCHAPIRE, R. E. The strength of weak learnability. **Mach. Learn.**, Kluwer Academic Publishers, Hingham, MA, USA, v. 5, n. 2, p. 197–227, jul. 1990. ISSN 0885-6125. Disponível em: <<http://dx.doi.org/10.1023/A:1022648800760>>.
- SECONDLIFE. **LSL Portal @ONLINE**. 2015. Disponível em: <http://wiki.secondlife.com/wiki/LSL_Portal/pt>.
- SHI, H. **Best-first decision tree learning**. Tese (Doutorado) — Citeseer, 2007.
- SKETCHUP, G. **Google SketchUp @ONLINE**. 2016. Disponível em: <<https://www.sketchup.com/pt-BR>>.
- SOLIMAN, M.; GUETL, C. Implementing intelligent pedagogical agents in virtual worlds: Tutoring natural science experiments in openwonderland. In: **EDUCON**. IEEE, 2013. p. 782–789. ISBN 978-1-4673-6111-8. Disponível em: <<http://ieeexplore.ieee.org/xpl/mostRecentIssue.jsp?punumber=6522574>>.
- SUN, J.-m.; PEI, X.-s.; ZHOU, S.-s. Facial emotion recognition in modern distant education system using svm. In: **IEEE. Machine Learning and Cybernetics, 2008 International Conference on**. [S.l.], 2008. v. 6, p. 3545–3548.
- THOMPSON, B.; THOMPSON, W. Finding rules in data. **Byte**, McGraw-Hill, Inc., v. 11, n. 12, p. 149–158, 1986.
- TORI, R. Métricas para uma educação sem distância. **Revista Brasileira de Informática na Educação, SBC**, v. 10, n. 2, 2002.
- VALENTINI, C. B.; SOARES, E. M. d. S. Aprendizagem em ambientes virtuais: compartilhando idéias e construindo cenários. **E-book-Aprendizagem em Ambientes Virtuais**, 2010.
- VALSTAR, M. F.; PANTIC, M. Fully automatic recognition of the temporal phases of facial actions. **Trans. Sys. Man Cyber. Part B**, IEEE Press, Piscataway, NJ, USA, v. 42, n. 1, p. 28–43, fev. 2012. ISSN 1083-4419. Disponível em: <<http://dx.doi.org/10.1109/TSMCB.2011.2163710>>.
- VIOLA, P.; JONES, M. J. Robust real-time face detection. **Int. J. Comput. Vision**, Kluwer Academic Publishers, Hingham, MA, USA, v. 57, n. 2, p. 137–154, maio 2004. ISSN 0920-5691. Disponível em: <<http://dx.doi.org/10.1023/B:VISI.0000013087.49260.fb>>.
- WANGENHEIM, C. G. V.; WANGENHEIM, A. V. **Raciocínio baseado em casos**. 2rd. ed. [S.l.]: Editora Manole Ltda, 2013.
- WEISS, S. Fallbasiertes problemlosen in wissensbasierten systemen zur entscheidungsunterstützung und diagnostik. 1995.

- .Z, K. H. U. Facial expressions: A cross-cultural study. In: **Emotion Recognition: A Pattern Analysis Approach**. [S.l.: s.n.], 2014. p. 113–128.

