

## Reconhecimento e Adaptação à Dinâmica de Estados Afetivos Relacionados à Aprendizagem

Ernani Gottardo<sup>1</sup>, Andrey Ricardo Pimentel<sup>2</sup>

<sup>1</sup>Instituto Federal de Educação, Ciência e Tecnológica do RS (IFRS)  
Erechim – RS – Brasil

<sup>2</sup>Universidade Federal do Paraná (UFPR)  
Curitiba – PR – Brasil

ernani.gottardo@erechim.ifrs.edu.br, andrey@inf.ufpr.br

**Abstract.** *Recognizing and responding adequately to the learners' affective reactions has emerged as a key functionality for building a new generation of adaptive computing learning environments. This work presents a low intrusiveness hybrid model for inference of learning centered affective states. This model allows gathering information that indicates situations relevant to learning, such as, vicious cycle and engaged concentration. Promising results obtained in an experiment with students indicate the feasibility of this proposal and also support the presentation of alternatives for adapting the computational environment or implementing personalized pedagogical interventions.*

**Resumo.** *Reconhecer e responder adequadamente às reações afetivas dos aprendizes tem emergido como uma funcionalidade fundamental para a construção de uma nova geração ambientes computacionais de aprendizagem adaptativos. Neste trabalho é apresentado um modelo híbrido de inferência de estados afetivos relacionados à aprendizagem com baixa intrusividade. Este modelo permite a obtenção de informações que indicam situações relevantes para o aprendizado, como “ciclo vicioso” e “concentração engajada”. Resultados promissores obtidos em um experimento com estudantes indicam a viabilidade desta proposta e também embasam a apresentação de alternativas de adaptação ou implementação de intervenções pedagógicas personalizadas.*

### 1. Introdução

Bons professores em uma sala de aula convencional frequentemente adaptam suas estratégias de ensino com base nas reações (por exemplo, motivação, emoção, atenção, etc) dos estudantes, buscando mantê-los engajados. Neste sentido, uma das principais críticas relativas aos softwares educacionais atuais refere-se à falta de personalização e adaptação às necessidades individuais dos aprendizes [Botelho et al. 2017, Baker et al. 2012].

Sistemas Tutores Inteligentes (STI) são exemplos de softwares que buscam melhorar a capacidade de adaptação. Contudo, uma das principais limitações apresentadas pelos STI é a falta de recursos para adaptar-se aos estados emocionais dos estudantes [D’Mello et al. 2010, Baker et al. 2012].

Esta limitação encontrada na maioria dos ambientes computacionais voltados à aprendizagem torna-se relevante, pois pesquisas demonstram que as emoções in-

fluenciam diretamente, positiva ou negativamente, a aprendizagem [Picard et al. 2004, Paquette et al. 2014, Reis et al. 2018].

Inferir a emoção do estudante é o primeiro passo para a construção de ambientes de aprendizado sensível ao afeto. Assim, com base na emoção inferida, é possível implementar estratégias de adaptação em resposta às reações afetivas do aprendiz. Um exemplo da importância desta adaptação é apresentado em [Reis et al. 2018] que observam que quando o estado afetivo confusão não é propriamente acompanhado e administrado o estudante pode ficar entediado, estado afetivo que dificulta ou até impede a aprendizagem.

Entretanto, para a implementação de um estratégia eficiente de adaptação, além de reconhecer as reações afetivas no momento que elas ocorrem é fundamental também acompanhar a dinâmica destas reações. Desta forma, considerar a taxa de incidência, persistência e as transições dos estados afetivos relacionados a aprendizagem possibilita a inferência de padrões afetivo/cognitivos de mais alto nível como “Humor do Aprendiz” (*Learning Mood*) (positivo/negativo/neutro) [Baker et al. 2010], “Ciclo Vicioso” (*Vicious Cycle*) [D’Mello et al. 2007] ou “Concentração Engajada” (*Engaged Concentration*) [Baker et al. 2010].

