



## Uaffect: Um Modelo para Predição de Estados Afetivos em Ambientes Educacionais a partir de Históricos de Contextos

Sandro O. Dorneles<sup>1</sup>, Luís Guilherme Eich<sup>2</sup>, Débora Nice Ferrari Barbosa<sup>3</sup>,  
Rosemary Francisco<sup>2</sup>, Jorge L. V. Barbosa<sup>2</sup>

<sup>2</sup>Universidade do Vale do Rio dos Sinos — UNISINOS

<sup>1</sup>Instituto Federal do Rio Grande do Sul (IFRS)

<sup>3</sup>Universidade Feevale

pfsandro@yahoo.com.br, luisguilherme@unisinossinos.br, deboranice@feevale.br  
{rosemaryf, jbarbosa}@unisinossinos.br

**Abstract.** *Studies indicate the growth and relevance of recognition systems of affective states in different areas. It is also known that there is a strong relationship between emotions and learning. So, what is the importance of context information in predicting affective states in educational environments? Thus, this article proposes Uaffect, a computational model that uses historical contexts formed in educational environments to classify and predict affective states. The model was evaluated from a quasi-experimental study with 25 students. The accuracy results found in the best scenario are 89% for positive affective states and 61% for negative affective states. The tests carried out showed evidences that indicate the possibility of using historical contexts in the classification and prediction of affective states in educational environments, which can be used to provide intelligent services that assist in decision making in educational planning and affective regulation of the student.*

**Resumo.** *Estudos apontam o crescimento e a relevância dos sistemas de reconhecimento de estados afetivos nas mais diferentes áreas. Sabe-se ainda, que existe uma forte relação entre emoções e aprendizagem. Assim, qual a importância das informações de contexto na predição de estados afetivos em ambientes educacionais? Dessa forma, este artigo propõe o Uaffect, um modelo computacional que utiliza históricos de contextos formados em ambientes educacionais para classificação e predição de estados afetivos. O modelo foi avaliado a partir de um estudo quase experimental com 25 alunos. Os resultados de precisão encontrados no melhor cenário são de 89% para estados afetivos positivos e de 61% para estados afetivos negativos. Os testes realizados apresentaram evidências que indicam a possibilidade de uso de históricos de contextos na classificação e predição de estados afetivos em ambientes educacionais, podendo ser usados para prover serviços inteligentes que auxiliem na tomada de decisão no planejamento educacional e regulação afetiva do aluno.*

### 1. Introdução

O ser humano interage constantemente com o meio onde vive, se adaptando e produzindo respostas fisiológicas ou psicológicas capazes de estabelecer e regular interações externas e funções internas [Cosenza e Guerra, 2011]. Estas respostas são definidas por Scherer (2000) como sendo estados afetivos que possuem características e reações próprias, como intensidade, duração, foco e impacto. São considerados estados afetivos distintos a emoção, humor, personalidade, atitudes e postura interpessoal. Esses

fenômenos preparam e orientam ações que se manifestam por alterações comportamentais, mobilizando entre outros, recursos cognitivos como atenção e percepção, fundamentais na aprendizagem, que impactam e são impactados pelo ambiente onde ocorrem.

O ambiente educacional é composto de todos os elementos que envolvem o educando e que estejam relacionados com os processos de aprendizagem. Logo, envolve os aspectos de interação, tanto virtuais como físicos, com artefatos e pessoas, constituindo-se como elementos determinantes para o aprendizado. Tais relações, sejam elas positivas ou negativas, podem influenciar de forma significativa os processos de ensino e aprendizagem.

Moore (2017) argumenta que há uma estreita relação entre o estado emocional de um indivíduo e o contexto em ambientes reais, podendo um ter influência sobre o outro. Logo, a integração pode melhorar tanto os sistemas sensíveis ao contexto quanto o reconhecimento afetivo, oferecendo oportunidades em diferentes domínios. Nesse sentido, considera-se Contexto como sendo “qualquer informação que possa ser usada para caracterizar a situação de uma entidade” [Dey, 2001]. Uma entidade pode ser uma pessoa, lugar ou um objeto relevante para a interação entre o usuário e uma aplicação.

As informações de contexto têm sido exploradas em muitos estudos para auxiliar no reconhecimento de estados afetivos [Álvares et al., 2020; Li e Sano, 2020; Wang et al., 2022; Sarmiento-Calisaya et al., 2022; Chen et al., 2023]. Entretanto, é necessário explorar aspectos relacionados ao impacto do contexto no estado afetivo, assim como a possibilidade de criação de históricos de contextos [Aranda et al., 2021; Martini et al., 2021] para auxiliar na análise, reconhecimento e predição de estados afetivos.

