

# Classificação de *Gamers* por Padrões em suas Expressões Faciais

Nicolau Calado Jofilsan  
Programa de Pós-Graduação em  
Engenharia de Computação  
Universidade de Pernambuco - UPE  
Recife, Brasil  
ncj@ecom.poli.br

Sidney Marlon Lopes de Lima  
Departamento de Eletrônica e Sistemas  
Universidade Federal de Pernambuco -  
UFPE  
Recife, Brasil  
sidney.lima@ufpe.br

Renan Costa Alencar  
Programa de Pós-Graduação em  
Engenharia de Computação  
Universidade de Pernambuco - UPE  
Recife, Brasil  
rca2@ecom.poli.br

Sthéfano Henrique M. Tavares Silva  
Programa de Pós-Graduação em  
Engenharia de Computação  
Universidade de Pernambuco - UPE  
Recife, Brasil  
shmts@ecom.poli.br

João Victor Oliveira de Albuquerque  
Graduação em Engenharia de  
Computação Universidade de  
Pernambuco - UPE  
Recife, Brasil  
jvoa@ecom.poli.br

Odilon Herculano Soares Filho  
Programa de Pós-Graduação em  
Engenharia de Computação  
Universidade de Pernambuco - UPE  
Recife, Brasil  
ohsf@ecom.poli.br

Alexandre Magno Andrade Maciel  
Programa de Pós-Graduação em  
Engenharia de Computação  
Universidade de Pernambuco - UPE  
Recife, Brasil  
alexandre.maciell@upe.br

Wellington Pinheiro dos Santos  
Programa de Pós-Graduação em  
Engenharia de Computação  
Universidade de Pernambuco - UPE  
Recife, Brasil  
wps@ecom.poli.br

**Resumo**—Este trabalho apresenta como principais contribuições um modelo de mineração dos dados das expressões faciais de jogadores de jogos digitais e o agrupamento desses jogadores por padrões. A base de dados autoral foi gerada utilizando um sistema de visão computacional capaz de auditar reações emocionais contendo um híbrido de sentimentos. As técnicas de mineração utilizadas foram aplicadas nos dados com as variações das 6 emoções básicas felicidade, tristeza, medo, surpresa, raiva e nojo, coletados durante o uso dos jogos, e nos questionários respondidos depois do uso desses mesmos jogos. Após a extração e o tratamento desses dados, foi possível agrupar os jogadores de acordo com padrões em suas expressões faciais e com as respostas dos questionários. Por fim, como forma de visualização de cada grupo de jogadores, os resultados gerados a partir dos centroides, após equalizados de acordo com o histograma dos valores das suas 6 emoções básicas, foram inseridos em um simulador de expressões faciais.

**Palavras-chave**—*Computação Afetiva, Jogos Digitais, Interação Humano Computador, Mineração de Dados, Reconhecimento de Padrões.*

## I. INTRODUÇÃO

A detecção de emoções do usuário é considerada importante elemento da computação afetiva [1], possui diversas aplicações no campo da interação humano-computador, especialmente em pesquisas ligadas a jogos digitais. Com a inserção da computação afetiva, os artefatos digitais são propensos à tomada de decisões de forma criativa e inteligente.

Como método de análise das expressões faciais, geralmente os participantes dos experimentos são instruídos a assistir vídeos com cenas que provocam determinadas emoções, de acordo com o interesse dos pesquisadores. Essas são

circunstâncias artificiais que não retratam as interações naturais de usuários de jogos digitais [2]. A partir da captura da face do participante, utiliza-se análise emocional com base em visão computacional. Daí em diante, os modelos são treinados com emoções rotuladas a partir dessa interatividade limitada. Em detecções não-interativas de emoções, os participantes assumem um papel passivo, com possibilidades limitadas de interação.

Quando a auditoria das emoções é realizada com os usuários interagindo com jogos digitais, geralmente o objetivo é detectar um conjunto muito específico de expressões faciais como as 6 expressões faciais universais<sup>1</sup>. Embora exerça um papel relevante na computação afetiva, a polarização imposta por grande parte dos trabalhos do estado-da-arte limita a detecção de uma única emoção por amostra. Em síntese, trabalhos do estado-da-arte desconsideram a possibilidade de haver reações emocionais contendo um híbrido de sentimentos [2,3]. Isso inclui momentos em que existam emoções aparentemente contraditórias acontecendo simultaneamente.

As técnicas mais comuns utilizadas para obter dados sobre o estado emocional dos jogadores, enquanto jogam, são medidas psicofisiológicas [4]. O processo de mapear sinais psicofisiológicos adquiridos física ou remotamente envolve a identificação dos sinais que melhor predizem os estados emocionais [5], bem como uma definição adequada dos próprios estados emocionais [6].

O sensoriamento psicofisiológico geralmente se dá por sensores físicos que fornecem medição ininterrupta dos sinais fisiológicos do usuário enquanto joga [7-10]. Uma quantidade relevante de informações psicofisiológicas pode ser lida a partir de sinais emitidos pelo corpo humano, como

<sup>1</sup> raiva, nojo, medo, tristeza, surpresa e felicidade.

frequência cardíaca, respiratória e expressões faciais, dentre outros.

A partir da combinação desses sinais é possível inferir sobre o estado emocional do usuário [11,12]. A análise facial com base em sensores físicos (EMG), fornece monitoramento contínuo dos usuários e não é afetada pelas condições de iluminação ou oclusão de pose gerada pelos movimentos do usuário. Como efeito colateral, os sensores podem restringir os movimentos do usuário enquanto joga, um sensor ligado a um dedo impede o uso desse dedo, por exemplo. Como agravante, os sensores são intrusivos e o uso deles aumenta a consciência do usuário de estar sendo monitorado [13-15].

Atualmente, a utilização de uma abordagem de coleta de dados baseada em sensoriamento remoto, para adquirir sinais psicofisiológicos de usuários é mencionada na literatura como uma possível solução para o problema de coleta de dados sobre as expressões faciais dos jogadores. A análise facial é uma abordagem discreta para detecção de emoções dos jogadores [2]. Avanços na visão computacional permitem captura detalhada da atividade facial, tornando a análise automatizada o suficiente para inferir sobre as emoções dos jogadores [16,17]. Assim, expressões faciais detectadas automaticamente têm sido utilizadas no contexto dos jogos, inclusive para correlacionar dimensões da experiência do jogador e para aprimorar esses jogos digitais [18-20].

A análise facial através de métodos visuais utilizando visão computacional, em geral são mais rápidos e fáceis de implantar se comparados aos métodos que utilizam sensores físicos. A utilização da captura remota ajuda na não consciência do usuário de ser monitorado, melhorando a obtenção das informações pela espontaneidade. Como aspecto desfavorável, os resultados são afetados no processo de captura dos sinais corporais [10,11]. Dessa forma, faltam estudos na área que analisem base de dados coletada remotamente e de forma contextualizada.

Consequentemente, os modelos preditivos são baseados em uma perspectiva coletiva. Como um modelo geralmente é treinado a partir de dados de vários usuários, na prática, ele potencialmente descreve o comportamento médio do grupo, sem identificar diferentes perfis dentro desse mesmo grupo. Diante disso, a presente proposta cria um modelo de análise de dados gerados a partir da detecção de emoções de forma não intrusiva e customizada para o usuário no contexto dos estímulos em jogos digitais.

A investigação do repositório de aprendizado estatístico autoral pode gerar informações e *insights* sobre o comportamento do jogador ainda desconhecidos na academia e na indústria. A partir da análise dos dados, o presente estudo prioriza a busca de nuances nas expressões faciais, microexpressões, ao invés de procurar classificar expressões faciais predefinidas, alheias ao contexto do uso de jogos digitais.

Em termos técnicos, essa proposta visa analisar as expressões faciais produzidas pelos jogadores durante o decorrer da partida de modo a criar grupos de jogadores de forma não-supervisionada. Em acréscimo, o sistema desenvolvido é capaz de sensoriar reações emocionais contendo múltiplos sentimentos afetivos. Dessa forma, pretende-se correlacionar dimensões da experiência do jogador e aprimorar os jogos digitais online.

