

Visualização computacional no apoio do estado afetivo de interesse na EaD: das ferramentas de captura ao modelo de inferência

Maurício José Viana Amorim

Instituto Federal Fluminense [amorim@iff.edu.br]
Doutor em Informática na Educação/UFRGS

Maqda Bercht

UFRGS/PGIE [bercht@inf.furb.br]
Doutora em Computação /UFRGS

Patricia Alejandra Behar

UFRGS/PGIE [patricia.behar@pq.cnpq.br]
Doutora em Computação/ UFRGS

Na Educação a Distância (EaD), o professor e o aluno elegem um conjunto de Tecnologias da Informação e Comunicação (TIC) para que ocorra a comunicação entre ambos e a interação para a aprendizagem. Essa comunicação e essa interação podem ocorrer por meio dos Ambientes Virtuais de Aprendizagem (AVA), dos Objetos de Aprendizagem (OA), de *e-mails*, de vídeo ou áudio conferência ou outras TIC. Todos os meios de comunicação e de interação entre os professores e os alunos são entendidos no contexto deste trabalho como ambiente de EaD¹. Nesses ambientes, a comunicação muitas vezes ocorre de maneira assíncrona, quando os interagentes (professores/alunos) não estão conectados ao mesmo tempo, fato que dificulta a percepção das dificuldades e o interesse do aluno por parte do professor (AMORIM, 2012).

Na aula presencial, o professor pode perceber o interesse do aluno e, a partir daí, é capaz de modificar a estratégia pedagógica de forma a buscar aumentar ou manter esse nível de interesse. Boa parte dessa percepção ocorre por meio da visão. Sendo a visão um dos mais importantes sentidos do ser humano no apoio à detecção do interesse², a falta desse meio de sensoramento causa carências quando se passa para o paradigma da

¹ Ambiente de EaD abrange os Ambientes Virtuais de Aprendizagem (AVA), Objetos de Aprendizagem (OA) e as outras Tecnologias da Informação e Comunicação (TIC) utilizadas durante a interação entre os alunos e os professores.

² Esta premissa é baseada nos trabalhos de Pease e Pease (2005), Weil e Tompakow (2011), Cohen (2011) e Argyle (1988). Em seus trabalhos, esses pesquisadores apresentam diversas características visuais que indicam a ocorrência do estado afetivo de interesse.

EaD, no qual a Visualização Computacional (VC) é pouco utilizada (PRATA; NASCIMENTO, 2007).

Nesse sentido, este trabalho busca indicadores que possam ser utilizados para a inferência do interesse a partir da análise de imagens de alunos em interação com ambientes de EaD e, assim, propõe um Modelo para Inferência do Interesse.

1. FERRAMENTAS PARA OBTENÇÃO DE IMAGENS EM AMBIENTES DE EaD

No decorrer desta pesquisa, foram construídos três artefatos com objetivo de obtenção das imagens em ambientes de EaD. A construção deles possibilita dotar ambientes de EaD da capacidade de VC. Os mesmos são denominados WICFramework, QuizWebcamXML e SQLOA e serão apresentados ao longo do texto.

O WICFramework, detalhado em Amorim (2010), é um *framework* para captura das imagens da câmera do usuário e direcionamento desta para um servidor devidamente preparado para recebê-las. Toda a parte de transmissão das imagens capturadas e recepção destas por parte do servidor é função deste *framework*. Compõe-se basicamente por dois módulos: o módulo cliente, que liga a câmera, obtém as imagens e as transmite; e o módulo servidor, que recebe as imagens, ordena, nomeia e grava (Figura 1).