Hoang et al. (2021) consideram que o contexto, de forma geral possibilita não só a análise do sujeito principal, mas também informações complementares sobre o ambiente para o reconhecimento e a predição de estados afetivos. Portanto, conhecer essas informações podem auxiliar de forma estratégica na criação de ambientes educacionais que apoiem a regulação de estados afetivos negativos.

Desta forma, este estudo apresenta um modelo computacional baseado em históricos de contextos afetivos compostos de informações pessoais e educacionais, denominado *Uaffect*. O modelo permite a classificação e a predição de estados afetivos em ambientes educacionais. Para avaliar o modelo, conduziu-se um estudo com 25 alunos que apontou evidências favoráveis do uso do *Uaffect* no reconhecimento afetivo.

O restante do artigo está organizado da seguinte forma. A Seção 2 apresenta os trabalhos relacionados com o tema da pesquisa, destacando a contribuição científica da pesquisa. Na Seção 3 é apresentado o modelo *Uaffect* e suas características. A Seção 4 apresenta a avaliação e os resultados obtidos, e a seção 5 aborda as conclusões finais e trabalhos futuros.

## **2. Trabalhos relacionados**

Essa seção examina trabalhos realizados por outros pesquisadores, que apresentam contribuições no mesmo foco deste estudo, identificando possibilidades de ampliação nessa área. Os trabalhos foram selecionados a partir de um mapeamento sistemático [Dorneles et al., 2023], tendo como critério o reconhecimento de estados afetivos associados a informações de contexto em ambientes de educação.

O Inter-ACT apresenta uma proposta para criação de um repositório de vídeos afetivos, considerando o contexto em um cenário de jogo educacional. Segundo Castellano et al. (2010) a proposta consiste na captura de fatias de interação entre o jogador e um robô chamado iCat durante uma partida de xadrez. Os vídeos são descritos com dados multimodais, onde são capturados a face, a postura lateral, os movimentos do corpo do aluno, o vídeo do robô e as imagens contextuais dos eventos do jogo.

Benta et al. (2010) desenvolveram um aplicativo *web* com o objetivo de detectar emoções secundárias a partir de um contexto de aprendizagem informal. O cenário de testes proposto considera uma visita a um museu de artes a fim de induzir e definir as emoções sentidas pelos visitantes. O usuário identifica fatores contextuais e relaciona os fatores aos níveis de intensidade de cada emoção.

Kuo e Tseng (2011) propuseram um ambiente de aprendizagem que usa sensores fisiológicos para reconhecimento da emoção do aluno. O sistema utiliza resposta galvânica da pele (GSR) e um modelo espiral de aprendizagem de quatro quadrantes para reconhecer e regular a emoção do aluno.

Shminan e Othman (2015) propuseram um *framework* com o objetivo de construir um perfil dinâmico do aluno baseado na motivação que possa apoiar a recomendação de materiais em um ambiente de aprendizagem personalizado. O modelo proposto apresenta três componentes principais: monitoramento das características do aluno, análise de dados e recomendação de aprendizagem personalizada.

Santos et al. (2016a), apresentaram o projeto AICARP (*Ambient Intelligence Context-aware Affective Recommender Platform*) que utiliza uma plataforma *Health Sensor* para coletar dados fisiológicos como temperatura corporal, condutância da pele, frequência cardíaca e ECG com um objetivo inicial de explorar o potencial de inteligência ambiental para fornecer recomendações educacionais. A proposta foi estendida de forma significativa por Santos et al. (2016b) para AICARP v2.

Uria-Rivas et al, (2019), propõem o AICARP v3 e traz como proposta, melhorias na aquisição de sinais e uma nova plataforma de hardware, buscando reduzir a intrusão e distorção que os sensores podem causar no usuário em situações reais.

Sarmiento-Calisaya et al. (2022) propõem uma arquitetura sensível à emoção para sistemas persuasivos na educação. Informações fisiológicas são obtidas por uma pulseira Empática E4 e usadas como entrada para o módulo de detecção de emoções. Um algoritmo baseado em aprendizado estatístico é usado para identificar emoções negativas e determinar o nível de estresse do aluno.

A Tabela 1 mostra a comparação entre os estudos tendo como base: tipo de sinal ou reação do usuário utilizado como parâmetro no reconhecimento dos estados afetivos; informações de contexto consideradas pelos modelos; uso de informações do contexto educacional; utilização de históricos de contextos; examina se os estudos utilizam algum tipo de ontologia para a inferência ou a representação de estados afetivos.