Estados afetivos com maior incidência ou persistência podem ser usados para inferir o “humor do aprendiz”, enquanto que a repetição de estados afetivos com valência negativa que dificultam o aprendizado, como tédio e frustração, indicam um ciclo vicioso [Baker et al. 2010]. Por outro lado, “Concentração Engajada” é um estado afetivo-cognitivo com valência positiva que envolve atenção e foco na tarefa, sendo considerada uma parte do estado conhecido como “fluxo” (“*flow*”) [Baker et al. 2010].

Neste contexto, este trabalho utiliza um modelo de inferência de emoções desenvolvido pelos autores, baseado em uma estratégia híbrida que combina informações cognitivas e físicas. Além de apresentar bons resultados no processo de inferência, o modelo utilizado destaca-se por utilizar sensores pouco intrusivos e de baixo custo.

Com base nas inferências deste modelo híbrido são construídas representações da dinâmica ou trajetória das emoções dos estudantes durante um processo de aprendizagem. Por fim, considerando-se a dinâmica das emoções, são discutidas também possíveis estratégias de adaptações ou intervenções tutoriais que poderiam ser implementadas em um software educacional, buscando melhorar a experiência de aprendizagem dos estudantes.

## 2. Inferência de Emoções Relacionadas à Aprendizagem

O processo de inferência a ser apresentado neste trabalho foi planejado com o objetivo de permitir a identificação de padrões relevantes e que tenham impacto no processo de aprendizagem. Considerando-se esta premissa, a tarefa inicial desenvolvida no âmbito desta pesquisa consistiu na escolha do conjunto de emoções a ser considerado.

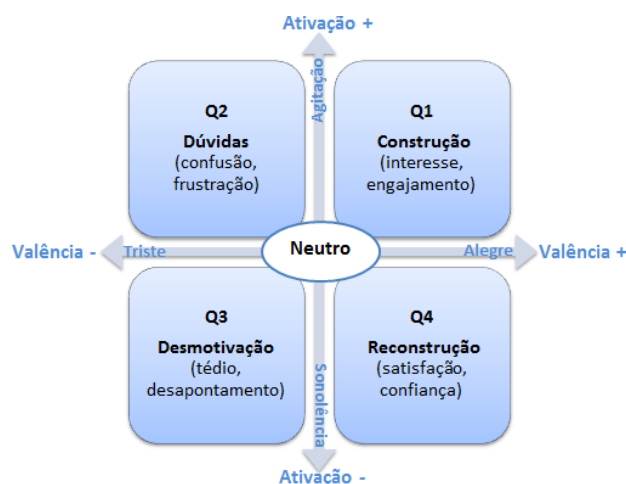
Trabalhos correlatos têm dado ênfase às emoções relacionadas à aprendizagem [Bosch et al. 2014, Conati 2011, D’Mello et al. 2007, Paquette et al. 2014, Jaques et al. 2014, Botelho et al. 2017]. Entretanto, analisando-se estes trabalhos, verifica-se que não há consenso quanto a definição de um conjunto definitivo de emoções.

Desta forma, neste trabalho optou-se por utilizar como fundamentação conceitual o ‘modelo circunplexo’ (*circumplex model*) [Russel 1980] e o ‘modelo de aprendizagem em espiral’ (*spiral learning model*) [Kort et al. 2001]. Ambos os modelos definem um

espaço bidimensional, formado pelas dimensões valência e ativação, em que as emoções de um estudante podem posicionar-se e mover-se dinamicamente durante o aprendizado.

Com base nestes dois modelos, optou-se por utilizar uma abordagem que agrupa as emoções em quadrantes formados pelas dimensões valência e ativação. Com isto, além do embasamento em pesquisas consolidadas [Russel 1980, Shen et al. 2009, Baker et al. 2010, Kort et al. 2001], diferencia-se através dos quadrantes os principais aspectos das reações afetivas relacionadas à aprendizagem. Adicionalmente, os quadrantes permitem o acompanhamento da dinâmica de evolução e transição das emoções.