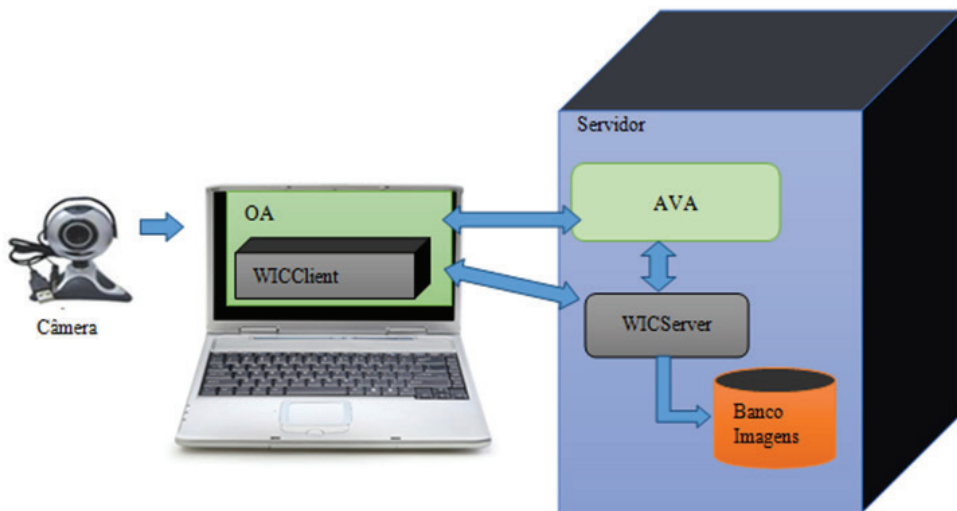


Figura 1 - Detalhamento do QuizWebcamXML

Fonte: Elaboração própria (2014).

O segundo artefato construído é denominado QuizWebcamXML (AMORIM et al., 2011a). O artefato é uma ferramenta abrangendo três módulos: o módulo XML é responsável por abrir o arquivo “xml” de mesmo nome da ferramenta e extrair dele as questões, as figuras, as possíveis respostas e o gabarito; o módulo Quiz, cuja função é montar o questionário com os parâmetros fornecidos pelo módulo XML; e, por último, o módulo Webcam tem a finalidade de ligar a câmera do usuário, registrar as imagens e enviá-las para o servidor. A Figura 2 detalha sua estrutura e a Figura 3 exemplifica o seu funcionamento.

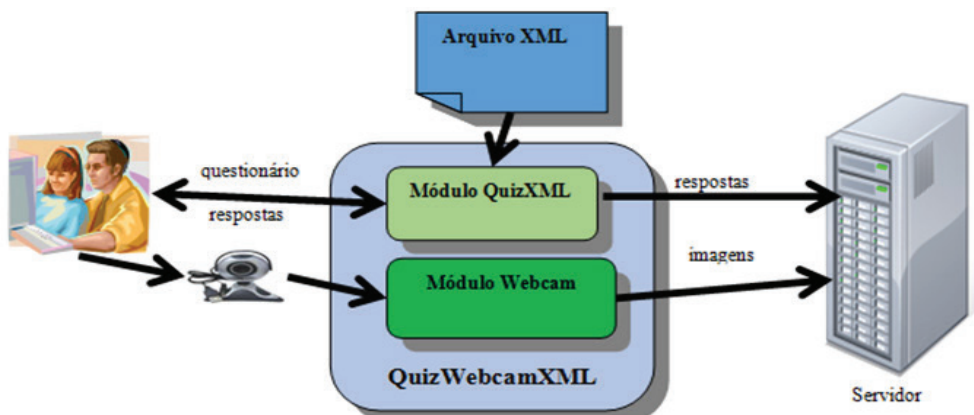


Figura 2 – Detalhamento do QuizWebcamXML

Fonte: Elaboração própria (2014).

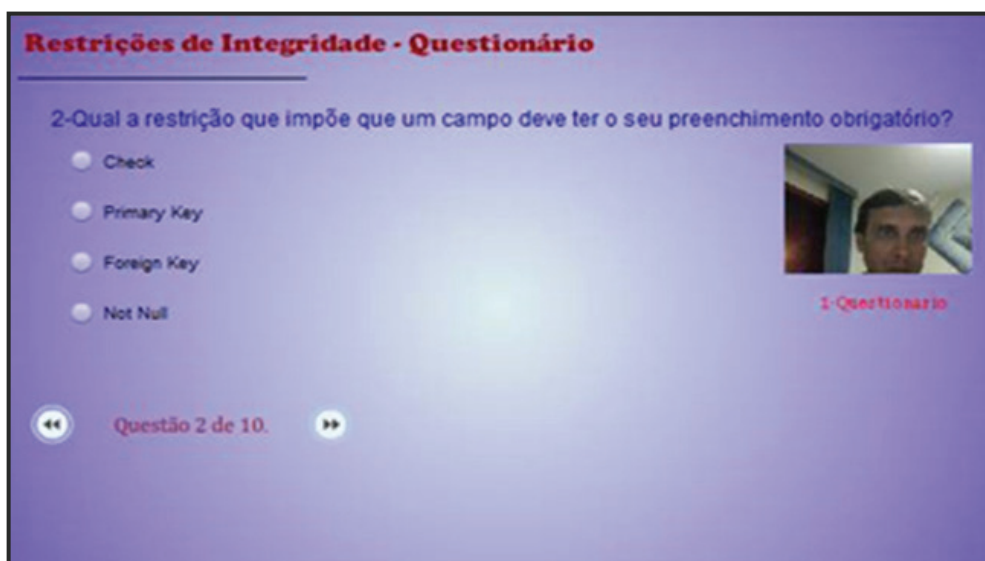


Figura 3 - Tela do QuizWebcamXML em funcionamento

Fonte: Elaboração própria (2014).