## II. FUNDAMENTAÇÃO TEÓRICA

Nesta seção são apresentados os conceitos utilizados como base teórica deste trabalho.

### A. Teoria do Fluxo (Flow)

Na indústria, a detecção discreta de níveis de estresse e tédio pode ser usada para avaliar jogos, uma vez que essas emoções são componentes chave no ciclo de desafio recompensa, que torna um jogo divertido e engajador [21]. Uma avaliação sobre estresse e tédio, por exemplo, permite que desenvolvedores e editores otimizem seus jogos antes de lançá-los ao mercado, aumentando suas chances de sucesso financeiro. Assim, os desenvolvedores podem explorar novas maneiras de criar jogos que detectam níveis de estresse e tédio sem hardwares ou sensores adicionais, fazendo com que os jogos autoajustem o nível de dificuldade durante o tempo de execução para melhorar a experiência dos jogadores.

Sweetser e Wyeth [22] fizeram uma revisão da literatura sobre a experiência de usuários em jogos para determinar como os elementos do *Flow* se manifestam nos jogos de computadores. Um modelo de satisfação em jogos foi construído a partir da literatura baseado nos elementos do *Flow* e nas evidências da experiência do *Flow* em jogos.

O resultado conseguido foi o modelo *GameFlow*, que consiste em oito elementos principais: concentração, desafio, habilidades, controle, regras claras, *feedback*, imersão e interação social. Cada elemento consiste em um número variável de critérios que se relacionam com os elementos de *Flow* propostos por Csikszentmihalyi, afirmam Sweetser e Wyeth [22]. As descrições sobre a experiência de *Flow* são idênticas ao que os jogadores experimentam quando imersos em jogos, perdendo a noção do tempo e esquecendo pressões externas, juntamente com outros interesses [23].

Um conceito inspirado na teoria de *Flow* é a Zona do *Flow*. Para manter a experiência de *Flow* do usuário, a atividade deve balancear o desafio inerente a essa atividade e a habilidade do jogador para superá-la. Se o desafio está além das habilidades do jogador, a atividade se torna intransponível gerando estresse excessivo. Se o desafio falha em engajar o jogador, ele rapidamente perde o interesse e tende a deixar o jogo. O jogo deve refletir o balanceamento correto entre desafio e habilidade para manter o jogador na Zona do *Flow* [23].

Considerando o contexto do uso de jogos digitais, diferentes jogadores têm diferentes habilidades e esperam diferentes desafios [23]. Alguns jogos propõem problemas mais atraentes para um certo perfil de jogador, já que diversas estruturas criadas a partir de elementos de game design são projetadas para tentar agradar diferentes personalidades. Isso ocorre tanto na forma como os problemas do jogo são apresentados como nas formas que o jogador pode atuar para solucioná-los. Neste caso, quando essas soluções não são devidamente exploradas e aplicadas, o jogo pode se tornar monótono, se considerarmos que quando algo está dando certo o jogador procura não alterar suas ações. Para manter o jogador na Zona de *Flow*, é importante oferecer diversas formas de experiência visando o balanceamento do desafio em relação as habilidades adquiridas [24].

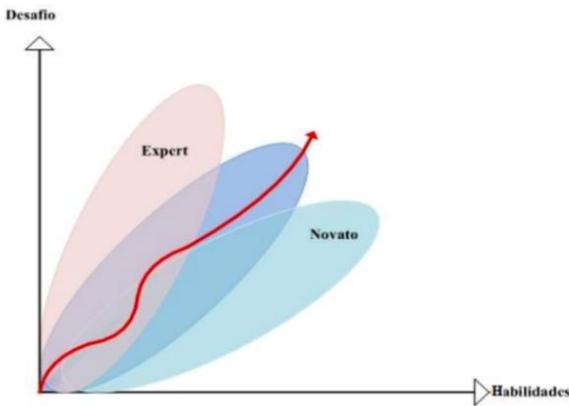


Fig. 1. Zonas de Flow [23].

Muitos jogos oferecem apenas uma experiência simples e estática mantendo apenas o jogador mediano no estado de *Flow*, o que não será divertido para novatos ou experts, conforme ilustra a Fig. 1 [23]. Nesse caso, identificar diferentes perfis de jogadores pode ser de suma importância para projetar experiências interessantes que podem ser oferecidas através dos jogos digitais.

### B. Expressões Faciais dos Jogadores de Jogos Digitais

A análise do comportamento facial comumente se baseia em dados obtidos de sensores físicos como eletromiografia (EMG), ou da aplicação de métodos visuais para avaliar o rosto através de extração de características via visão computacional [25]. A abordagem baseada em dados EMG usa sensores físicos acoplados aos indivíduos para medir a atividade elétrica dos músculos faciais, como o zigomático, o orbicular dos olhos e o músculo corrugador do supercílio. O estudo realizado por Hazlett [26] apresenta evidências de atividade do músculo corrugador mais frequente quando ocorrem eventos positivos nos jogos. Por sua vez, Tijis et al. [10] mostram aumento da atividade do músculo zigomático associado a emoções positivas. Da mesma forma, Ravaja et al. [27] mostram que eventos positivos e gratificantes no jogo estão ligados ao aumento da atividade EMG zigomática e orbicular do olho. As abordagens baseadas em EMG são mais resistentes às variações das condições de iluminação e oclusão facial, no entanto, são intrusivas, uma vez que sensores físicos devem ser fixados ao rosto do participante da pesquisa.

Ao contrário das abordagens baseadas em EMG, intrusivas e obstrutivas, a análise do comportamento facial baseada em métodos visuais automatizados pode ser realizada remotamente e sem contato físico. O processo geralmente envolve detecção do rosto, localização de características faciais, também conhecidas como pontos fiduciais, e classificação de tais informações em expressões faciais [28]. Uma abordagem de classificação comum é baseada nas distâncias e ângulos dos pontos de referência. Samara et al. [29] usam a distância euclidiana entre os pontos da face para treinar um modelo de máquina de vetores suporte (SVM) para detectar expressões. Da mesma forma, Chang et al. [30] usam 12 distâncias calculadas a partir de 14 marcos para detectar medo, amor, alegria e surpresa. Os pesquisadores Hammal et al. [31] usam 5 distâncias faciais calculadas a partir de linhas em regiões chave do rosto, derivadas do padrão de animação MPEG-4 [32], para classificação de expressões. Tang e Huang [33,34] usam até 30 distâncias euclidianas entre os marcos faciais também obtidos a partir de modelos de face 3D baseados em MPEG-

4 para reconhecer as 6 expressões faciais universais. Da mesma forma, Hupont et al. [35] classificam as mesmas emoções usando uma técnica de seleção de características baseada em correlação para selecionar as distâncias e ângulos mais significativos dos pontos faciais. Finalmente Akakn e Sankur [36] usam as trajetórias de marcos faciais para reconhecer gestos de cabeça e expressões faciais.

### C. Trabalhos Relacionados

Alguns métodos visuais contam com análise manual ou automatizada baseada em *Facial Action Coding System* (FACS) como um padrão para categorização e medição de expressões emocionais [37]. Kaiser et al. [38] demonstram que mais *Action Units* (AUs) foram relatadas por codificadores FACS manuais durante a análise de gravações de vídeos de usuários jogando a parte estressante de um jogo, quando comparados à sua parte neutra. Além disso, os autores relatam o canto do lábio e o aumento da sobrancelha como AUs mais frequentes durante as sessões de jogo. Wehrle e Kaiser [39] usam uma análise facial automatizada baseada em FACS agregada com dados de eventos de jogo para fornecer uma análise da avaliação do estado emocional do usuário. Da mesma forma, Grafsgaard et al. [40] usam uma análise automatizada baseada em FACS para relatar uma relação entre a expressão facial e aspectos de envolvimento, frustração e aprendizagem em sessões de tutoria. Ao contrário do trabalho anterior, Heylen et al. [41] não contam com FACS, mas em vez disso, usam uma análise facial empírica e manual com base na interpretação dos autores sobre o contexto. Heylen et al. [41] descobriram que na maioria das vezes os sujeitos permanecem com uma face neutra.