A análise dos critérios permitiu identificar lacunas que contribuem para o *Uaffect* como a possibilidade de uso de históricos de contextos e integração das informações sensíveis ao contexto no reconhecimento de estados afetivos. Desta forma, o modelo proposto tem como principal contribuição a predição de estados afetivos a partir de históricos de contextos em ambientes de educação.

**Tabela 1: Comparação de trabalhos relacionados**

Estudos /autores	Sinal afetivo	Informações de contexto	Contexto Educacional	Histórico de Contexto	Ontologia
Inter-ACT [Castellano et al., 2010]	Visual (Face, postura)	Atividades (Eventos das partidas (logs))	Não	Não	Não
Benta et al. (2010)	Autorrelato	Identidade (Pessoas próximas e perfil) clima e tempo	Sim	Não	Não
Kuo e Tseng (2011)	Fisiológico	Identidade (Perfil)	Sim	Não	Não
Shminan e Othman (2015)	Visual (Face, postura)	Identidade (Perfil)	Sim	Não	Sim
Santos et al. (2016a)	Fisiológico	Atividades usuário	Não	Não	Não
Santos et al. (2016b)	Fisiológico	Atividades usuário	Não	Não	Não
Uria-Rivas et al. (2019)	Fisiológico	Atividades (Rastreamento de sensores)	Não	Não	Não
Sarmiento-Calisaya et al. (2022)	Fisiológico	Identidade/Atividades /localização /tempo	Sim	Não	Não
Uaffect	Multimodal	Identidade/Atividades /localização /tempo	Sim	Sim	Sim

### 3. Modelo Uaffect

Esta seção apresenta o Uaffect, um modelo computacional baseado em históricos de contextos para classificação e previsão de estados afetivos em ambientes educacionais. O modelo baseia-se na identificação de aspectos afetivos do aluno em interações com o ambiente educacional.

#### 3.1. Visão geral

O modelo proposto se baseia em aspectos como Computação afetiva [Picard, 1997], Computação Ubíqua [Weiser, 1991], [Satyanarayanan, 2001] e Estados Afetivos [Scherer, 2000], além dos trabalhos previamente revisados. Desse modo, fazem parte do modelo as seguintes características: Monitoramento de estados afetivos; Perfil do aluno; Rotulagem de estados afetivos; Ambiente educacional; Armazenamento de históricos de contextos; Utilização de agentes e Serviços inteligentes.

O monitoramento acompanha e coleta informações do aluno tais como localização, voz e face usando o *smartphone*, sinais fisiológicos através de vestíveis, comportamento através de interações em redes sociais, mensagens de texto e atividades realizadas pelo aluno no uso de dispositivos móveis. Um aplicativo *mobile* é responsável pela coleta de dados e encaminhamento das informações através de um *web service*, que recebe e trata as informações relacionadas ao contexto afetivo, contexto educacional e contexto pessoal. Em seguida, é realizada a fusão das informações e a classificação de estados afetivos. As informações são então armazenadas em históricos de contextos e usadas para oferecer serviços que serão consumidos através de uma aplicação *web*.

### 3.2. Arquitetura

A Figura 1 apresenta a arquitetura do modelo. A modelagem teve como base o padrão interno da SAP *Technical Architecture Modeling* (TAM, 2018), composta por atores (A1, A2), acessos, *Client* (*App*, *Web Site*), *Server* (Componente internos) e *Database*. O Uaffect organiza o fluxo das informações de forma a obter dados gerados pelo ator A1, tratando e disponibilizando informações com base nos históricos de contextos através de aplicações *web* ao ator A2.

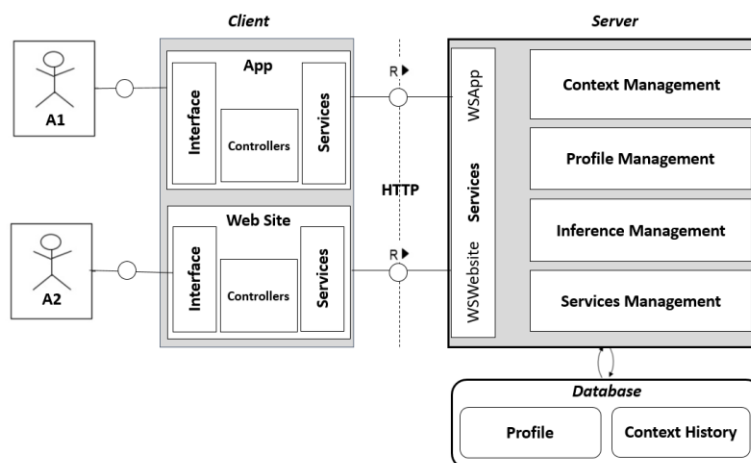


Figura 1: Arquitetura do modelo Uaffect

O ator A1 representa um aluno que pode gerenciar informações relacionadas ao seu perfil (Criar, ler, atualizar e deletar), obter informações sobre os recursos monitorados (redes sociais, sensores, mensagens e outros), cadastrar informações relacionadas ao ambiente educacional e rotular seu estado afetivo. O ator A2 representa uma equipe multidisciplinar que pode ser composta por professores, pedagogos, psicopedagogos e psicólogos que poderão acessar serviços relacionados aos estados afetivos do aluno.