O último artefato construído foi o objeto de aprendizagem denominado de SQLOA (AMORIM et al., 2011b). O SQLOA tem por objetivo apoiar o ensino da disciplina de banco de dados. Por meio dele, o aluno identifica-se, utiliza o material didático e tem acesso aos módulos que possuem VC, no caso a videoaula e o questionário. O SQLOA mantém, em sua base, os dados do aluno, as respostas dos questionários executados e o histórico de utilização dos módulos.

2. COLETA DE DADOS E ANÁLISE DAS IMAGENS

Inicialmente realizou-se uma revisão literária buscando os principais Movimentos Corporais, Gestuais e Posturais (MCGP) indicativos do estado afetivo de interesse. A partir dessa coleta, procurou-se observar, nas imagens, quais MCGP podem ser obtidos através da VC. Para isso, agruparam-se os alunos por desempenho. A ideia central inicial foi buscar nos vídeos da interação de cada grupo, padrões de comportamento comuns que indicassem o grau de interesse. Esta associação de desempenho x interesse tem, por base, a premissa de que alunos mais interessados obtêm desempenho superior aos alunos menos interessados (CHARDOSIM, 2011).

Para o nivelamento dos alunos, foi aplicado um pré-teste com a finalidade de eliminar os alunos com desempenhos não condizentes com o padrão de comportamento esperado pela premissa. Baseado na teoria da Aprendizagem Significativa (AUSUBEL et al., 1978), isso poderia ocorrer em duas situações:

- supondo que o aluno já conhecesse o conteúdo, ele poderia demonstrar desinteresse (tédio) perante as câmeras e mesmo assim obter um bom desempenho;
- o inverso também poderia acontecer. Supondo que o aluno não conhecesse o conteúdo, ele poderia demonstrar interesse, e não ter subsunçores necessários a uma Aprendizagem Significativa. Dessa forma, apesar dos indicativos comportamentais do estado afetivo de interesse se apresentarem, seu desempenho será ruim.

O pré-teste foi aplicado objetivando diagnosticar e separar os indivíduos que já conhecem o conteúdo e os que não tinham subsunçores necessários à Aprendizagem Significativa dos conteúdos ensinados dos demais alunos. Segundo Ausubel (1978), a aprendizagem é dita significativa quando uma nova informação (conceito, ideia, proposição) adquire significados para o aprendiz por meio de uma espécie de ancoragem em aspectos relevantes da estrutura cognitiva pré-existente do indivíduo.

Ao todo, 31 alunos foram submetidos aos experimentos. Os alunos faziam parte de três turmas da disciplina de Administração para Banco de Dados do Curso de Sistema de Informação do Instituto Federal Fluminense, RJ. Destes, 30 foram classificados como aptos. Ressalta-se o fato de todos os alunos participarem de todas as fases, mas apenas os escolhidos na fase de pré-teste tiveram seus Movimentos Corporais, Gestuais e Posturais (MCGP) analisados (AMORIM et al., 2011a).

A seguir, os alunos foram convidados a assistir à videoaula sobre Restrições de Integridade e também a responder ao Quiz criado contendo questões sobre o assunto. Tanto a videoaula quanto o Quiz fazem parte do SQLOA e através da capacidade de VC do OA, as imagens dessa interação (vídeos) foram capturadas. Além dos vídeos, o desempenho obtido no Quiz foi utilizado nas conclusões.

De posse dos dados, seguiu-se um levantamento dos MCGP encontrados nas imagens obtidas. A partir desse levantamento e de sua associação com desempenho obtido no Quiz, buscaram-se os MCGP que melhor indicavam o estado afetivo de interesse. Além desse levantamento, foi feita uma entrevista com os alunos. Esta objetivava o detalhamento de fenômenos que contradiziam a bibliografia ou tentava explicar algum comportamento novo ainda não relatado. A Figura 4 esquematiza o processo descrito, cujos resultados serão apresentados na próxima seção.