A Figura 1 apresenta os quadrantes formados pelas dimensões valência (eixo horizontal) e ativação (eixo vertical) que foram nomeados como “Q1”, “Q2”, “Q3”, “Q4”, além de um estado “Neutro”(QN). Foi atribuído um nome representativo para cada um dos quadrantes e também as principais emoções relacionadas ao aprendizado contidas no mesmo considerando trabalhos correlatos [Russel 1980, Kort et al. 2001, Shen et al. 2009, Baker et al. 2010].



**Figura 1. Abordagem de representação das emoções em quadrantes**

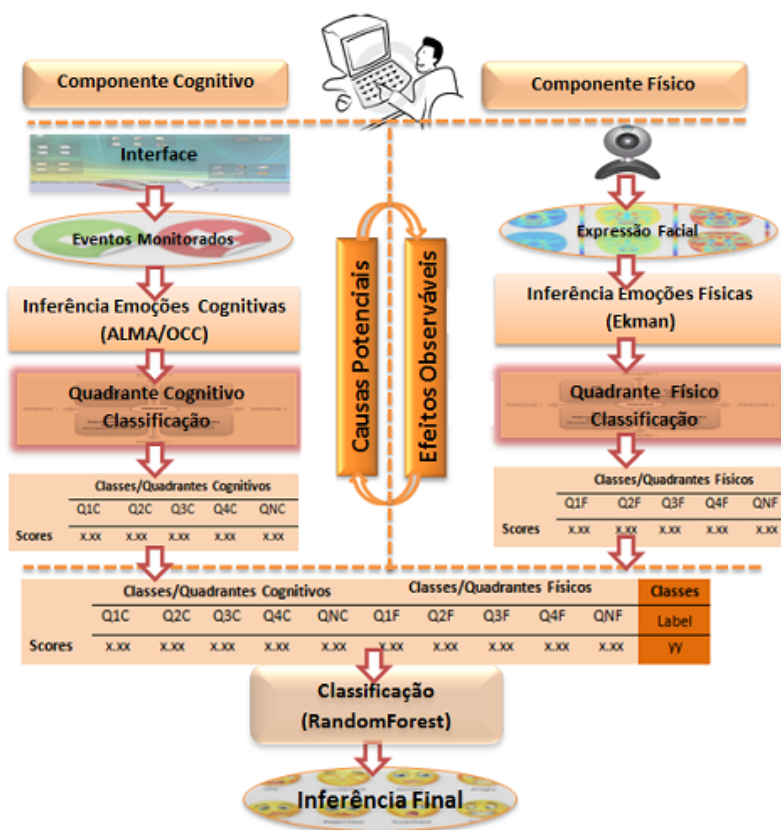
Para a inferência dos estados afetivos da Figura 1 foi utilizado o Modelo Híbrido de Inferência de Emoções - ModHEmo [Gottardo and Pimentel 2018, Gottardo and Pimentel 2017]. A Figura 2 exibe a representação gráfica deste modelo que apresenta como característica principal a divisão inicial do processo de inferência em dois componentes fundamentais: cognitivo e físico.

O componente cognitivo do ModHEmo tem como função principal o tratamento de dados comportamentais que possam indicar o contexto e as causas potenciais de geração de determinados estados afetivos. A inferência das emoções no componente cognitivo são implementadas usando o modelo cognitivo de Ortony, Clore e Collins - OCC [Ortony et al. 1990].

Por outro lado, o componente físico é responsável pelo monitoramento e extração de dados relacionados a efeitos observáveis. As reações físicas consideradas são as expressões faciais, capturadas usando webcam padrão. Com base nas expressões faciais são inferidas as emoções básicas do modelo clássico de Ekman [Ekman 1992].