Apesar do FACS ter provado ser uma abordagem útil e quantitativa para medir expressões faciais [37], sua aplicação manual é trabalhosa e demorada e requer profissionais certificados para inspecionar as gravações de vídeo. A aplicação de FACS também possui desvantagens, incluindo a má interpretação de expressões faciais de indivíduos de diferentes culturas e etnias [42]. Nesse caso, a análise facial através de método visual utilizando visão computacional pode ser menos subjetiva se considerarmos sua natureza discreta.

## III. MATERIAIS E MÉTODOS

A base de dados autoral foi constituída à distância, através do experimento disponível no endereço emotiondetect.com.br. A coleta dos dados seguiu a metodologia desenvolvida no trabalho de Bevilacqua [2], que possui foco na coleta presencial, em ambiente controlado. Mesmo tendo realizado a coleta em campo, à distância, a base de dados autoral não apresentou prejuízo significativo na qualidade dos dados adquiridos. A privacidade do usuário também foi garantida, já que suas expressões não foram gravadas em vídeo, apenas as linhas de expressão, formadas por pontos, foram coletadas por meio do sistema de visão computacional `clm-trackr.js` face tracker [43], como mostra a Fig. 2.



Fig. 2. Exemplo das linhas de expressão capturadas pelo sistema de visão computacional clmtrackr.js face tracker [43].

A base de dados autoral foi constituída a partir da detecção das expressões faciais de 232 jogadores durante a interação com três jogos digitais. A abordagem utilizada foi eficiente em detectar as emoções dos jogadores de forma discreta a partir da análise facial desses. O método automatizado de análise utilizou a visão computacional por meio de webcam e a extração das características faciais foi realizada de forma discreta, como mostra a Fig. 2. Esse sistema permite detectar a atividade de um conjunto de músculos faciais como método de aferição das 6 emoções básicas obtidas naturalmente durante os jogos.

O experimento foi realizado com o uso de três jogos digitais customizados, com progressão linear e constante, de um estado enfadonho de tédio a um estressante, sem níveis predefinidos ou condições de parada. Esses jogos foram criados como uma abordagem válida na exploração de comportamentos faciais e sinais fisiológicos, ao considerar sua conexão com os estados emocionais que se deseja capturar.

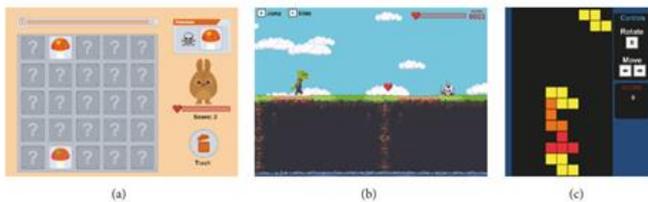


Fig. 3. Jogos utilizados no experimento: a) Cogumelo, b) Plataforma, c) Tetris [2].

O tempo médio da participação no experimento foi de 25 minutos. Durante esse tempo, os participantes jogaram três jogos diferentes na seguinte ordem a) Jogo do cogumelo, onde o jogador deve alimentar o coelho separando os cogumelos bons dos ruins analisando suas cores; b) Jogo estilo plataforma, em que o jogador deve saltar ou deslizar por baixo de obstáculos enquanto coleta corações; c) Tetris, clone da versão clássica do jogo, com a adição das dicas sobre a próxima peça a cair.

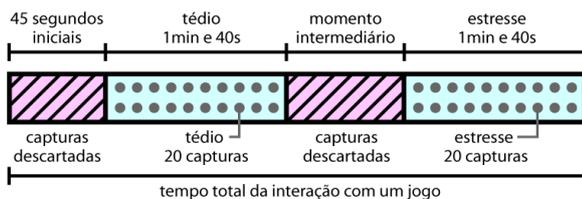


Fig. 4. Critério utilizado na extração inicial dos dados das expressões faciais em momentos de tédio e estresse, adaptado de [2].

Essa extração inicial teve o objetivo de separar os dados que representam os momentos de maior intensidade das reações nas expressões faciais. Em cada um dos 3 jogos jogados pelo participante, 20 persistências dos dados no momento de tédio e 20 no momento de estresse foram extraídas de todo o conjunto de dados. Isso totalizou 60 momentos com a persistência das expressões faciais de um jogador no momento de tédio e 60 no momento de estresse. Essas persistências dos dados gerados pelas capturas aconteceram de 5 em 5 segundos.

Ao final da interação com cada jogo, o participante respondeu um questionário onde expressou em uma escala de 1 a 5 o quão se sentiu entediado ou estressado nos momentos iniciais e finais das jogadas. Nesse questionário, o participante também pôde registrar o momento que mais se divertiu, no início ou no final de cada jogo.

#### A. Modelo de Mineração de Dados das Expressões Faciais

O modelo de mineração dos dados das expressões faciais dos *gamers* proposto neste trabalho, surgiu após análise do contexto e da natureza dos dados armazenados na base.

Em relação à etapa 1, por consistir em um experimento realizado à distância, uma série de vantagens podem ser atribuídas a essa solução como: escalabilidade, facilidade de acesso, dispensar a necessidade de deslocamento e da existência de um ambiente controlado, por exemplo. Mas como em grande parte das soluções de *design*, ao resolver alguns problemas, é comum que outros surjam, como a falta de engajamento na realização de experimentos à distância, obstruções na captura da câmera, distrações, ruídos no ambiente e instabilidade na internet.

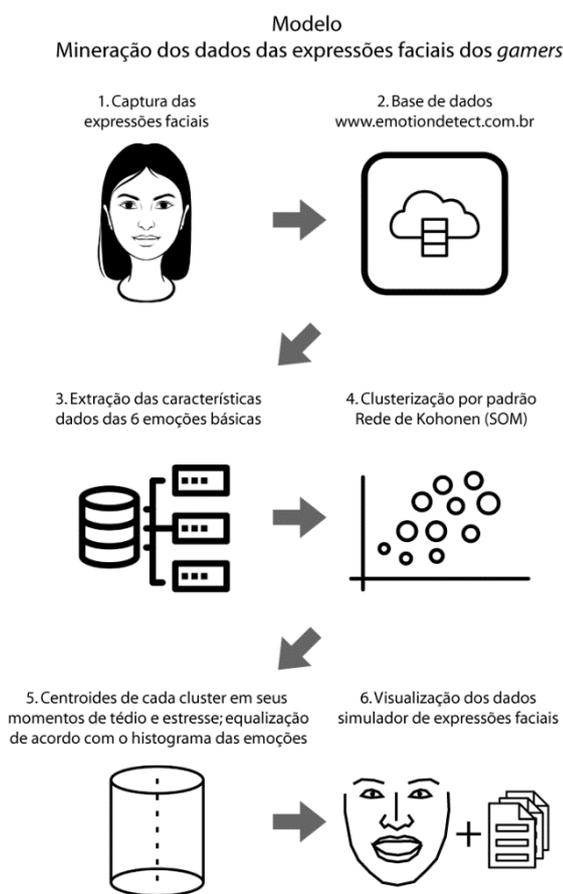
Na etapa 2, como efeito positivo dos experimentos, foi gerada uma base de dados rica ao considerarmos o contexto e a diversidade dos estilos de jogadores que participaram do experimento. Como efeito colateral, a base autoral foi alimentada com conjuntos incompletos de dados em uma quantidade considerável de participações.

Como solução para esse problema das participações incompletas, a etapa 3 teve como objetivo a extração das características de acordo com os critérios definidos para os momentos de tédio e de estresse. Assim, o pré-processamento extraiu os dados de interesse para que fosse possível dar continuidade as próximas etapas. As variações das 6 emoções básicas foram empregadas na criação do repositório de aprendizado estatístico.

Na etapa 4, foi utilizada a clusterização com a rede neural não supervisionada do tipo SOM<sup>2</sup> em seis grupos gerados de acordo com padrões nas expressões faciais. Na etapa 5, houve a geração dos centroides dos dados, equalizados de acordo com o histograma das 6 emoções contidas em cada *cluster*, em seus momentos de tédio e estresse respectivamente.