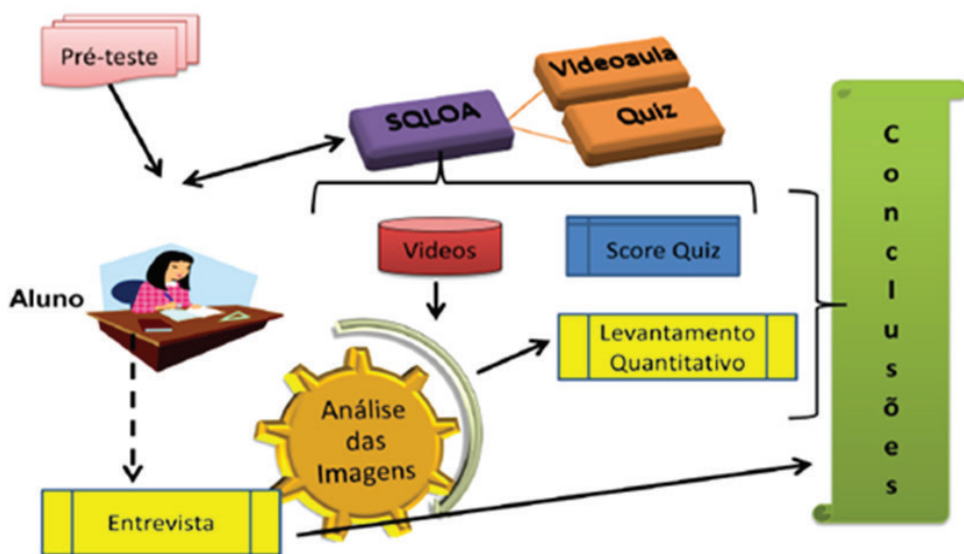


Figura 4 - Processo metodológico

Fonte: Elaboração própria (2014).

3. INDICADORES DE INTERESSE

A partir da separação da amostra em grupos, segundo o desempenho no Quiz, iniciou-se a análise das imagens. Nessa fase, assistiu-se aos vídeos das interações dos alunos de maior e de menor desempenho e os MCGP encontrados foram assinalados e contabilizados em suas fichas. A Tabela 1 mostra os principais MCGP encontrados nos vídeos.

Tabela 1 - Principais MCGP encontrados nos vídeos

Gestos	Descrição
11	Balançar a cabeça afirmativamente
12	Balançar a cabeça negativamente
13	Bater atrás da nuca
14	Esconder a boca
15	Franzir a testa
16	Ajeitar a boca
17	Olhar para o lado
18	Piscada Longa
19	Dar de ombros
20	Coçar a cabeça, boca, queixo, orelha ou nariz
21	Ajeitar-se na cadeira
22	Aproximar-se e voltar
23	Afastar-se e voltar
24	Balançar o corpo

Fonte: Elaboração própria (2014).

Além dos MCGP descritos na Tabela 1, com base na teoria sobre Comunicação Não Verbal (CNV), foram criadas seis taxas: a taxa de foco (JOLIVET, 1967), taxa de tensão aparente de (KAPOOR; PICARD, 2005; ARGYLE, 1988), taxa de apoio da cabeça (PEASE, A.; PEASE, B., 2005), taxa de mobilidade facial aparente (KAPOOR; PICARD, 2005), taxa de mobilidade corporal aparente (HAKURA et al., 2010; KAPOOR; PICARD, 2005) e taxa de piscada (ARGYLE, 1988; PEASE, A.; PEASE, B., 2005).

A classificação das imagens por meio das taxas obedeceu à escala de 1 a 5. Amorim (2012) detalha o processo de escolha e de criação desses indicadores. Dessa forma, as fichas com o levantamento quantitativo de cada aluno passaram a ter um local para anotação dessas taxas com suas respectivas métricas. A Tabela 2 apresenta as taxas criadas. Um resumo do levantamento feito é visto na Tabela 3. Nela observa-se cada aluno do grupo de maior e menor escores (Grupo 1 e Grupo 5) e suas respectivas MCGP.

A escolha dos Indicadores de Interesse é realizada por meio do confronto das médias aritméticas dos MCGP de cada grupo. Os MCGP cuja diferença das médias for superior a 1,5 são considerados como Indicadores de Interesse.

Tabela 2 - Indicadores de interesse criados

Gestos	Descrição
1	Taxa de foco
2	Taxa de tensão aparente
3	Taxa de apoio da cabeça
4	Taxa de mobilidade facial aparente
5	Taxa de mobilidade corporal aparente
6	Taxa de piscada

Fonte: Elaboração própria (2014).

Casos individuais nos quais os MCGP tiveram uma grande discrepância sobre a média geral foram destacados e chamados para uma entrevista. Por exemplo, o caso do aluno 238 no indicador 18 (piscada longa). A partir das entrevistas, outros Indicadores de Interesse foram escolhidos.

Os MCGP escolhidos com indicadores de interesse foram: a Taxa de Foco, a Taxa de Apoio da Cabeça, Forma de apoio da Cabeça, Taxa de Piscada, Piscada Longa, Atividades Dispersivas, Olhar para os lados e Mudança de Postura. Amorim (2012) faz o detalhamento de cada um desses Indicadores.