A inferência do estado afetivo final representado pelos quadrantes (ver Figura 1), é

obtida pela fusão dos dois componentes. Este processo de fusão é realizado utilizando-se o algoritmo de classificação RandomForest [Witten et al. 2016].



**Figura 2. Modelo Híbrido de Inferência de Emoções - ModHEmo** Fonte: Adaptado de [Gottardo and Pimentel 2018]

A abordagem utilizada no ModHEmo baseia-se no fato de que as emoções nos seres humanos estão fortemente relacionadas com algumas reações físicas, mas também envolvem um processo racional/cognitivo [Picard 1997]. Desta forma, o ModHEmo tem como objetivo melhorar a inferência de emoções em um ambiente de aprendizado, investigando como diferentes tipos de dados podem ser combinados ou complementados.

### 3. Design do Experimento

Com o objetivo de verificar a viabilidade do ModHEmo e também analisar seus resultados, um experimento foi realizado com uma versão executável deste modelo. Neste experimento, utilizou-se como software educacional uma versão personalizada do ‘Tux, of Math Command’ ou TuxMath<sup>1</sup>. TuxMath é um software de código aberto que utiliza uma abordagem educacional baseada em jogos, permitindo que crianças pratiquem suas habilidades aritméticas enquanto defendem pinguins do ataque de cometas inimigos.

No experimento realizado com o ModHEmo integrado em uma versão personalizada do TuxMath, participaram 32 estudantes com idades entre 10 a 14 anos, cursando entre o quinto e nono ano do Ensino Fundamental. Este experimento foi realizado no laboratório de informática do Núcleo Tecnológico Municipal (NTM) e no laboratório de

<sup>1</sup><http://tux4kids.alioth.debian.org/tuxmath/index.php>

informática de uma escola do município de Erechim-RS entre os meses de outubro e novembro de 2017. É importante ressaltar que o experimento realizado foi devidamente aprovado pela Comissão de Ética em Pesquisa da Instituição Federal de Ensino em que o primeiro autor é professor.

Enquanto os estudantes usavam o TuxMath, alguns dos principais eventos do jogo foram monitorados, como por exemplo: acertos e erros nas questões, vencer ou perder o jogo, etc. Após a ocorrência de um evento monitorado, a imagem da face do estudante foi capturada com uma webcam básica e utilizada como entrada para o componente físico do ModHEmo. O tipo de evento foi utilizado como entrada para o componente cognitivo do modelo. Considerando-se estas duas entradas, a cada ocorrência de um evento monitorado, o ModHEmo realizou a inferência do provável estado afetivo do estudante.

Após a conclusão da atividade, os estudantes realizaram a rotulagem da base de dados criada durante a execução do jogo. Desta forma, foi possível verificar a acurácia do ModHEmo através da comparação das inferências do modelo com a classificação feita pelo estudante.

Para a tarefa de rotulagem foi desenvolvida uma ferramenta personalizada que foi instalada nos laboratórios de informática. Esta ferramenta permite que os estudantes revejam a sessão do jogo através de uma interface que mostra de forma sincronizada um vídeo capturado pela webcam, juntamente com um vídeo que mostra a gravação da tela do jogo. Desta forma o estudante pode rever suas reações de forma sincronizada com o desenvolvimento do jogo.

Os vídeos são pausados automaticamente pela ferramenta no instante específico em que um evento monitorado ocorreu. Neste momento, a imagem da Figura 3 com cinco *emoticons* representativos (um para cada quadrante mais o estado neutro) é mostrada e solicitado ao estudante para escolher o *emoticon* que melhor representa o seu estado afetivo naquele momento. Após a resposta do estudante, o processo continua.



Figura 3. *Emotions* utilizados para escolha dos estados afetivos

A estratégia de rotulagem de dados apresentada na Figura 3 baseia-se nos resultados de [Hayashi et al. 2016], demonstrando que crianças encontram dificuldades de uso e entendimento da ferramenta clássica SAM (*Self-Assessment Manikin*) [Bradley and Lang 1994]. Dessa forma, optou-se por utilizar *emoticons* familiares às crianças tendo em vista seu amplo uso atualmente em redes sociais e aplicativos de mensagens.