Finalmente, na etapa 6, os valores dos centroides equalizados foram inseridos em um simulador de expressões faciais para viabilizar a visualização dos dados tratados. Esses resultados foram cruzados com os centroides das respostas dos questionários sobre tédio e estresse respondidos pelos participantes de cada *cluster*. Assim, buscou-se identificar os sentimentos de cada um desses grupos da forma mais aproximada da realidade possível.

<sup>2</sup> SOM: *Self Organizing Map* - Mapa auto-organizável.

Fig. 5. Modelo – Mineração dos dados das expressões faciais dos *gamers*.

### B. Descrição da Base de Dados

A base de dados constitui a leitura de expressões faciais e respostas de questionários durante o uso dos três jogos por 232 jogadores. As diferentes experiências de jogo deram ao repositório uma composição de 68.299 amostras de dados.

Segundo informações fornecidas através dos questionários, os jogadores participantes da pesquisa são de ambos os gêneros e de diferentes idades. Esses dados foram tratados de forma anônima, tendo em vista que todo o processo do experimento foi realizado assíncrona, remotamente e com total isonomia.

A base de dados bruta apresenta inicialmente quatro campos *fk\_game*, *timestamp*, *uuid* e *data* que representam respectivamente a identificação do jogo, o tempo, a identificação do usuário e os dados obtidos durante a captura. O campo *data* apresenta um *array* de JSON com persistência dos dados de 5 em 5 segundos. Cada amostra da nova base de dados, com a abertura do campo *data*, representa o cálculo da distância euclidiana de pontos de referência faciais. Estas variações determinam a probabilidade das seis emoções básicas: raiva, nojo, medo, tristeza, surpresa e felicidade.

Após a expansão do campo *data*, a base passou a possuir 34 variáveis, dentre elas 24 pontos de leituras das distâncias euclidianas indo do ponto 1 (p1) ao ponto 24 (p24). Além das distâncias euclidianas, o banco conta com os campos tempo (*timestamp*), identificação do usuário (*uuid*) e identificação do jogo (*game\_id*) que são compostos por números inteiros e os demais campos são formados por dados do tipo *float*.

### C. Extração das Características - Pré Processamento

Todos os dados de capturas dos eventos foram armazenados como um *array* de objetos JSON dentro do banco de dados no servidor *web*. Para realizar a extração das características e descartar os dados irrelevantes para o estudo, foram desenvolvidos *scripts* de separação de dados. Isso possibilitou além da extração dos dados, a aplicação dos filtros necessários para excluir dados irrelevantes e aplicar as regras definidas no estudo para seleção das amostras válidas.

Os filtros autorais são capazes de identificar jogadores que não movimentaram o mouse ou que não utilizaram o teclado durante as partidas, portanto, que por algum motivo não interagiram com o experimento. Em acréscimo, os filtros propostos conseguem identificar jogadores com participações muito curtas nos jogos, que não alcançaram nem o momento intermediário (Fig. 4.), e ficaram abaixo do desvio padrão da média dos demais. Em síntese, os filtros autorais têm a capacidade de reconhecer e segregar os jogadores que perderam as partidas de maneira proposital.

Por se tratar de dados estruturados não indexados, foi utilizado o algoritmo de árvores binárias de busca, para realizar uma busca incremental e iterativa em todos os elementos do *array* de objetos JSON dentro do campo *data* do banco de dados. Todos os objetos dentro do *array* de JSON possuem a mesma estrutura de dados, o elemento “t” que guarda a fração de milissegundos em que a captura foi realizada, e o elemento “d” que guarda todas as variáveis do evento de captura.

A estratégia de busca em árvores binárias iterativas foi escolhida porque para realizar a leitura dos registros do banco de dados é necessário fazer a varredura em todo *array* de objetos JSON e verificar cada elemento e o seu respectivo valor. Tal estratégia possibilita que o *script* de extração consiga classificar esses dados como dado válido para o estudo. Por exemplo, as distâncias euclidianas entre as expressões faciais constituíram dados úteis para o processo de aferição dos perfis emocionais dos jogadores. Por outro lado, as capturas de eventos de pressionamento de botões do teclado ou movimento do mouse, não foram utilizados para aferição dos estados emocionais dos jogadores. Os referidos eventos de mouse e teclado serviram para a construção dos filtros na expectativa de auditar se o jogador perdeu a partida propositalmente ou se houve algum problema em meio a sua participação. Quando o *script* termina a classificação e indexa todos os dados relevantes, é realizada a inclusão desses dados como resultado do experimento do jogador, e em qual jogo a captura foi realizada.

### D. Clusterização

A literatura aponta para a existência de grupos de usuários com respostas emotivas distintas entre si. Por exemplo, os nativos digitais processam diferentes informações de forma muito rápida e paralela, o que implica em reações contendo múltiplas emoções, por outro lado os imigrantes digitais costumeiramente são despreparados para lidar com essas multidimensões [44]. Assim, entende-se como investigação relevante analisar as expressões faciais produzidas por diferentes jogadores durante o uso de jogos digitais de modo a criar agrupá-los por padrões de forma não-supervisionada.

A Clusterização proposta adota a rede neural do tipo SOM. As ligações sinápticas, ou ajuste de pesos, da rede SOM são baseadas no aprendizado competitivo. O neurônio

vencedor é aquele que alcançar menor distância euclidiana à resposta obtida pela rede neural, também responsável por organizar automaticamente os dados topologicamente.

Uma das principais vantagens oferecidas pela clusterização é o fornecimento de uma melhor representação dos dados, pois os objetos em um *cluster* têm menos variabilidade em seus atributos e podem ser resumidos com eficiência [45]. Em acréscimo, a clusterização foi empregada como mineração de dados visando a segregação de jogadores que apresentaram algum problema na captura dos dados sobre suas expressões faciais durante o experimento.

#### IV. RESULTADOS

Após o pré-processamento, foi utilizada a estratégia de busca em árvores binárias iterativas. Dessa forma, os dados passaram de uma organização em vetores com diferentes tipos de dados agrupados, para um repositório onde as colunas representavam os neurônios de entrada da rede neural e as linhas seu momento de persistência no tempo. Após esse pré-processamento, das 232 participações registradas, apenas 107 mostraram-se válidas de acordo com a metodologia e as técnicas de mineração adotadas.

Esse tratamento simplificou a extração dos dados com as variações das 6 emoções básicas dos jogadores nos momentos de tédio e estresse. Assim, de posse dos dados com as variações das emoções, que foram extraídos das tabelas, deu-se início ao processo de clusterização utilizando a rede não supervisionada SOM.

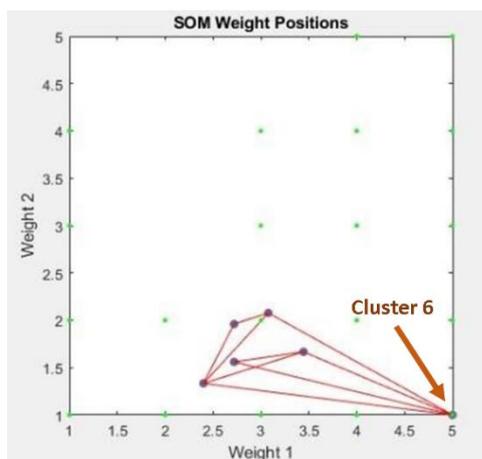


Fig. 6. Resultado da clusterização em 6 grupos por padrões nas expressões faciais – *cluster 6*, agrupamento dos participantes que apresentaram problemas na realização do experimento.

Assim, além de separar os conjuntos de expressões faciais por padrões, a rede neural realizou mineração não convencional separando os jogadores que apresentaram problemas para completar sua participação no experimento agrupando-os no *cluster 6*. Esse *cluster* recebeu as participações com excessivos zeros e nulos nas variações das emoções no decorrer do tempo.