O *client App* é responsável por monitorar e coletar as informações relacionadas ao contexto do aluno, suportando ações de A1 e realizando comunicação com o servidor utilizando *web services*. O *client Web Site* oferece uma interface de acesso para suportar ações de A2. No *Web Site* é possível monitorar informações relacionadas ao perfil, ambiente educacional e estados afetivos do aluno.

O *server* é responsável por processar os dados de contexto recebidos pelo *Web service*, comunicar os componentes internos e a *database*. O *server* está organizado nos seguintes módulos: i) *Services*; ii) *Context Management*; iii) *Profile Management*; iv) *Inference Management*; v) *Services Management*.

O módulo *Context Management* é responsável por receber, tratar e analisar os dados de contextos recebidos do módulo *Service*. O módulo *Profile Management* é responsável por gerenciar o perfil de cada aluno que faz parte do Uaffect. Ao receber dados de algum perfil, o módulo trata, interpreta e compara com os dados já existentes no perfil.

A *Database* armazena os dados do perfil do aluno do contexto educacional, sensores e históricos de contextos. Os históricos de contextos são compostos por

informações dos estudantes disponível no perfil e eventos que registram dados do estado afetivo do aluno, sensores, informações do contexto educacional e avaliação do nível de impacto destes contextos no estado afetivo percebido pelo aluno. Um exemplo do perfil e histórico de contextos do Uaffect é representado na Figura 2, no formato JSON.

```
{
  "profile": {
    "id": "115",
    "name": "Pedro",
    "course": "Informática",
    "gender": "M",
    "age": "16",
    "interests": [
      { "name": "Computer programming" },
      { "name": "Mathematics" }
    ]
  }
}

{
  "history": {
    "profile": {
      "event": {
        "reg_id": "02",
        "timestamp": "2023-03-10 09:07:34",
        "affectivestate": "Confusion",
        "lspace": "Lab6",
        "impactLS": "3",
        "subject": "Redes de computadores",
        "impact": "2"
      },
        "resource": "Materiais multimidia",
        "impactR": "4",
        "estrategie": "Aula expositiva",
        "impactE": "5",
        "impactP": "3",
        "sensors": [
          { "EDA": "1.182" },
          { "Temperature": "34.97" },
          { "BVP": "0.66" },
          { "HR": "74.33" }
        ]
      }
    ]
  }
}
```

Figura 2: Exemplo do perfil e histórico de contextos

O módulo *Inference Management* utiliza os registros contidos nos históricos de contextos para treinar o modelo considerando as informações coletadas e fornecidas pelo aluno através da aplicação *mobile*. O módulo *Services Management* é responsável por gerenciar os resultados de predição afetiva disponibilizando serviços inteligentes a partir do módulo *Service*.

#### 4. Avaliação e Resultados

A avaliação do modelo teve como foco os módulos de gerenciamento de contexto, gerenciamento de perfil e gerenciamento de inferência. A avaliação respondeu as seguintes questões: a) quais estados afetivos são percebidos no ambiente educacional? b) informações do contexto educacional podem ser utilizadas na predição do estado afetivo? c) históricos de contextos podem ser utilizados para a predição de estados afetivos?

A avaliação foi realizada em 2 etapas: a primeira, consistiu na coleta de dados do contexto educacional e estado afetivo do aluno através de rotulagem; a segunda envolveu o tratamento, formação de históricos de contexto e o treinamento usando os dados coletados.

##### 4.1. Coleta de dados

A coleta de dados para este estudo fez uso de uma versão adaptada do *Experience Sampling Method real time application* (ESMeRA) proposto por Eich et al. (2022), a partir de uma aplicação *mobile*. Este modelo computacional deu suporte à aplicação do método ESM auxiliando na coleta e análise de dados em tempo real.