#### 4. Resultados do Experimento e Discussão

No experimento descrito na seção anterior, somando-se todos os 32 estudantes, foram gravados um total de 148 minutos de vídeo ( $\mu = 1,37$ ,  $\sigma = 0,52$  minutos por estudante) que registram as sessões de jogos no software educacional TuxMath. Além disso, foram gerados um total de 1.669 eventos monitorados, perfazendo uma média geral de 49,09 ( $\sigma = 16,77$ ) eventos por estudante.

No processo de inferência de estados afetivos utilizando o ModHEmo alcançou-se 1098 (65,79%) instâncias corretamente classificadas de um total de 1.669 eventos monitorados. Desta forma, 571 (34,21%) das instâncias foram classificadas de forma incorreta. A estatística Cohen Kappa [Witten et al. 2016] obtida foi de 0,5581 e a média da medida AUC (*area under curve*) [Witten et al. 2016] atingiu 0,867.

Estes resultados obtidos pelo ModHEmo podem ser considerados promissores quando comparados com o estado da arte publicado em trabalhos correlatos. Como exemplo, com base na expressão facial dos estudantes durante o uso de um STI, [Bosch et al. 2014] reporta o melhor índice Cohen Kappa de 0,112. Usando técnicas de mineração de texto [Paquette et al. 2014] mostrou um método para inferir quatro emoções: tédio, confusão, frustração e concentração. Para estas emoções, a melhor AUC relatada foi 0,777 e os melhores resultados para o índice Cohen Kappa foram de 0,486. O trabalho de [Botelho et al. 2017] usou uma abordagem de aprendizagem profunda (*deep learning*), baseada em registros da interação dos alunos em um STI, para inferir quatro emoções relacionadas ao aprendizado: confusão, concentração, aborrecimento, frustração. Neste trabalho, os melhores resultados reportados para AUC e Cohen Kappa foram, respectivamente, 0,78 e 0,24.


Os índices apresentados acima, apresentam um visão estática dos resultados obtidos. Porém, é possível adicionar uma dimensão temporal aos resultados do ModHEmo, permitindo a obtenção de informações que poderiam ser úteis para a implementação de estratégias de adaptação ou intervenção em um software educacional.

Desta maneira, na Figura 4 é apresentada graficamente uma comparação temporal entre o resultado da inferência do ModHEmo (linha azul) e a rotulagem feita por um estudante específico<sup>2</sup> (linha vermelha). Esta figura demonstra a trajetória afetiva do estudante durante a atividade de aprendizagem. O eixo horizontal do gráfico representa os instantes em que os eventos ocorreram e o eixo vertical representa os quadrantes ou classes.

É importante observar na Figura 4 que, mesmo em momentos que não há coincidência exata, em boa parte do tempo os valores reais e inferidos apresentam uma coerência aproximada entre as linhas. No intervalo aproximado entre 09:23:34 e 09:24:19 ocorreram as maiores divergências entre as linhas. Porém, mesmo neste intervalo, não são observados inconsistências extremas, como, por exemplo, o quadrante inferido ser “Q1” e o real “Q3”. As maiores diferenças neste intervalo ocorreram quando o valor inferido foi “QN” e o real “Q3”, como no intervalo aproximado entre 09:24:16 e 09:24:19.