A nulidade dos atributos de entrada pode ter ocorrido por distintos fatores, visto que os experimentos foram realizados em ambientes não controlados, em campo. Algumas hipóteses são a retirada do rosto do enquadramento da webcam, clarão ou escuridão temporária alterando a luminosidade do

ambiente, a webcam ter falhado temporariamente durante o experimento ou ainda a possível queda repentina da conexão com a internet. Ao final, a base de dados autoral emprega 36.264 amostras de tédio e outras 32.035 amostras de estresse produzidas por 107 participantes.

#### A. Normalização e Centroides

Os valores das emoções gerados pelo sistema de visão computacional originalmente variaram entre 0 e 1. A partir da geração desses dados foi iniciada a análise dos *clusters* válidos. Foi considerado que nesse contexto os resultados naturalmente teriam valores baixos por se tratar de microexpressões. Em busca de melhor compreensão sobre o comportamento de cada um desses 5 grupos de jogadores, foi calculado um centroide para cada uma das seis emoções em seus respectivos momentos de tédio e de estresse. Os resultados gerados com esses cálculos apresentaram valores muito baixos. Esses valores então foram normalizados para possibilitar uma melhor análise. Para tanto, foram utilizados os intervalos do simulador de expressões<sup>3</sup> que possui valores entre 0 e 2000 em seu campo positivo, Tabelas I e II.

Os valores entre 0 e 1 foram considerados para o uso nos casos em que os projetistas poderiam submetê-los a sistemas baseados em aprendizado de máquina, que utilizassem redes neurais, por exemplo. Nesse caso, o objetivo poderia ser promover automação em seus jogos com base nos perfis de jogadores. Eventos poderiam ser disparados ou mudanças no comportamento do jogo poderiam acontecer de acordo com a alteração dos valores discretos das expressões faciais dos jogadores enquanto estivessem interagindo com os jogos.

Um outro caso seria proporcionar aos designers informações sobre os diferentes perfis de jogadores, de acordo com a visualização das suas expressões faciais após a realização de testes com os jogos. Acredita-se que essas informações poderiam auxiliar no processo de tomada de decisão projetual. Nesse caso, como se trata de microexpressões, mesmo após a normalização entre 0 e 2000, as expressões geradas pelo simulador utilizando esses valores ficaram quase imperceptíveis. Como solução, foi utilizada a estratégia de equalização dos centroides de acordo com o histograma das emoções, para que as diferenças entre as expressões dos grupos de jogadores se destacassem e sua visualização se tornasse possível.

TABELA I. CENTROIDES DAS 6 EMOÇÕES BÁSICAS NO MOMENTO CLASSIFICADO COMO TÉDIO

Momento tédio - Centroides das 6 emoções básicas normalizados de 0 a 2000						
Cluster	Raiva	Nojo	Medo	Tristeza	Surpresa	Felicidade
1	290.17	305.82	117.09	470.84	310.14	432.73
2	607.52	659.03	237.95	344.23	355.31	629.86
3	286.02	307.1	113.2	385.61	263.19	361.05
4	205.78	220.45	222.58	486.02	476.61	441.02
5	273.52	266.75	136.83	566.54	326.43	442.73

<sup>3</sup> Simulador de emoções. Disponível em <https://emotiondetect.com.br/js/3rdparty/clmtrackr/examples/classviewer.html>. Acesso em junho de 2021.

A Tabela I mostra os valores dos centroides de cada emoção dos 5 *clusters* no momento tédio. A Tabela II apresenta os centroides gerados a partir dos valores das emoções dos 5 *clusters* no momento classificado como estresse.

TABELA II. CENTROIDES DAS 6 EMOÇÕES BÁSICAS NO MOMENTO CLASSIFICADO COMO ESTRESSE

Momento estresse - Centroides das 6 emoções básicas normalizados de 0 a 2000

Cluster	Raiva	Nojo	Medo	Tristeza	Surpresa	Felicidade
1	342.02	356.32	146.59	477.39	277.22	409.26
2	556.2	419.33	487.83	376.65	344.55	668.97
3	332.59	297.02	121.27	304.79	212.5	400.84
4	217.76	283.15	211.44	467.63	495.81	414.31
5	396.85	377.83	118.43	466.7	275.03	424.19

A Tabela III contém os valores dos centroides das respostas dos questionários sobre os sentimentos dos jogadores quanto aos seus níveis de tédio e estresse, no início e final dos jogos. Nesse questionário o jogador também expressou seu momento de maior divertimento. Nos dois casos a escala utilizada variou de 1 a 5, onde duas perguntas solicitaram o nível de tédio e estresse do jogador no início do jogo e outras duas perguntas o nível de tédio e estresse no final do jogo. A última pergunta solicitou que o jogador escolhesse o momento que mais se divertiu dentre as seguintes alternativas: 1. logo no início do jogo; 2. depois do início e antes do meio; 3. no meio do jogo 4. depois do meio e antes do fim; 5. no fim do jogo.

TABELA III. CENTROIDES DAS RESPOSTAS DO QUESTIONÁRIO SOBRE SENTIMENTOS DE TÉDIO, ESTRESSE E DIVERSÃO - ESCALA DE 1 A 5

Cluster	Início dos Jogos		Finais dos Jogos		Divertimento
	Tédio	Estresse	Tédio	Estresse	
1	2,68	1,53	1,84	3,57	3,48
2	4,00	1,67	1,00	4,00	2,67
3	3,00	2,04	2,13	2,43	3,26
4	3,17	1,97	2,72	3,21	3,28
5	2,81	1,76	2,36	3,50	2,98

Segundo os resultados da Tabela III, os jogadores dos *clusters* 1, 3 e 4 tiveram seus momentos de maior divertimento após o meio e antes do final do jogo. Momento um pouco mais estressante onde os jogos começaram a apresentar mais dificuldade. Enquanto os jogadores dos *clusters* 2 e 5 acharam mais divertido depois do início e antes do meio de cada jogo. Momento menos estressante quando os jogos apresentaram dificuldade reduzida.

Sobre as variações entre tédio e estresse no decorrer do tempo, os destaques vão para os *clusters* 2 e 3. O *cluster* 2 obteve a maior variação entre os valores de tédio decrescente

e estresse crescente. Enquanto o *cluster* 3 quase não apresentou variação nos valores de estresse no decorrer das jogadas.

Ainda segundo os mesmos resultados da Tabela III, todos os *clusters* apresentaram, em menor ou maior variação, diminuição do tédio e aumento do estresse no decorrer das interações com os jogos. Esta foi condição essencial para a validação deste experimento, que pretendeu analisar as variações dos sentimentos dos jogadores nos momentos de tédio e estresse em meio ao uso de jogos digitais.

### B. Visualização dos Dados

Os valores dos centroides foram inseridos no simulador facial após serem equalizados de acordo com o histograma das emoções contidas em cada *cluster*. Assim, foi possível gerar visualizações das expressões com destaque entre os diferentes perfis e inferir sobre seus comportamentos.

A estratégia de equalização baseada no histograma é inspirada em processamento de imagens biomédicas. Apesar dos modernos dispositivos de imagens proverem excepcionais resoluções da anatomia interna, a análise é limitada a olho humano. Logo, uma das providências das ferramentas de suporte à decisão médica diz respeito a aumentar o contraste das imagens baseado na equalização do histograma. De tal modo que se torna mais viável um profissional especialista conseguir identificar visualmente uma possível anomalia anatômica [46].

Ao se traçar um paralelo com as reações emocionais, os novos valores foram gerados a partir da soma da probabilidade da soma da ocorrência do nível de intensidade da emoção. A expansão do contraste tem como propósito redistribuir os centroides das emoções, de modo a elevar o contraste na faixa de níveis disponíveis no simulador utilizado.

O *cluster* 1 apresentou maiores valores nas emoções tristeza e felicidade. Seu comportamento demonstra aumento da raiva, do nojo, do medo e da tristeza, e a diminuição da surpresa e da felicidade no decorrer do tempo. Esse perfil de jogador possui valores maiores das emoções surpresa e felicidade enquanto se encontra nos momentos iniciais dos jogos, e tristeza nos momentos finais. Em contraponto a essas emoções, de acordo com a Tabela III, os jogadores deste *cluster* obtiveram o valor sobre o momento de maior divertimento mais próximo das fases finais dos jogos, as mais difíceis. Esse *cluster* agrupou a maioria dos jogadores, isso significa que esse perfil representa o padrão mais comum entre os participantes deste experimento.