Participaram do experimento proposto nessa etapa, 25 estudantes<sup>1</sup> de um Curso Técnico em Informática Integrado ao Ensino Médio. O experimento teve duração de 10 dias úteis. Foi fornecido aos alunos acesso à pesquisa a partir de aplicação *mobile*, disponível nas lojas *Apple store* e *Play store*. Inicialmente os estudantes realizaram um cadastro com informações sociodemográficas utilizadas na construção do perfil do indivíduo. A cada período de aula o aluno recebia notificação no aplicativo para fazer nova interação. A Tabela 2 apresenta a descrição dos dados coletados durante cada interação, envolvendo o estado afetivo do aluno em um determinado instante, assim como informações sobre o contexto de aprendizagem e avaliação do nível de impacto de cada uma das informações no estado afetivo.

**Tabela 2: Dados coletados no experimento**

Coluna	Identificador
Reg_Id	Representa a identificação de cada coleta realizada.
User_Id	Associa o aluno a um identificador único.
Timestamp	Registra data e hora em que a coleta de cada evento foi realizada.
Affective_state	Armazena informação do estado afetivo do aluno no instante da coleta.
Int (Intensity)	Representa a intensidade do estado afetivo com valores de 1 a 5 onde 1, é avaliado como muito fraca e 5 muito forte.
Learningspace	Identifica o contexto de localização <i>indoor</i> do aluno no ambiente de aprendizagem.
ImpactLS	Avalia de 1 a 5 o impacto que o local afeta o estado afetivo do aluno, sendo 1 muito negativo e 5 muito positivo.
Com Curriculum	Indica o componente curricular ocorrendo no instante da coleta.
ImpactC	Avalia de 1 a 5, o impacto com que o componente curricular afeta o estado afetivo do aluno, sendo 1 muito negativo e 5 muito positivo.
Resource	Exibe os recursos utilizados pelo professor.
ImpactR	Avalia de 1 a 5 o impacto dos recursos utilizados, no estado afetivo do aluno, sendo 1 muito negativo e 5 muito positivo.
Estrategia	Mostra as estratégias de aprendizagem utilizadas pelo professor.
ImpactE	Avalia de 1 a 5 o impacto das estratégias utilizados pelo professor no estado afetivo do aluno, sendo 1 muito negativo e 5 muito positivo.
ImpactP	Avalia de 1 a 5 o impacto dos indivíduos presentes no ambiente no estado afetivo do aluno, sendo 1 muito negativo e 5 muito positivo.

Para este experimento, foram considerados os estados afetivos engajamento, prazer e concentração com polaridade positiva, e com polaridade negativa, tédio, frustração e confusão. A utilização destes estados afetivos é baseada na pesquisa de D’Mello e Calvo (2013), pois segundo os autores se evidenciam com mais frequência em ambientes de aprendizagem.

A idade dos alunos participantes variou entre 15 e 17 anos, sendo a maioria dos participantes do sexo masculino 72% (18/25), enquanto 28% (7/25) eram do sexo feminino. Estas informações foram utilizadas para compor o perfil dos usuários. Ao final do estudo foram armazenados 472 registros contendo identificador do estudante, estados afetivos e os respectivos dados relacionados ao contexto educacional e a avaliação de impacto. Esses registros foram usados para compor o *dataframe* com os históricos de contextos que foram utilizados no treinamento do modelo Uaffect.

<sup>1</sup> O estudo foi aprovado pelo Comitê de Ética e Pesquisa da Universidade

As coletas foram realizadas em sala de aula (73%), laboratórios de informática (24%), e outros locais (3%). As coletas ocorreram nas disciplinas de Práticas de Hardware e Software (9%), Filosofia (3%), Sociologia (6%), Biologia (14%), Matemática (11%), Química (14%), Português (9%), Redes de Computadores (10%), Língua Inglesa (9%), Programação (6%), Física (5%) e Educação Física (4%). Em relação aos recursos pedagógicos utilizados pelos professores, 17% foram de materiais impressos, 19% de materiais multimídias, em 41% das aulas ocorreu utilização do projetor e em 45% o professor utilizou quadro branco ou outros recursos (16%). Diferentes estratégias foram identificadas durante a coleta tendo sido utilizadas combinadas ou individualmente como exercícios (43%), aulas expositivas (40%), práticas (24%), leituras (18%), trabalhos em grupo (7%) e outras estratégias (10%).

## 4.2. Análise dos resultados

Após a coleta de dados, foram realizados o tratamento dos dados e o treinamento do modelo. Nestas etapas, foi utilizada uma abordagem de prototipação evolucionária a partir de *scripts* em linguagem *Python*, com apoio da ferramenta *Jupyter Notebook*, bibliotecas *pandas* e *sklearn*. Os resultados obtidos são apresentados nas seções a seguir.