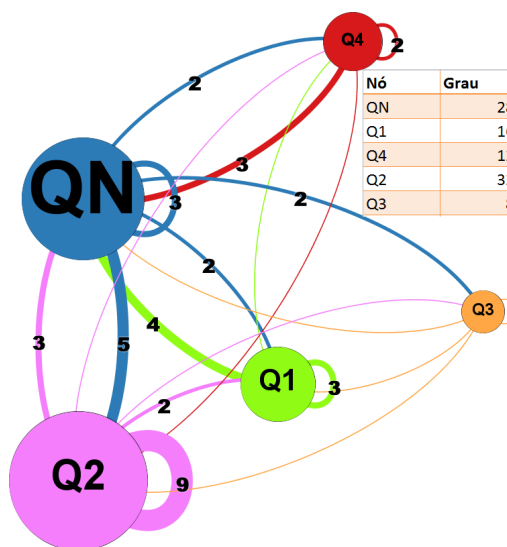
Com o objetivo de apresentar a dinâmica das relações em termos de incidência e persistência dos estados afetivos é apresentado na Figura 5 um grafo baseado nas inferências do ModHEmo para o mesmo estudante demonstrado na Figura 4. Os nós do

<sup>2</sup>Informações sobre o estudante foram omitidas por questões de confidencialidade



**Figura 4. Aderência entre a rotulagem e a inferência do ModHEmo para um estudante específico**

grafo representam os quadrantes, com o tamanho do nó sendo definido com o valor do grau ponderado deste nó. As arestas representam as transições entre os nós, incluindo transição para no mesmo nó (persistência). A cor da aresta é herdada do nó de origem. A espessura das arestas e os números nas linhas representam o peso de cada aresta no grafo. Para simplificar a visualização as linhas sem numeração tem peso igual a 1. A tabela inserida na figura mostra o grau de cada nó.



**Figura 5. Grafo apresentando a dinâmica dos estados afetivos de um estudante**

No grafo da Figura 5 pode-se perceber que o estado afetivo “QN”(neutro) e “Q2”(dúvidas) tiveram a maior incidência (tamanho do nó). Desta forma, pode-se perceber que o “humor do aprendiz” manteve-se principalmente em um estado geral entre neutro e dúvidas.

Um grafo que apresente o tamanho (incidência) do nó “Neutro” excessivamente superior aos demais poderia indicar que a tarefa foi muito fácil ou entediante. Esta afirmação deve-se ao fato de que uma aprendizagem eficiente é necessário manter um nível intermediário de ativação e experimentar um certo nível de frustração antes de atingir um incremento no aprendizado [Picard 1997, Baker et al. 2010].

Adicionalmente, o grafo apresentado acima apresenta-se como uma informação

relevante considerando-se que o aprendizado naturalmente envolve falhas ou erros [Kort et al. 2001] e que uma estratégia eficiente de aprendizagem deve reconhecer que encontrar e superar momentos de frustração é uma parte natural do aprendizado [Picard 1997]. Desta forma pode-se considerar normal um grafo com algumas incidências e transições para os nós “Q2” ou “Q3” como o apresentado na Figura 5.

Contudo, é importante observar a persistência que é observada principalmente no estado “Q2” da Figura 5, pois esta condição é um indicativo de um possível ciclo vicioso. Esta situação pode ser confirmada na Figura 4 que demonstra, por exemplo, que houve persistência do estado afetivo “Q2” aproximadamente entre às 09:22:00 e 09:22:37.

Neste caso, intervenções automáticas poderiam ser pertinentes, buscando trazer o estudante para um estado positivo que possa favorecer o aprendizado. Neste sentido, em [Reis et al. 2018] observou-se que estudantes identificados com traços da personalidade neuroticismo e um baixo nível de conhecimento em álgebra (elemento cognitivo) podem lidar com o sentimento de confusão (quadrante “Q2”) por pouco tempo, podendo facilmente sentir-se entediado (quadrante “Q3”) quando não há intervenção.

As inferências dos estados afetivos representados pelos quadrantes podem também ser úteis para implementação de estratégias de intervenção tutorial que combina elementos cognitivos e afetivos. Neste sentido, os trabalhos de [Woolf et al. 2009] e [Reis et al. 2018] apresentam algumas possibilidades de utilização desta abordagem de intervenção.