Em geral, o *cluster* 2 possuiu os valores mais altos nas emoções felicidade, nojo e raiva. Seu comportamento apresenta diminuição da raiva, do nojo e da surpresa, e o aumento do medo, da tristeza e da felicidade com o passar do tempo. Esse perfil de jogador possui os valores mais altos na emoção felicidade enquanto se encontra no momento estresse, e nojo enquanto está no momento tédio. Em contraponto a essas emoções, de acordo com os resultados dos questionários, esse perfil possui seu momento de maior divertimento nas fases mais próximas do início dos jogos, nos momentos mais fáceis. Esse *cluster* agrupou a menor quantidade de jogadores participantes deste experimento. Isso pode significar que a criação deste *cluster* se justifica por possuir padrões que se destacam, por representar um conjunto de expressões diferentes ao ponto de não se encaixar em nenhum outro *cluster*.

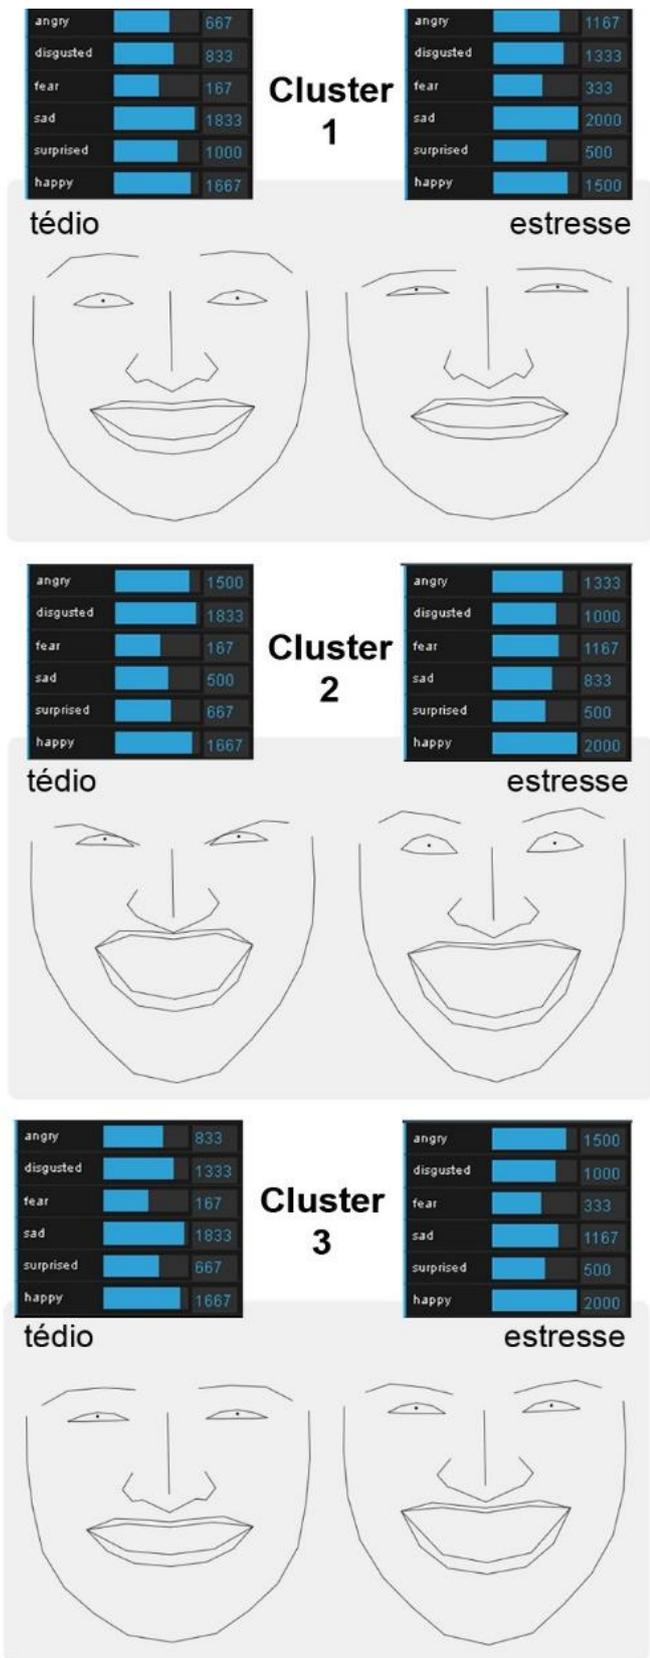


Fig. 7. Simulador de expressões faciais – centroides equalizados dos clusters 1, 2 e 3 nos momentos de tédio e estresse.

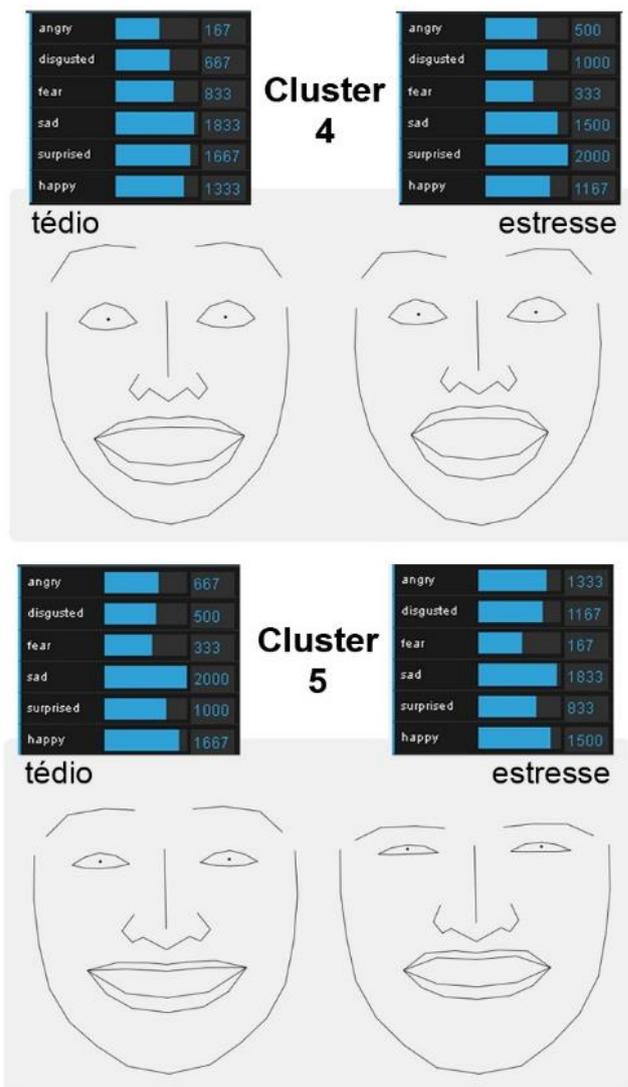


Fig. 8. Simulador de expressões faciais – centroides equalizados dos clusters 4 e 5 nos momentos de tédio e estresse.

O cluster 3 possui o valor da emoção tristeza como o mais alto no momento tédio e das emoções raiva e felicidade como ao mais altos no momento estresse. As emoções nojo, medo e surpresa diminuem no decorrer do tempo, enquanto as emoções raiva, tristeza e felicidade aumentaram. Aparentemente alinhados a evolução das emoções desse grupo de jogadores, os questionários mostraram que esse perfil parece se divertir mais, um pouco depois do meio do jogo e antes do seu final.

No caso do cluster 4, suas emoções com maior valor são tristeza no momento tédio e surpresa no momento estresse. É possível perceber a diminuição da felicidade, tristeza e medo, e o aumento das emoções raiva, nojo e surpresa no decorrer do tempo. Esse perfil de jogador parece se divertir mais, depois do meio e antes do fim do jogo, enquanto sua tristeza e medo diminuem, e sua surpresa aumenta.