Tabela 3 - Resultados da análise dos vídeos dos grupos 1 e 5

Alunos de Grupo 1						Alunos de Grupo 5					
MCGP	220	230	219	206	Média	MCGP	211	209	221	238	Média
1	5	5	5	4	4,75	1	3	1	2	2	2,00
2	2	3	3	5	3,25	2	2	5	5	3	4,00
3	1	5	3	3	3,00	3	2	0	2	0	1,33
4	2	2	2	5	2,75	4	2	4	4	3	3,33
5	2	2	3	4	2,75	5	2	4	4	3	3,33
6	1	2	1	1	1,25	6	2	4	4	5	3,33
11	0	0	0	0	0,00	11	0	0	0	0	0,00
12	0	0	1	1	0,50	12	0	0	0	0	0,00
13	0	1	0	1	0,50	13	0	1	0	0	0,33
14	0	0	7	0	1,75	14	0	0	1	0	0,33
15	0	0	0	3	0,75	15	0	0	0	0	0,00
16	0	0	0	3	0,75	16	1	0	0	2	0,33
17	0	0	2	3	1,25	17	1	8	8	0	5,67
18	0	0	0	0	0,00	18	3	0	0	10	1,00
19	0	0	0	1	0,25	19	0	0	0	0	0,00
20	3	3	2	9	4,25	20	0	0	4	1	1,33
21	1	2	0	0	0,75	21	0	2	2	5	1,33
22	0	0	0	1	0,25	22	0	0	1	2	0,33
23	0	1	0	0	0,25	23	0	2	0	0	0,67
24	0	0	1	1	0,50	24	1	1	1	0	1,00
Δt	3,3	4,2	5,0	10,17	5,71	Δt	9,2	7,0	5,5	5,5	7,26
Score	9	9	9	9	9,00	Score	2	2	3	4	2,33

Fonte: Elaboração própria (2014).

4. MODELO PARA INFERÊNCIA DO INTERESSE

O objetivo deste trabalho é a identificação do interesse do aluno a partir da análise das imagens capturadas por meio da Visualização Computacional em ambientes de EaD. Uma das etapas para esta verificação foi o levantamento dos indicadores do estado afetivo de interesse que podem ser obtidos através da VC. Essa etapa foi descrita na seção anterior. Dentre as diversas taxas e MCGP apresentados, as taxas de foco, de apoio de cabeça e de piscada e os MCGP “olhar para o lado”, “atividades dispersivas”, “forma de apoio da cabeça”, “piscada longa” e “mudança de postura” foram os que apresentaram os resultados mais significativos na detecção do interesse do aluno.

De posse dos indicadores e, por conseguinte, da possibilidade de inferência do interesse em ambientes EaD, surge outra questão: Como um profissional da educação pode utilizar esses indicadores para o acompanhamento do interesse do aluno?

Gatti (2003) lembra que o professor tem a tarefa de acompanhar o desenvolvimento do aluno. Ele deve acompanhar o processo de desenvolvimento das atividades escolares, compreender como estão se concretizando, oferecer informações relevantes para o próprio desenvolvimento do ensino e para o planejamento das atividades escolares. Todo esse processo passa pelo viés afetivo em que acompanhar a motivação e o interesse do aluno é de suma importância, completa Longhi (2011).

Novak (1977) aponta para o papel da afetividade na regulação das relações de significação entre o professor e os estudantes e na estreita inter-relação entre predisposição para aprender e Aprendizagem Significativa. Aprender Significativamente é fixar os conceitos à estrutura cognitiva existente de maneira organizada e consistente e o interesse é um fator que interfere positivamente.

Partindo desses conceitos, este trabalho propõe um *Modelo para Inferência do Interesse* (Figura 5) que utiliza os Indicadores de Interesse em conjunto com um esquema denominado *Esquema para Identificação do Interesse* (EII). O modelo baseia-se na análise das imagens dos alunos, quando se contabiliza os MCGP destacados e produz-se um Extrato dos Indicadores de Interesse. Os valores de cada Indicador de Interesse é submetido ao EII e define um valor entre 0 e 100% condizente com a taxa de interesse do aluno. Amorim (2012) mostra as fórmulas e o algoritmo do Esquema para Identificação do Interesse.