Apêndices

APÊNDICE **A**

Casos retidos com a simulação para o perfil

Perfil	% Alegria	% Tristeza	% Raiva	% Medo	% Desgost	% Surpres	% Neutro	IM	Regra
Afetivo	10.39	18.99	28.49	6.82	18.1	16.62	0.59	corporal	R16
Afetivo	2.16	3.24	1.08	20.86	34.53	30.58	7.55	corporal	R16
Afetivo	18.13	19.01	23.1	16.37	16.08	5.56	1.75	corporal	R1
Afetivo	7.26	2.42	14.92	33.47	33.06	8.87	0.0	corporal	R1
Afetivo	20.92	1.42	7.09	20.92	19.86	7.45	22.34	logica	R29
Afetivo	15.1	21.74	8.24	17.16	19.45	8.47	9.84	logica	R29
Afetivo	10.0	25.79	12.11	14.74	24.74	11.84	0.79	textual	R29
Astucioso	15.58	13.96	12.99	14.61	22.08	15.58	5.19	visual	R16
Astucioso	24.02	3.92	18.14	4.9	22.79	18.14	8.09	textual	R13
Astucioso	31.68	0.64	7.03	3.51	24.6	18.21	14.38	textual	R33
Astucioso	17.03	15.03	13.03	17.43	16.63	10.42	10.42	logica	R16
Docil	13.07	1.51	0.5	35.18	43.22	3.52	3.02	corporal	R20
Docil	23.88	10.7	17.16	9.45	24.63	3.73	10.45	corporal	R39
Docil	22.59	8.15	7.78	33.33	16.3	5.93	5.93	corporal	R7
Docil	29.17	18.75	3.33	22.5	16.67	3.75	5.83	corporal	R1
Docil	4.79	28.74	2.4	22.16	18.26	2.1	21.56	visual	R33
Docil	30.77	17.95	6.41	0.85	19.66	23.08	1.28	logica	R33
Docil	3.42	0.0	5.7	8.75	28.14	25.86	28.14	logica	R33
Docil	23.83	0.0	4.3	8.59	18.75	35.94	8.59	logica	R33
Docil	6.64	17.84	2.49	16.18	31.54	8.71	16.6	corporal	R16
Eremita	3.61	19.64	13.09	22.35	17.16	20.54	3.61	logica	R39
Eremita	8.33	12.08	3.75	4.58	14.17	34.58	22.5	textual	R1
Eremita	8.45	1.09	9.81	14.71	21.53	25.34	19.07	textual	R13
Eremita	0.71	3.2	7.47	20.64	25.62	35.59	6.76	textual	R20
Eremita	8.05	19.25	9.48	15.8	22.7	11.49	13.22	logica	R39
Eremita	24.05	0.32	1.27	1.27	26.9	30.06	16.14	logica	R39
Excessivo	1.13	21.4	21.62	11.71	15.99	16.22	11.94	visual	R33
Excessivo	1.69	33.78	11.49	13.18	30.41	9.46	0.0	visual	R29
Excessivo	37.7	14.68	7.14	14.68	23.02	2.38	0.4	visual	R20
Excessivo	41.98	6.13	21.23	7.55	18.4	2.83	1.89	visual	R29
Excessivo	33.91	1.29	3.43	16.74	36.48	4.72	3.43	logica	R13
Excessivo	4.01	23.75	21.74	10.7	17.73	5.69	16.39	visual	R39
Excessivo	17.05	23.86	0.85	23.01	18.75	11.36	5.11	visual	R42
Flexivel	16.62	18.77	1.61	4.29	23.32	10.72	24.66	logica	R13
Flexivel	9.06	22.33	16.18	13.27	18.45	15.53	5.18	logica	R16
Flexivel	8.64	28.57	10.63	19.93	17.94	10.63	3.65	logica	R1
Flexivel	16.9	11.36	14.68	0.28	15.79	24.38	16.62	logica	R33
Flexivel	27.3	7.8	17.55	14.21	19.22	11.7	2.23	visual	R42
Flexivel	29.26	0.87	12.23	4.8	25.33	6.99	20.52	logica	R13
Flexivel	2.92	19.59	13.74	26.9	22.81	10.82	3.22	visual	R42
Meticuloso	15.68	1.54	24.42	15.42	15.68	17.48	9.77	logica	R13
Meticuloso	14.13	3.31	19.43	9.05	18.54	18.76	16.78	logica	R7
Meticuloso	7.34	8.39	19.93	6.64	23.78	31.12	2.8	logica	R7
Meticuloso	23.29	0.55	24.38	15.89	24.11	7.4	4.38	textual	R20
Teatral	10.59	22.22	24.81	5.43	18.86	17.05	1.03	textual	R33
Teatral	5.33	21.07	23.35	16.5	22.34	9.14	2.28	textual	R33
Teatral	1.51	9.07	13.6	9.82	20.91	23.93	21.16	textual	R42
Teatral	5.4	15.83	4.32	15.11	17.27	17.27	24.82	logica	R7
Teatral	7.13	14.25	20.67	6.18	15.2	21.14	15.44	textual	R1