Finalmente, o cluster 5 apresenta como valor mais alto tristeza no momento tédio. No decorrer do tempo, medo, tristeza, surpresa e felicidade diminuíram e as emoções raiva e nojo aumentaram. Esse perfil de jogador parece se divertir mais depois do início e antes do meio do jogo, enquanto sua tristeza diminui e sua raiva aumenta.

## V. CONCLUSÃO

O sistema autoral estabeleceu um modo de captura não obstrutivo, de forma remota e assíncrona, sem a utilização de sensores físicos, o que pode gerar interrupções na coleta dos dados e ruídos, já que a webcam precisa estar adequadamente posicionada, com iluminação suficiente e devidamente conectada à Internet. Como aspecto favorável, os resultados obtidos poderão contribuir para uma melhor compreensão sobre os grupos de jogadores e fornecer uma base para o desenvolvimento e aprimoramento de jogos digitais online.

Este estudo se propôs a realizar investigação na base de dados autoral constituída através de experimento realizado em campo, à distância. As tecnologias e métodos utilizados refletem o estado-da-arte na área do estudo das expressões faciais e comportamento dos jogadores de jogos digitais. Através das técnicas de mineração de dados foi possível desvendar 5 (cinco) perfis de jogadores distintos por meio da análise de suas microexpressões, e ainda isolar um conjunto considerável de dados inválidos.

Os 5 (cinco) perfis de jogadores foram estabelecidos através do emprego das redes neurais artificiais. Uma das principais vantagens oferecidas pela clusterização de jogadores foi o fornecimento de uma melhor representação dos dados. Os objetos em um *cluster* têm menos variabilidade em seus atributos e podem ser resumidos com eficiência. Em acréscimo, a clusterização foi empregada como mineração de dados visando a segregação de jogadores que apresentaram algum problema na captura dos dados das suas expressões faciais durante o experimento. Dessa forma, buscou-se correlacionar dimensões da experiência do jogador com o intuito de aprimorar os jogos digitais.

Acredita-se que a detecção das reações emocionais em momentos de tédio e de estresse pode colaborar para o desenvolvimento de jogos *indies*. Uma justificativa seria a inviabilidade de remuneração de jogadores visando auditar suas reações emocionais mediante a interação com jogos *indies*, principalmente em um país emergente como o Brasil. Através da metodologia apresentada neste trabalho, o reconhecimento emocional do jogador pode ocorrer à distância e de forma assíncrona. Como tratamento dos dados, a regressão estatística pode ser empregada utilizando os centroides dos momentos de tédio e de estresse como projeções desejadas. Dessa forma, este trabalho tem capacidade de mitigar os custos financeiros necessários às fases de desenvolvimento e de teste dos jogos independentes.

É importante destacar que grande parte dos jogos *indies* é desenvolvido sem a presença de programadores na equipe de projetistas. Existe uma série de *game engines* com modelos de negócio acessíveis disponíveis, capazes de auxiliar em vários aspectos no processo de desenvolvimento dos jogos digitais. Como aspecto negativo, torna-se inviável embarcar um sistema de visão computacional nessas *game engines* almejando o reconhecimento das expressões faciais como foi feito no experimento aqui apresentado. Como alternativa, foi proposto um modelo que pode ser reproduzido em diferentes contextos que envolvam o uso de jogos digitais com o objetivo de gerar informações relevantes sobre as reações emocionais dos jogadores para a equipe de projetistas. As expressões faciais dos diferentes perfis gerados neste experimento também podem servir para comparações entre futuros perfis gerados a partir de condições distintas no uso de jogos digitais.

Em acréscimo, por se tratar de uma ferramenta de auxílio ao projeto de jogos digitais, a detecção de emoções proposta possibilita que os desenvolvedores explorem um público-alvo mediante a clusterização apresentada. Entendemos que, torna-se inviável um jogo *indie* se propor a alcançar todo e qualquer tipo de jogador de maneira universal. É mais prudente que a equipe *indie* escolha um público-alvo e trabalhe tanto a sua satisfação quanto sua fidelidade. O presente sistema de detecção de reações emocionais possibilita inferir qual público-alvo a equipe de projetistas deve focar em função das características empreendidas pelo jogo. Como trabalhos futuros pretende-se continuar a investigação sobre os dados desta base, que se transforma e aumenta periodicamente.

## AGRADECIMENTOS

Os autores agradecem o fomento financeiro da Fundação de Amparo à Ciência e Tecnologia do Estado de Pernambuco (FACEPE), instituição vinculada à Secretaria de Ciência, Tecnologia e Inovação (SECTI). Os autores também gostariam de prestar os devidos agradecimentos ao corpo docente e coordenação do Programa de Pós-Graduação em Engenharia de Computação da Universidade de Pernambuco (PPGEC UPE).

## REFERÊNCIAS

- [1] R. W. Picard, "Affective Computing," MIT Press: Cambridge, MA, USA, 2000.
- [2] F. Bevilacqua, H. Engström, P. Backlund, "Game-calibrated and user-tailored remote detection of stress and boredom in games," *Sensors* (Switzerland), vol. 19, no. 13, Jul. 2019, doi: 10.3390/s19132877.
- [3] A. Dzedzickis, A. Kaklauskas, V. Bucinkas, "Human Emotion Recognition: Review of Sensors and Methods," *Sensors*. 2020; 20(3):592. <https://doi.org/10.3390/s20030592>
- [4] E. D. Mekler, J. A. Bopp, A. N. Tuch, K. Opwis, "A systematic review of quantitative studies on the enjoyment of digital entertainment games," in *Proceedings of the 32nd Annual ACM Conference on Human Factors in Computing Systems, CHI 2014*, pp. 927–936, May 2014.
- [5] S. Jerritta, M. Murugappan, R. Nagarajan, K. Wan, "Physiological signals based human emotion Recognition: A review," in *Proceedings of the 2011 IEEE 7th International Colloquium on Signal Processing and its Applications, Penang, Malaysia, 4–6 March 2011*; Institute of Electrical and Electronics Engineers (IEEE): Piscataway Township, NJ, USA, 2011; pp. 410–415.
- [6] R. L. Mandryk, M. S. Atkins, K. M. Inkpen, "A continuous and objective evaluation of emotional experience with interactive play environments," in *Proceedings of the SIGCHI conference on Human Factors in computing systems, Montréal, QC, Canada, 22–27 April 2006*; ACM: New York, NY, USA, 2006; pp. 1027–1036.
- [7] F. Bousefsaf, C. Maaoui, A. Pruski, "Remote assessment of the Heart Rate Variability to detect mental stress," in *Proceedings of the 2013 7th International Conference on Pervasive Computing Technologies for Healthcare and Workshops, Venice, Italy, 5–8 May 2013*; pp. 348–351.
- [8] C. Yun, D. Shastri, I. Pavlidis, Z. Deng, "O'game, can you feel my frustration?," in *Proceedings of the 27th International Conference on Human Factors in Computing Systems—CHI 09, Boston, MA, USA, 4–9 April 2009*; Association for Computing Machinery (ACM): New York, NY, USA, 2009; pp. 2195–2204.
- [9] P. Rani, C. Liu, N. Sarkar, E. Vanman, "An empirical study of machine learning techniques for affect recognition in human–robot interaction," *Pattern Anal. Appl.* 2006, 9, 58–69.
- [10] T.J.W. Tijs, D. Brokken, W.A. IJsselstein, "Dynamic game balancing by recognizing affect," in *Fun and Games*, vol. 5294 of *Lecture Notes in Computer Science*, pp. 88–93, Springer, Berlin, Germany, 2008.
- [11] D. Kukolja, S. Popović, M. Horvat, B. Kovač, K. Čosić, "Comparative analysis of emotion estimation methods based on