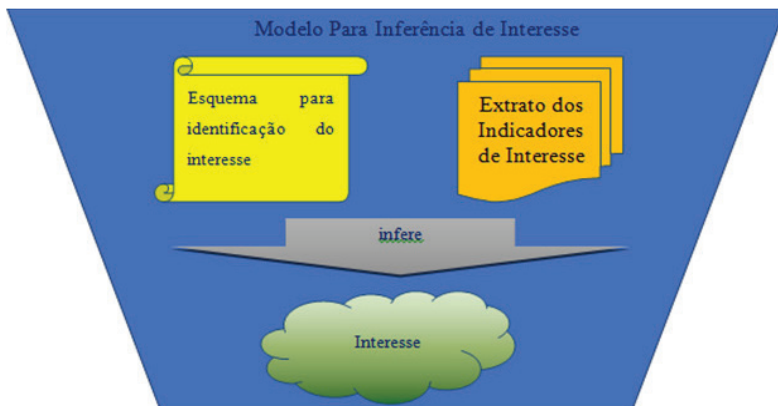


Figura 5 - Modelo para inferência de interesse

Fonte: Elaboração própria (2014).

Para ilustrar o Modelo para Inferência de Interesse, a figura 6 contém um exemplo como todo o processo ocorre. A parte pontilhada da figura destaca a parte referente ao modelo. Inicialmente, o aluno acessa o ambiente de EaD que captura os vídeos com as imagens, armazenando-as. Os vídeos são transformados em extratos contendo os identificadores de interesse dos alunos. De posse desses extratos, com auxílio do Esquema para Identificação do Interesse, o professor pode obter o interesse do aluno, utilizando-o para, por exemplo, modificar suas estratégias pedagógicas, objetivando manter ou elevar o interesse do aluno ou da turma. O autor deste trabalho acredita que a manutenção de bons níveis de interesse é um dos fatores norteadores para a Aprendizagem Significativa.

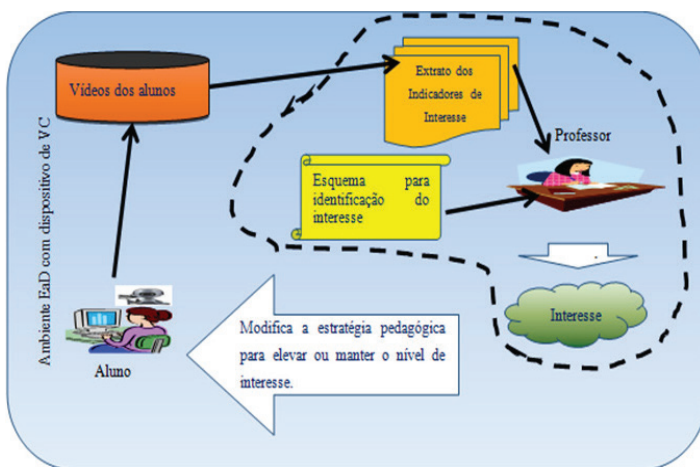


Figura 6 - Uso do modelo para inferência de interesse

Fonte: Elaboração própria (2014).

5. ESQUEMA PARA IDENTIFICAÇÃO DO INTERESSE

Uma parte importante no Modelo de Inferência de Interesse é o Esquema para Identificação do Interesse. Ele é um conjunto de procedimentos e fórmulas para que o usuário, ao segui-lo, possa inferir com algum grau de certeza o interesse do aluno.

Para utilizar o Esquema para Identificação do Interesse, faz-se necessário possuir extratos contendo a identificação do aluno e os demais identificadores de interesse criados com suas respectivas contagens e quantificações. Na identificação do aluno, pode-se optar por elementos que não sejam necessariamente o seu nome, sua matrícula, seu número de chamada, entre outros. As outras variáveis foram aqui denominadas de i1 a i8 em referência à abreviação de identificador1 ... identificador8, cada qual correspondendo a um indicador específico. A Tabela 4 mostra os indicadores utilizados e suas variáveis correspondentes.

Tabela 4 - Extrato dos Indicadores de Interesse

#	Identificação do Aluno
i1	Taxa de Foco
i2	Taxa de Apoio da Cabeça
i3	Taxa de Piscada
i4	Forma de Apoio da Cabeça
i5	Piscada Longa
i6	Atividades Dispersivas
i7	Olhar para os Lados
i8	Mudança de Postura

Fonte: Elaboração própria (2014).

O Esquema para Identificação do Interesse é dividido em seis passos (Figura 7). Os passos foram denominados de p1 a p6. Cada um dos passos possui entradas, ações, resultados parciais, pesos e resultados finais. Os valores de entrada são os Indicadores de Interesse presentes nos extratos (i1, i2,...,i8). A saída do esquema é o resultado final $P(x)$ que é o interesse de cada passo. Dependendo do passo, um ou mais Indicadores de Interesse podem ser utilizados, por exemplo, o p3 utiliza os indicadores i3 e i5 como entrada.