### 4.2.1. Quais estados afetivos são percebidos no ambiente educacional?

Os estados afetivos que apresentaram maior número de ocorrências foram concentração com 30,9% (146/472), tédio com 23,5% (111/472) e engajamento com 22,7% (107/472). Pode-se analisar também o nível de impacto das variáveis do contexto educacional no estado afetivo, a partir das médias dos resultados obtidos no estudo (Tabela 3), que foram avaliadas a partir de uma escala likert de 1 a 5 sendo: 1 muito negativo, 2 negativo, 3 neutro, 4 positivo e 5 muito positivo.

**Tabela 3: Média de impacto do contexto no estado afetivo**

Estado afetivo	Total Registros	Impacto Local	Impacto Recursos	Impacto Componente	Impacto Estratégia	Impacto Pessoas
Concentração	146	3.42	3.35	3.40	3.66	3.56
Engajamento	107	3.37	3.27	3.46	3.62	3.67
Prazer	42	3.57	3.88	4.07	4.05	3.83
Tédio	111	2.78	2.78	2.98	2.90	2.79
Confusão	39	2.92	2.79	2.74	2.87	3.05
Frustração	27	2.37	2.33	2.63	2.48	3.00

Nota-se, que os estados afetivos considerados positivos como concentração, engajamento e prazer se mantêm acima de 3 em todas as avaliações médias de impacto, ou seja, a percepção de que as informações de contexto são positivas refletem em estados afetivos também positivos. Entretanto quando o estado afetivo informado é negativo, a avaliação média do impacto na maioria dos contextos educacionais também é negativa.

### 4.2.2. Informações do contexto educacional podem ser utilizadas na predição do estado afetivo?

Para a definição dos melhores *features* para o treinamento do modelo foi utilizado o *ExtraTreesClassifier*, um algoritmo de *machine learning* (ML) que faz uso de árvores



de decisão para classificação, permitindo treinar e avaliar modelos. Este algoritmo permite também identificar as melhores *features* em problemas de classificação através da propriedade *feature\_importances\_* que retorna um *array* com a relevância de cada *feature*. A Tabela 4 apresenta os resultados obtidos.

**Tabela 4: Relevância de informações de contexto no modelo**

Features	Relevância	Features	Relevância
Intensity	0.07992087	ImpactR	0.0864644
LearningSpace	0.03523452	Estrategia	0.10459474
ImpactLS	0.08517772	ImpactE	0.11768796
CompCurriculum	0.11218309	ImpactP	0.11870867
ImpactC	0.09569536	Gender	0.04152353
Resourse	0.07998464	Age	0.04282451

A comparação dos resultados mostra quais as variáveis possuem melhores resultados no treinamento do modelo. Destas variáveis, pode-se destacar com maior relevância a informação relacionada ao componente curricular e a avaliação do nível de impacto do componente curricular (*ImpactC*) com 11% e 9% respectivamente, estratégias de aprendizagem utilizadas pelo professor com 10%, impacto das estratégias (*ImpactE*) com 12% e o impacto de outros indivíduos no ambiente (*ImpactP*) também com 12%. Em relação a menor relevância destacam-se o ambiente de aprendizagem (*LearningSpace*) com 3%, gênero (*Gender*) e idade (*Age*) com 4%.

Os resultados mostram que as variáveis analisadas refletem impacto positivo e negativo no estado afetivo. Dessa forma, pode-se considerar que as evidências encontradas na avaliação indicam que as informações do contexto educacional podem ser utilizadas na predição de estados afetivos do estudante.

#### 4.2.3. Históricos de contextos podem ser utilizados para predição de estados afetivos?

Na Tabela 5 são apresentados os resultados das métricas e algoritmos utilizados na avaliação do modelo com base nos históricos de contextos. Os históricos foram formados a partir dos dados coletados durante o experimento considerando as informações de perfil, estado afetivo e contexto educacional. Durante o tratamento dos dados, as variáveis relacionadas aos estados afetivos foram categorizadas de forma binária conforme suas polaridades negativas (0) e positivas (1). O conjunto de dados contendo 472 registros foi dividido percentualmente em 70% para treinamento e 30% para testes. Os dados de teste utilizam o modelo treinado para prever o estado afetivo do aluno a partir das *features* definidas na Tabela 2.

As métricas e valores utilizados para a avaliação foram *accuracy*, *precision*, *recall* e *f1-score*. A *accuracy* mede a proporção de registros classificados corretamente. *Precision* identifica quantas amostras foram classificadas corretamente como estados afetivos positivos (*precision 1*) e negativos (*precision 0*). O *recall* considera as amostras classificadas de forma errada, falsos negativos. O *f1-score* é o balanço entre as métricas *recall* e *precision*.