APÊNDICE **B**

Casos retidos com a simulação para as inteligências múltiplas

Perfil	% Alegria	% Tristeza	% Raiva	% Medo	% Desgosto	% Surpresa	% Neutro	IM	Regra
Afetivo	11.46	23.44	13.28	20.83	20.83	3.65	6.51	logica	R42
Afetivo	3.94	18.87	20.85	22.82	15.77	8.73	9.01	corporal	R13
Afetivo	10.21	9.16	24.61	25.65	19.11	6.54	4.71	corporal	R33
Afetivo	12.66	5.43	11.63	21.71	21.96	1.81	24.81	corporal	R16
Astucioso	14.89	15.63	14.71	10.11	15.63	12.5	16.54	textual	R39
Astucioso	16.88	10.91	5.97	16.36	20.0	4.94	24.94	textual	R29
Astucioso	8.19	12.81	25.62	0.36	10.68	23.84	18.51	corporal	R13
Astucioso	1.52	5.32	5.7	22.81	27.0	16.73	20.91	textual	R13
Astucioso	18.85	19.07	17.74	13.75	18.63	6.21	5.76	textual	R1
Astucioso	5.56	0.0	2.78	40.74	35.65	1.85	13.43	textual	R29
Astucioso	15.85	18.2	7.07	7.92	16.7	13.49	20.77	logica	R42
Astucioso	2.62	19.87	8.73	16.38	19.21	11.57	21.62	corporal	R33
Astucioso	18.7	4.74	2.74	18.95	18.2	24.44	12.22	textual	R7
Astucioso	0.0	19.08	4.61	19.74	16.45	28.95	11.18	textual	R39
Astucioso	14.22	18.18	17.25	18.18	17.25	10.72	4.2	corporal	R29
Astucioso	3.6	17.22	6.68	24.16	19.79	24.42	4.11	textual	R7
Astucioso	19.18	17.9	15.6	13.04	20.2	10.49	3.58	textual	R42
Astucioso	6.0	19.9	22.06	0.96	16.07	19.42	15.59	visual	R1
Astucioso	6.88	28.65	1.72	25.79	20.63	14.33	2.01	textual	R42
Docil	1.09	15.76	21.2	8.42	25.82	17.66	10.05	corporal	R16
Docil	6.99	16.4	18.55	24.73	23.39	5.38	4.57	textual	R16
Docil	1.39	4.44	6.11	17.78	21.39	25.83	23.06	corporal	R16
Docil	7.85	10.76	21.97	12.78	20.85	11.66	14.13	visual	R1
Docil	20.85	9.19	12.78	19.96	16.59	14.8	5.83	corporal	R29
Docil	12.32	17.86	1.03	11.09	20.12	19.3	18.28	textual	R39
Docil	16.79	1.43	11.43	12.14	17.86	28.21	12.14	corporal	R20
Docil	8.04	12.86	5.14	11.58	27.33	19.61	15.43	corporal	R13
Docil	8.68	10.92	27.73	4.76	23.53	2.52	21.85	corporal	R39
Docil	2.37	15.38	23.37	0.89	19.23	18.93	19.82	corporal	R39
Docil	7.0	17.12	5.84	29.18	15.95	10.51	14.4	textual	R7
Eremita	10.96	5.32	31.23	29.9	13.62	0.0	8.97	textual	R7
Eremita	11.09	12.47	20.09	2.08	23.09	9.47	21.71	textual	R16
Eremita	3.68	29.14	14.11	20.55	12.88	19.63	0.0	textual	R33
Eremita	18.92	14.74	16.53	12.55	18.53	4.18	14.54	visual	R13
Eremita	3.44	16.62	20.92	24.64	18.34	6.3	9.74	logica	R20
Eremita	10.91	17.59	11.58	2.23	22.05	17.59	18.04	logica	R42
Eremita	6.02	27.71	7.53	16.27	23.19	9.64	9.64	textual	R16
Eremita	14.81	9.35	14.64	9.7	16.4	17.46	17.64	visual	R1
Eremita	3.62	13.41	31.88	2.9	21.74	15.58	10.87	textual	R16
Eremita	13.18	9.21	18.83	20.08	20.92	15.9	1.88	textual	R13
Excessivo	6.53	10.09	14.24	21.66	17.8	20.47	9.2	textual	R39
Excessivo	11.35	28.22	10.74	15.03	15.03	17.79	1.84	visual	R33
Excessivo	18.94	8.07	1.86	4.97	28.88	24.22	13.04	textual	R39
Excessivo	25.75	4.49	10.18	0.3	17.07	22.16	20.06	textual	R39
Excessivo	11.65	2.43	1.46	16.99	20.39	0.0	47.09	textual	R7
Excessivo	16.67	13.98	14.52	21.24	15.59	4.57	13.44	corporal	R33
Excessivo	9.12	21.82	21.5	2.93	23.78	12.38	8.47	visual	R16
Excessivo	17.35	7.23	20.48	18.55	18.31	13.25	4.82	textual	R39
Flexivel	14.02	12.62	17.29	20.56	18.93	8.18	8.41	logica	R20
Flexivel	17.51	12.95	0.96	17.27	16.07	21.58	13.67	corporal	R33
Flexivel	14.04	32.98	0.35	4.91	22.81	8.77	16.14	textual	R7
Flexivel	10.81	16.49	4.86	22.16	15.41	16.22	14.05	textual	R7