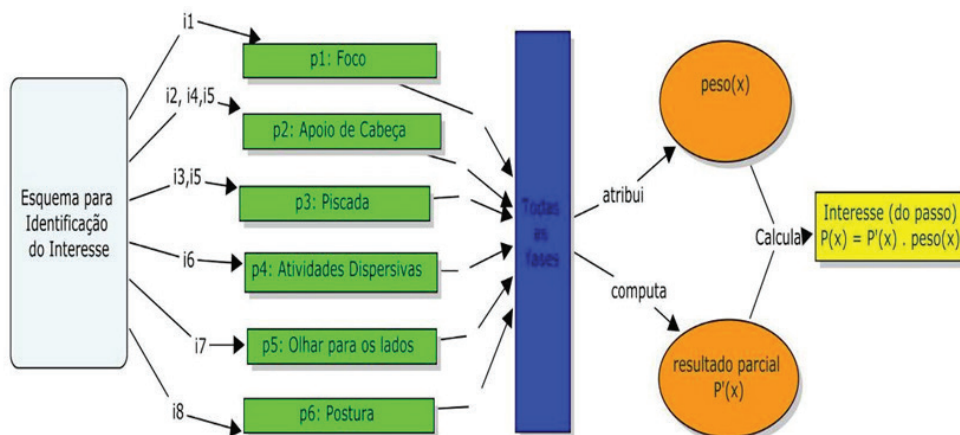


Figura 7 - Esquema para identificação do interesse

Fonte: Elaboração própria (2014).

As ações são algoritmos a serem seguidos com os dados de entrada. A saída deste algoritmo será o resultado parcial $P'(x)$ em que x indica o passo que está sendo processado. Essa saída sempre terá como valores as constantes Interesse, Tédio ou Neutro. Nesse esquema, o **Interesse** é uma constante de valor **igual a 1**. O **Tédio** uma constante de valor **igual a 0**. O **Neutro** uma constante de valor **igual a 0,5**. Os algoritmos são detalhados em Amorim (2012).

O Esquema para Detecção do Interesse permite que cada um dos resultados parciais obtidos $P'(x)$ possa ter os seus valores ajustados para o cômputo do resultado final. Isso é feito pelo usuário por meio da atribuição de pesos distintos a cada um dos passos. O usuário pode, por exemplo, atribuir pesos maiores nos critérios em que acredita serem mais adequados para a detecção do interesse.

Para o cômputo do valor do Interesse de cada passo $P(x)$, multiplica-se cada um dos resultados parciais pelo peso de cada passo. O peso padrão de cada passo é igual a 1 (Equação 1).

O interesse final é o somatório dos interesses de todos os passos, divididos somatório dos pesos atribuídos a cada um dos passos, conforme equação 2.

Equação 1 - Interesse de cada passo

$$P(x) = P'(x) \cdot \text{peso}(x) \quad \text{onde} \quad 0 \leq \text{peso}(x) \leq 1$$

Interesse	= 1
Tédio	= 0
Neutro	= 0,5

Fonte: Elaboração própria (2014).

Equação 2 - Cálculo do Interesse Final

$$\text{Interesse Final} = \frac{\sum_{i=1}^6 P(x)}{\sum_{i=1}^6 \text{peso}(x)}$$

Fonte: Elaboração própria (2014).

A Tabela 5 exemplifica o cálculo do interesse para dois alunos. O aluno 220, segundo o modelo, obteve o interesse de 58%, e o aluno 211 obteve o interesse de 9%. Observa-se, nesse exemplo, que o peso do passo 5 foi zerado.

Tabela 5 - Exemplo de inferência do interesse

Aluno	220			211			
#	peso(x)	Entradas	P(x)	P(x)	Entradas	P(x)	P(x)
p1	1	i1=97%	Interesse=1,00	1,00	i1=80%	Tédio=0,00	0,00
p2	1	i2=20%,i4=tripé,i5=não	Neutro=0,50	0,50	i2=80%,i4=apoio,i5=sim(3)	Tédio=0,00	0,00
p3	1	i3=5/min,i5=não	Interesse=1,00	1,00	i3=5/min, i5=sim(3)	Tédio=0,00	0,00
p4	1	i6=4	Neutro=0,50	0,50	i6=0	Tédio=0,00	0,00
p5	0	i7=0	Interesse=1,00	0,00	i7=1	Interesse=1,00	0,00
p6	1	i8=1	Neutro=0,50	0,50	i8=1	Neutro=0,50	0,50
Σ	6			3,50			0,50
			Interesse:	58%		Interesse:	9%

Fonte: Elaboração própria (2014).