- physiological measurements for real-time applications,” *Int. J. Hum. Comput. Stud.* 2014, 72, 717–727.
- [12] H. Zacharatos, C. Gatzoulis, Y. L. Chrysanthou, “Automatic emotion recognition based on body movement analysis: A survey,” *IEEE Computer Graphics and Applications*, vol. 34, no. 6, article no. 106, pp. 35–45, 2014.
- [13] T. Yamakoshi, K. Yamakoshi, S. Tanaka et al., “A preliminary study on driver’s stress index using a new method based on differential skin temperature measurement,” in *Proceedings of the 29th Annual International Conference of IEEE-EMBS, Engineering in Medicine and Biology Society, EMBC’07*, pp. 722–725, August 2007.
- [14] M. Yamaguchi, J. Wakasugi, J. Sakakima, “Evaluation of driver stress using biomarker in motor-vehicle driving simulator,” in *Proceedings of the Conference Proceedings. Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 1834–1837, New York, NY, August 2006.
- [15] J. A. Healey, R. W. Picard, “Detecting stress during real-world driving tasks using physiological sensors,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 6, no. 2, pp. 156–166, 2005.
- [16] J. F. Cohn, F. De la Torre, “Automated Face Analysis for Affective,” *The Oxford handbook of affective computing*, 2014.
- [17] C. T. Tan, S. Bakkes, Y. Pisan, “Inferring player experiences using facial expressions analysis,” in *Proceedings of the 10th Australian Conference on Interactive Entertainment, IE 2014*, pp. 1–8, ACM Press, December 2014.
- [18] C. T. Tan, S. Bakkes, Y. Pisan, “Correlation between facial expressions and the game experience questionnaire,” in *Proceedings of the Entertainment Computing-ICEC 2014: 13th International Conference*, vol. 8770, p. 229, Springer, Sydney, Australia, October 2014.
- [19] X. Zhou, X. Huang, Y. Wang, “Real-time facial expression recognition in the interactive game based on embedded hidden markov model,” in *Proceedings of the Computer Graphics, Imaging and Visualization*, pp. 144–148, Penang, Malaysia, 2004.
- [20] C. Zhan, W. Li, P. Ogunbona, F. Safaei, “A real-time facial expression recognition system for online games,” *International Journal of Computer Games Technology*, vol. 2008, pp. 1–7, 2008.
- [21] J. Schell, “The Art of Game Design: A book of Lenses,” CRC Press: Boca Raton, FL, USA, 2014.
- [22] P. Sweetser, P. Wyeth, “GameFlow: a model for evaluating player enjoyment in games,” *Comput. Entertain.* 2005. DOI=10.1145/1077246.1077253. Disponivel em: <<http://doi.acm.org/10.1145/1077246.1077253>> Acesso em 03/05/2021.
- [23] J. Chen, “Flow in games (and everything else),” *Commun. ACM*, p. 31-34, 2007.
- [24] R. Koster, “The Theory of Fun for Game Design,” 2a. ed. O’Reilly Media, p. 300, 2013.
- [25] C. Schrader, J. Brich, J. Frommel, V. Riemer, K. Rogers, “Rising to the challenge: an emotion-driven approach toward adaptive serious games,” in *Serious Games and Edutainment Applications*, pp. 3–28, Springer, 2017.
- [26] R. L. Hazlett, “Measuring emotional valence during interactive experiences: boys at video game play,” in *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, pp. 1023–1026, 2006.
- [27] N. Ravaja, T. Saari, M. Salminen, J. Laarni, K. Kallinen, “Phasic emotional reactions to video game events: a psychophysiological investigation,” *Media Psychology*, vol. 8, no. 4, pp. 343–367, 2006.
- [28] A. A. Salah, N. Sebe, T. Gevers, “Communication and automatic interpretation of affect from facial expressions,” *Affective Computing and Interaction: Psychological, Cognitive and Neuroscientific Perspectives*, pp. 157–183, 2010.
- [29] A. Samara, L. Galway, R. Bond, H. Wang, “Sensing affective states using facial expression analysis,” in *Ubiquitous Computing and Ambient Intelligence, Lecture Notes in Computer Science*, pp. 341–352, Springer International Publishing, 2016.
- [30] C. Y. Chang, J. S. Tsai, C. J. Wang, P. C. Chung, “Emotion recognition with consideration of facial expression and physiological signals,” in *Proceedings of the 2009 IEEE Symposium on Computational Intelligence in Bioinformatics and Computational Biology, CIBCB 2009*, pp. 278–283, April 2009.
- [31] Z. Hammal, L. Couvreur, A. Caplier, and M. Rombaut, “Facial expression classification: An approach based on the fusion of facial deformations using the transferable belief model,” *International Journal of Approximate Reasoning*, vol. 46, no. 3, pp. 542–567, 2007.
- [32] G. A. Abrantes, F. Pereira, “MPEG-4 facial animation technology: survey, implementation, and results,” *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 9, no. 2, pp. 290–305, 1999.
- [33] H. Tang, T. S. Huang, “3D Facial expression recognition based on automatically selected features,” in *Proceedings of the 2008 IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops, CVPR Workshops*, pp. 1–8, June 2008.
- [34] H. Tang, T. S. Huang, “3d facial expression recognition based on properties of line segments connecting facial feature points,” in *Proceedings of the Automatic Face & Gesture Recognition, 8th IEEE International Conference on IEEE*, pp. 1–6, 2008.
- [35] I. Hupont, S. Baldassarri, E. Cerezo, “Facial emotional classification: from a discrete perspective to a continuous emotional space,” *PAA. Pattern Analysis and Applications*, vol. 16, no. 1, pp. 41–54, 2013.
- [36] H. Ç. Akakn, B. Sankur, “Spatiotemporal-boosted DCT features for head and face gesture analysis,” in *Human Behavior Understanding*, pp. 64–74, Springer Nature, 2010.
- [37] M. S. Bartlett, J. C. Hager, P. Ekman, T. J. Sejnowski, “Measuring facial expressions by computer image analysis,” *Psychophysiology*, vol. 36, no. 2, pp. 253–263, 1999.
- [38] S. Kaiser, T. Wehrle, P. Edwards, “Multi-modal emotion measurement in an interactive computer game: A pilot-study,” in *Proceedings of the VIII conference of the international society for research on emotions*, pp. 275–279, ISRE Publications Storrs, 1994.
- [39] T. Wehrle, S. Kaiser, “Emotion and facial expression,” in *Affective Interactions*, vol. 1814 of *Lecture Notes in Computer Science*, pp. 49–63, Springer, Berlin, Germany, 2000.
- [40] J. F. Grafsgaard, J. B. Wiggins, K. E. Boyer, E. N. Wiebe, J. C. Lester, “Automatically recognizing facial expression: Predicting engagement and frustration,” in *EDM*, pp. 43–50, 2013.
- [41] D. Heylen, M. Ghijssen, A. Nijholt, R. Op Den Akker, “Facial signs of affect during tutoring sessions,” *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics): Preface*, vol. 3784, pp. 24–31, 2005.
- [42] R. E. Jack, “Culture and facial expressions of emotion,” *Visual Cognition*, vol. 21, no. 9-10, pp. 1248–1286, 2013.
- [43] J. M. Saragih, S. Lucey, J. F. Cohn, “Deformable model fitting by regularized landmark mean-shift,” *Int J Comput Vis* 91(2):200–215. 2011. Disponivel em: <https://dl.acm.org/doi/10.1007/s11263-010-0380-4>. Acesso em: 27 abr. 2021 às 14hs50min.
- [44] M. Prensky, “Digital Natives, Digital Immigrants,” *On the Horizon*, Vol. 9 No. 5, pp. 1-6. <https://doi.org/10.1108/10748120110424816>, 2001.
- [45] P. Nerurkar, et al. “Empirical Analysis of Data Clustering Algorithms,” *Procedia Computer Science*. Volume 125, Pages 770-779. doi: <https://doi.org/10.1016/j.procs.2017.12.099>, 2018.
- [46] S. M. L. Lima, A. G. Silva-Filho, W. P. Santos, “Morphological Decomposition to Detect and Classify Lesions in Mammograms,” In: Wellington Pinheiro dos Santos; Maíra Araújo de Santana; Washington Wagner Azevedo da Silva. (Org.). *Understanding a Cancer Diagnosis*, New York: Nova Science. <https://novapublishers.com/shop/understanding-a-cancer-diagnosis/>, 2020 a.