Como exemplo de aplicação da proposta de [Woolf et al. 2009] baseando-se nas inferências do ModHEmo pode-se citar: i) quando um estudante comete um erro (elemento cognitivo) e demonstra estar curioso e focado (elemento afetivo, quadrantes “Q1” e “Q4”) não é necessária intervenção, pois, neste caso, o estudante está engajado no aprendizado e exploração. Nesta situação, intervenções possivelmente seriam prejudiciais pois interromperiam a concentração ou engajamento. ii) caso o estudante esteja acertando (elemento cognitivo), mas apresenta sinais de frustração/aborrecimento (elemento afetivo, quadrantes “Q2” e “Q3”), é necessário aumentar o nível de desafio da atividade.

## 5. Considerações Finais, Limitações e Trabalhos Futuros

Neste trabalho foi apresentado um experimento em que as reações afetivas dos estudantes foram inferidas utilizando um modelo híbrido de reconhecimento de emoções relacionadas à aprendizagem. Este modelo destaca-se por apresentar um método para combinar informações bastante distintas (físicas e cognitivas), abordagem que é pouco explorada na comunidade de pesquisa atualmente. Além disso, o modelo utiliza sensores pouco intrusivos e de baixo custo com potencial de utilização em larga escala em ambientes reais de aprendizagem. Os resultados das inferências demonstram que o modelo é promissor e obteve resultados melhores quando comparado com trabalhos correlatos.

Baseando-se nas inferências afetivas obtidas pode-se implementar um conjunto de adaptações no ambiente computacional, buscando-se manter o estudante engajado nas atividades de aprendizagem. Além disso, as informações afetivas poderiam ser usadas para descrever um perfil da dinâmica das emoções dos aprendizes que indicam estados afetivos/cognitivos de alto nível como ciclo vicioso e engajamento. Estes estados tem um alto potencial de utilização para implementação de adaptações no ambiente computacional ou a aplicação intervenção pedagógica individualizadas.



Entende-se que uma possível limitação do trabalho refere-se à generalização dos resultados da pesquisa devido principalmente ao número de estudantes participantes do experimento. Para superar esta limitação e verificar a generalização dos resultados pretende-se realizar novos experimentos ampliando o o número de estudantes participantes, incluindo também estudantes com outras faixas etárias.

Aprimoramentos no processo de inferência do modelo apresentado farão parte de trabalhos futuros. Uma das principais melhorias planejada envolve a inclusão de novas informações com potencial de impactar positivamente na acurácia das inferências. Como exemplo pretende-se incluir a detecção de gestos, como movimentos de cabeça que indiquem discordância, que podem ser obtidos através dos vídeos já disponíveis.

## Agradecimentos

Os autores agradecem o IFRS e a UFPR pelo apoio financeiro para realização deste trabalho.

## Referências

- Baker, R., D’Mello, S., Rodrigo, M., and Graesser, A. (2010). Better to be frustrated than bored: The incidence and persistence of affect during interactions with three different computer-based learning environments. *International Journal of human-computer studies*, 68(4):223–241.
- Baker, R. S., Gowda, S., Wixon, M., Kalka, J., Wagner, A., Salvi, A., Aleven, V., Kusbit, G., Ocumpaugh, J., and Rossi, L. (2012). Sensor-free automated detection of affect in a cognitive tutor for algebra. In *Educational Data Mining 2012*.
- Bosch, N., Chen, Y., and D’Mello, S. (2014). It’s written on your face: detecting affective states from facial expressions while learning computer programming. In *International Conference on Intelligent Tutoring Systems*, pages 39–44. Springer.
- Botelho, A. F., Baker, R. S., and Heffernan, N. T. (2017). Improving sensor-free affect detection using deep learning. In *International Conference on Artificial Intelligence in Education*, pages 40–51. Springer.
- Bradley, M. M. and Lang, P. J. (1994). Measuring emotion: the self-assessment manikin and the semantic differential. *Journal of behavior therapy and experimental psychiatry*, 25(1):49–59.
- Conati, C. (2011). Combining cognitive appraisal and sensors for affect detection in a framework for modeling user affect. In *New perspectives on affect and learning technologies*, pages 71–84. Springer.
- D’Mello, S., Picard, R. W., and Graesser, A. (2007). Toward an affect-sensitive autotutor. *IEEE Intelligent Systems*, 22(4).
- D’Mello, S., Lehman, B., Sullins, J., Daigle, R., Combs, R., Vogt, K., Perkins, L., and Graesser, A. (2010). A time for emoting: When affect-sensitivity is and isn’t effective at promoting deep learning. In *Intelligent tutoring systems*, pages 245–254. Springer.
- Ekman, P. (1992). An argument for basic emotions. *Cognition & emotion*, 6(3-4):169–200.