Flexivel	20.22	4.31	0.54	25.61	16.71	13.48	19.14	corporal	R29
Flexivel	4.17	19.87	9.29	30.77	22.44	13.46	0.0	textual	R39
Flexivel	32.14	18.25	4.37	20.24	13.1	5.16	6.75	visual	R13
Flexivel	10.4	18.4	12.0	14.67	22.4	12.0	10.13	logica	R33
Flexivel	7.36	15.98	14.72	11.67	16.88	17.59	15.8	logica	R39
Flexivel	32.41	15.02	23.32	0.4	23.32	3.95	1.58	logica	R16
Meticuloso	22.2	14.57	19.51	0.9	15.7	22.42	4.71	logica	R33
Meticuloso	15.12	8.29	12.2	11.46	19.02	16.1	17.8	logica	R13
Meticuloso	12.63	8.6	17.74	23.39	24.19	11.29	2.15	logica	R13
Meticuloso	13.55	9.35	13.55	29.03	21.29	7.42	5.81	logica	R13
Meticuloso	16.72	17.01	0.29	6.45	23.46	9.68	26.39	textual	R7
Meticuloso	18.51	11.67	9.05	15.29	15.9	17.71	11.87	corporal	R33
Meticuloso	4.9	13.24	0.49	30.39	25.0	8.82	17.16	visual	R1
Teatral	20.9	2.47	10.34	11.24	21.57	22.02	11.46	visual	R1
Teatral	23.51	9.52	11.61	27.08	20.83	5.36	2.08	textual	R1
Teatral	23.26	1.16	19.77	20.7	16.98	7.91	10.23	logica	R42
Teatral	5.36	15.46	17.35	8.83	22.4	30.6	0.0	textual	R13
Teatral	9.67	10.77	6.15	19.34	20.88	20.88	12.31	corporal	R33
Teatral	15.82	17.14	1.32	18.9	20.44	11.43	14.95	textual	R13
Teatral	7.69	21.98	17.86	17.58	22.8	10.44	1.65	textual	R33
Teatral	12.44	18.42	23.92	19.62	20.81	3.35	1.44	textual	R16
Teatral	4.28	9.48	14.37	22.94	27.52	18.65	2.75	textual	R42
Teatral	9.4	33.56	13.76	30.54	11.07	1.68	0.0	textual	R1
Teatral	1.61	17.69	19.84	8.04	25.47	23.59	3.75	logica	R20
Teatral	12.32	6.3	13.18	0.29	12.32	27.79	27.79	logica	R42
Teatral	1.44	22.6	18.75	19.23	26.44	5.29	6.25	textual	R39
Temerario	7.84	19.12	16.91	3.43	19.12	18.14	15.44	logica	R20
Temerario	9.15	12.5	28.66	3.96	28.05	10.37	7.32	corporal	R29
Temerario	10.28	30.22	4.36	22.74	12.77	12.77	6.85	textual	R7
Temerario	6.46	15.07	7.42	12.68	22.25	16.99	19.14	visual	R16
Temerario	15.34	24.15	1.7	28.41	18.18	4.26	7.95	textual	R39
Temerario	2.7	24.08	12.78	11.55	20.64	22.11	6.14	visual	R13
Temerario	20.41	10.79	24.78	0.58	13.7	20.7	9.04	visual	R16
Temerario	24.27	9.65	26.02	22.22	15.2	2.34	0.29	visual	R29
Temerario	15.42	9.3	9.52	10.43	13.83	21.32	20.18	visual	R16
Temerario	4.74	7.89	20.79	16.84	15.79	17.63	16.32	logica	R42
Temerario	12.12	19.39	7.07	15.76	18.38	14.34	12.93	textual	R16
Temerario	18.55	3.01	4.51	20.55	15.04	16.79	21.55	visual	R20
Temerario	30.14	10.64	2.13	4.26	21.28	12.77	18.79	textual	R39