6. CONSIDERAÇÕES FINAIS

Este trabalho mostra que é possível utilizar a Visualização Computacional em ambientes de EaD para apoio à detecção do “interesse” do aluno. É apresentada uma ferramenta para prover ambientes de EaD a capacidade de VC. Destaca os principais Movimentos Corporais, Gestuais ou Posturais que se apresentaram mais adequados na inferência do interesse. Por último, exhibe um Modelo e um Esquema para a inferência do interesse, quando profissionais da educação, ao aplicarem o modelo, podem detectar o nível de interesse dos seus alunos.

O Modelo para Inferência do Interesse é baseado nos Indicadores de Interesse aqui apresentados. Já o Esquema para Identificação configura-se em um conjunto de passos (algoritmo) em que os extratos com os Indicadores de Interesse são aplicados e o nível de interesse do aluno é obtido. Amorim (2012) detalha cada passo com seus respectivos algoritmos.

REFERÊNCIAS

AMORIM, M. J. V. *Visualização Computacional como apoio à identificação do interesse do aluno em ambientes de EaD*. 2012. 169 f. Tese (Doutorado em Informática na Educação) - Universidade Federal do Rio Grande do Sul, Porto Alegre, RS, 2012.

AMORIM, M. J. V.; BERCHT, M.; BEHAR, P. A. Ferramenta para captura de imagens em ambientes virtuais de aprendizagem. In: CONFERÊNCIA IADIS IBERO-AMERICANA WWW/INTERNET, 2013, Algarve, Portugal. *Actas ...* Algarve, Portugal, 2010. p. 424-428.

_____. *QuizWebcamXML* - Uma ferramenta para confecção de questionários utilizando o padrão XML e com captura de imagens. In: CONFERÊNCIA IADIS IBERO-AMERICANA WWW/INTERNET, 2011, Lisboa, Portugal. *Actas ...* IADIS Press Publication, Lisboa, Portugal, 2011a.

_____. Análise do Grau de Interesse através da Visualização Computacional. In: SIMPÓSIO BRASILEIRO DE INFORMÁTICA NA EDUCAÇÃO, 22., 2011b, Aracajú, Sergipe. *Anais...Aracaju*, SE, 2011b.

ARGYLE, M. *Bodily communication*. 2. ed. London and New York, 1988.

AUSUBEL, D. P.; NOVAK, J. D.; HANESIAN, H. *Educational psychology*. New York: Holt, Rinehart and Winston, 1978. Publicado em português pela Editora Interamericana, Rio de Janeiro, 1980.

CHARDOSIM, N. M. O. *Um Estudo de associação entre Desempenho Escolar e Medidas Neuropsicológicas em Alunos da 3ª série do ensino fundamental*. 2011. Monografia (Especialização em Psicologia) - Universidade Federal do Rio Grande do Sul, Porto Alegre, RS, Brasil, 2011.

COHEN, D. *A Linguagem do Corpo: o que você precisa saber*. 4. ed. Petrópolis: Vozes, 2011.

GATTI, B. A. O Professor a avaliação em sala de aula. *Estudos em Avaliação Educacional*. São Paulo: Fundação Carlos Chagas, n. 27, p. 97-133, jan./jun. 2003.

HAKURA, J.; TAKAHASHI, N.; KUREMATSU, M.; FUJITA, H. Estimating Interest Level of Person through Posture by Vision System. Japan: *IOS PRESS*, 2010.

JOLIVET, R. *Tratado de Filosofia, Volume 2*. Traduzido por Gerardo Dantas Barretto. Rio de Janeiro: Agir Editora, 1967.

KAPOOR, A.; PICARD, R. W. Multimodal Affect Recognition in Learning Environments. In: ANNUAL ACM INTERNATIONAL CONFERENCE ON MULTIMEDIA, 13., 2005, Singapore. *Proceedings...* Singapore: ACM, 2005. p. 667-682.

LONGHI, M. T. *Mapeamento de aspectos afetivos em um ambiente virtual de aprendizagem*. 2011. Tese (Doutorado em Informática na Educação) - Universidade Federal do Rio Grande do Sul, Porto Alegre, RS, Brasil, 2011.

NOVAK, J. *A theory of education*. Ithaca, NY: Cornell University Press, 1977.

PRATA, C.; NASCIMENTO, A. *Objetos de aprendizagem: uma proposta de recurso pedagógico/Organização*. Brasília: MEC, SEED, 2007.

PEASE, A.; PEASE, B. *Desvendando os segredos da Linguagem Corporal*. Rio de Janeiro: Editora Sextante, 2005.

WEIL, P.; TOMPAKOW, R. *O Corpo Fala: a linguagem silenciosa da comunicação não verbal*. 4. ed. Petrópolis: Editora Vozes, 2011.