- Gottardo, E. and Pimentel, A. (2017). Modelo híbrido de inferência de emoções para ambientes de aprendizagem: uma proposta baseada na fusão de componentes físicos e cognitivos. In *Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)*, volume 28, pages 1778–1780.
- Gottardo, E. and Pimentel, A. R. (2018). Improving inference of learning related emotion by combining cognitive and physical information. In *International Conference on Intelligent Tutoring Systems*, pages 313–318. Springer.
- Hayashi, E., Posada, J. E. G., Maïke, V. R., and Baranauskas, M. C. C. (2016). Exploring new formats of the self-assessment manikin in the design with children. In *Proceedings of the 15th Brazilian Symposium on Human Factors in Computer Systems*, page 27. ACM.
- Jaques, N., Conati, C., Harley, J. M., and Azevedo, R. (2014). Predicting affect from gaze data during interaction with an intelligent tutoring system. In *International Conference on Intelligent Tutoring Systems*, pages 29–38. Springer.
- Kort, B., Reilly, R., and Picard, R. W. (2001). An affective model of interplay between emotions and learning: Reengineering educational pedagogy—building a learning companion. In *Advanced Learning Technologies, 2001. Proceedings. IEEE International Conference on*, pages 43–46. IEEE.
- Ortony, A., Clore, G. L., and Collins, A. (1990). *The cognitive structure of emotions*. Cambridge university press.
- Paquette, L., Baker, R. S., Sao Pedro, M. A., Gobert, J. D., Rossi, L., Nakama, A., and Kauffman-Rogoff, Z. (2014). Sensor-free affect detection for a simulation-based science inquiry learning environment. In *International Conference on Intelligent Tutoring Systems*, pages 1–10. Springer.
- Picard, R. W. (1997). *Affective computing*, volume 252. MIT press Cambridge.
- Picard, R. W., Papert, S., Bender, W., Blumberg, B., Breazeal, C., Cavallo, D., Machover, T., Resnick, M., Roy, D., and Strohecker, C. (2004). Affective learning—a manifesto. *BT technology journal*, 22(4):253–269.
- Reis, H., Alvares, D., Jaques, P., and Isotani, S. (2018). Analysis of permanence time in emotional states: A case study using educational software. In *International Conference on Intelligent Tutoring Systems - ITS*, pages 180–190. Springer.
- Russel, J. A. (1980). A circumplex model of affect. *Journal of Personality and Social Psychology*, 39:1161–1178.
- Shen, L., Wang, M., and Shen, R. (2009). Affective e-learning: Using “emotional” data to improve learning in pervasive learning environment. *Journal of Educational Technology & Society*, 12(2):176.
- Witten, I. H., Frank, E., Hall, M. A., and Pal, C. J. (2016). *Data Mining: Practical machine learning tools and techniques*. Morgan Kaufmann.
- Woolf, B., Bursleson, W., Arroyo, I., Dragon, T., Cooper, D., and Picard, R. (2009). Affect-aware tutors: recognising and responding to student affect. *International Journal of Learning Technology*, 4(3-4):129–164.