Os resultados da Tabela 5 apresentam o algoritmo SVC com melhores resultados para acurácia (70%) e *f1-score* positivo (78%). O algoritmo MLPC para acurácia (70%), precisão de estados afetivos positivos (89%), para *recall* negativos (73%) e *f1-score*

positivo (78%). O KNN para precisão de estados afetivos negativos (61%) e *f1-score* negativo (60%). LR para *recall* positivo (71%). Assim, é possível verificar neste cenário, que o algoritmo MLPC reflete com maior precisão a classificação e predição de estados afetivos positivos, enquanto o KNN, resulta em métricas mais precisas quando avaliado a estados afetivos negativos.

**Tabela 5: Métricas e algoritmos utilizados**

Métricas/Algoritmos	KNN	SVC	LR	DT	RF	MLPC
Accuracy	0.64	0.70	0.69	0.64	0.65	0.70
Precision (1)	0.66	0.88	0.82	0.68	0.73	0.89
Precision (0)	0.61	0.45	0.52	0.59	0.53	0.41
Recall (1)	0.69	0.70	0.71	0.70	0.69	0.69
Recall (0)	0.58	0.72	0.67	0.56	0.57	0.73
F1-score (1)	0.68	0.78	0.76	0.69	0.71	0,78
F1-score (0)	0.60	0.55	0.58	0.57	0.55	0.53

A presente questão considerou o uso de históricos de contextos para predição de estados afetivos. Os resultados indicam valores significativos nas métricas de acurácia (70%), precisão de estados afetivos (89%), precisão de estados afetivos negativos (61%), *recall* positivo (71%), *recall* negativo (73%), *f1-score* negativo (60%) e *f1-score* positivo (78%). Na comparação entre os resultados é possível perceber índices mais significativos quando o estado afetivo é positivo. A eficácia do modelo é menor quando avaliados estados afetivos negativos, sendo possível que eventuais diferenças ocorram em função da baixa representatividade amostral. Assim, as evidências encontradas indicam que os históricos de contextos podem ser utilizados na predição de estados afetivos em ambientes educacionais.

## 5. Conclusão

Esse artigo apresentou o Uaffect, um modelo computacional sensível ao contexto para predição de estados afetivos em ambientes educacionais a partir de históricos de contextos. Uma avaliação realizada com 25 estudantes de um curso Técnico Integrado ao Ensino Médio permitiu a coleta e análise de dados relacionados ao perfil, estado afetivo e informações de contexto. As informações foram armazenadas e permitiram a construção de históricos de contextos que foram utilizados para o treinamento do modelo.

A avaliação apresentou evidências significativas da possibilidade de uso de históricos de contextos na classificação e predição de estados afetivos em ambientes educacionais. O modelo pode contribuir na identificação de contextos que favoreçam estados afetivos positivos ou negativos. Essas informações podem ser utilizadas de forma estratégica no desenvolvimento de sistemas inteligentes que auxiliem professores e instituições no planejamento educacional e regulação afetiva do aluno.

Como sugestão de trabalhos futuros está a realização de avaliações com um número maior de alunos e a coleta de dados fisiológicos, permitindo assim a fusão com informações de contexto educacional. Além disso, existe a possibilidade de avaliar a utilização contínua do modelo através dos históricos de contextos, assim como análise de impacto dessas informações no processo de aprendizagem.

## 6. Referências

- Álvarez, P.; Zarazaga-Soria, F. J.; Baldassarri, S. (2020). Mobile music recommendations for runners based on location and emotions: The DJ-Running system, *Pervasive and Mobile Computing*, 67, p. 101242.
- Aranda, J. A. S.; Bavaresco, R.; Carvalho, J. V.; Yamin, A. C.; Tabares, M. T.; Barbosa, J. L. V. (2021). A computational model for adaptive recording of vital signs through context histories. *Journal of Ambient Intelligence and Humanized Computing*, v. 1, p. 1-15.
- Bența, K. I.; Cremene, M.; Gibă, N. R.; Eligio, U. X.; Rarău, A. (2010). Secondary Emotions Deduction from Context, *Innovations and Advances In Computer Sciences and Engineering*. Springer-Verlag Berlin, Heidelberger Platz 3, D-14197 BERLIN, GERMANY, p. 165+.
- Castellano, G.; Leite, I.; Pereira, A.; Martinho, C.; Paiva, A.; Mcowan, P. W. (2010). Inter-ACT: An affective and contextually rich multimodal video corpus for studying interaction with robots, in *MM'10 - Proceedings of the ACM Multimedia 2010 International Conference*, p. 1031–1034.
- Chen, J., Yang, T., Huang, Z., Wang, K., Liu, M., & Lyu, C. (2023). Incorporating structured emotion commonsense knowledge and interpersonal relation into context-aware emotion recognition. *Applied Intelligence*, 53(4), 4201-4217.
- Cosenza, R.; Guerra, L. (2011). *Neurociência e educação*. Artmed Editora
- Dey, A. K. (2001). Understanding and Using Context, *Personal Ubi Comp*, 5(1), p. 4–7.
- D’Mello, S.; Calvo, R. A. (2013). Beyond the basic emotions. *CHI '13 Extended Abstracts on Human Factors in Computing Systems on - CHI EA '13*, p. 2287.
- Dorneles, S. O., Francisco, R., Barbosa, D. N. F., & Barbosa, J. L. V. (2023). Context awareness in recognition of affective states: A systematic mapping of the literature. *International Journal of Human–Computer Interaction*, 39(8), 1563-1581.
- Eich, L. G. et al. (2022). ESMeRA: a computational model to support Experience Sampling Method (ESM) real-time application. In: *XVIII Brazilian Symposium on Information Systems*. p. 1-8.
- Hoang, M. H.; Kim, S. H.; Yang, H. J.; Lee G. S. (2021). Context-Aware Emotion Recognition Based on Visual Relationship Detection. *IEEE Access*, 9, 90465-90474.
- Kuo, Y. C.; Tseng, C. C. (2011). Recognizing the emotion of learners by physiological sensors to improve english learning performance, in *2011 4th International Conference on Biomedical Engineering and Informatics (BMEI)*, v. 4, p. 2152–2156.
- Li, B.; Sano, A. (2020). Extraction and Interpretation of Deep Autoencoder-based Temporal Features from Wearables for Forecasting Personalized Mood, Health, and Stress, *Proc. ACM Interact. Mob. Wearable Ubiquitous Technol*, 4(2), p. 49:1–49:26.
- Martini, B. G.; Helfer, G. A.; Barbosa, J. L. V.; Espinosa Modolo, R. C.; Silva, M. R.; Figueiredo, R. M.; Mendes, A. S.; Leithardt, V. R. Q. (2021). IndoorPlant: A Model for Intelligent Services in Indoor Agriculture Based on Context Histories. *SENSORS*, v. 21, p. 1631.

Moore, P. (2017). Do We Understand the Relationship between Affective Computing, Emotion and Context-Awareness? *Machines*, 5(3), p. 16.

Object-Oriented Architecture SAP: PowerDesigner Documentation Collection. (2018). [https://help.sap.com/doc/c7bcdbf06e1b1014b1fadaaf5f160630/16.6.6/enUS/object\\_oriented\\_modeling.pdf](https://help.sap.com/doc/c7bcdbf06e1b1014b1fadaaf5f160630/16.6.6/enUS/object_oriented_modeling.pdf). Agosto de 2022.

Picard, R. W. (1997). *Affective Computing*. Cambridge: MIT Press.

Santos, O. C.; Saneiro, M.; Boticario, J. G.; Rodriguez-Sanchez, M. C. (2016). Toward interactive context-aware affective educational recommendations in computer-assisted language learning, *New Review of Hypermedia and Multimedia*, 22(1-2), p. 27–57.

Santos, O. C.; Uria-Rivas, R.; Rodriguez-Sanchez, M. C.; Boticario, J. G. (2016). An Open Sensing and Acting Platform for Context-Aware Affective Support in Ambient Intelligent Educational Settings, *IEEE Sensors Journal*, 16(10), p. 3865–3874.

Sarmiento-Calisaya, E., Ccori, P. C., & Parari, A. C. (2022). An emotion-aware persuasive architecture to support challenging classroom situations. In *2022 IEEE International Conference on Consumer Electronics*. p. 1-2.

Satyanarayanan, M. (2001). *Pervasive Computing: Vision and Challenges*. In: *IEEE Personal Communications*, 4(8) p. 10-17.

Scherer, K. R. (2000). Psychological models of emotion. *The neuropsychology of emotion*, v. 137, n. 3, p. 137-162.

Shminan, A. S., & Othman, M. K. (2015). Dynamic student assessment to advocate personalized learning plan. In *2015 International Conference on Information Technology Systems and Innovation* p. 1-6.

Uria-Rivas, R., Rodriguez-Sánchez, M. C., Santos, O. C., Vaquero, J., & Boticario, J. G. (2019). Impact of physiological signals acquisition in the emotional support provided in learning scenarios. *Sensors*, 19(20), 4520.

Wang, Z., Lao, L., Zhang, X., Li, Y., Zhang, T., & Cui, Z. (2022). Context-dependent emotion recognition. *Journal of Visual Communication and Image Representation*, 89, 103679.

Weiser, M. (1991). The Computer for the 21st Century. *Scientific American*. v. 265, n. 3, p.94-104.