

UNIVERSIDADE FEDERAL DO PARANÁ

WELLTON COSTA DE OLIVEIRA

UM ESTUDO NO USO DE *FEEDBACKS* PARA MUDANÇAS DE ESTADOS AFETIVOS DO  
ESTUDANTE USANDO ELETROENCEFALOGRAMA E EXPRESSÕES FACIAIS

CURITIBA PR

2022

WELLTON COSTA DE OLIVEIRA

UM ESTUDO NO USO DE *FEEDBACKS* PARA MUDANÇAS DE ESTADOS AFETIVOS DO  
ESTUDANTE USANDO ELETROENCEFALOGRAMA E EXPRESSÕES FACIAIS

Tese apresentada como requisito parcial à obtenção do grau de Doutor em Ciência da Computação no Programa de Pós-Graduação em Informática, Setor de Ciências Exatas, da Universidade Federal do Paraná.

Área de concentração: *Ciência da Computação*.

Orientador: Prof. Dr. Andrey Ricardo Pimentel.

Coorientador: Prof. Dr. Ernani Gottardo.

CURITIBA PR

2022

DADOS INTERNACIONAIS DE CATALOGAÇÃO NA PUBLICAÇÃO (CIP)  
UNIVERSIDADE FEDERAL DO PARANÁ  
SISTEMA DE BIBLIOTECAS – BIBLIOTECA DE CIÊNCIA E TECNOLOGIA

Oliveira, Wellton Costa de

Um estudo no uso de feedbacks para mudanças de estados afetivos do estudante usando eletroencefalograma e expressões faciais / Wellton Costa de Oliveira. – Curitiba, 2022.

1 recurso on-line : PDF.

Tese (Doutorado) - Universidade Federal do Paraná, Setor de Ciências Exatas, Programa de Pós-Graduação em Informática.

Orientador: Andrey Ricardo Pimentel

Coorientador: Ernani Gottardo

1. Sistemas tutoriais inteligentes. 2. Eletroencefalografia. 3. Expressão facial. 4. Interface cérebro-computador. 5. Emoções. I. Universidade Federal do Paraná. II. Programa de Pós-Graduação em Informática. III. Pimentel, Andrey Ricardo. IV. Gottardo, Ernani. V. Título.

Bibliotecário: Elias Barbosa da Silva CRB-9/1894

## TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação INFORMÁTICA da Universidade Federal do Paraná foram convocados para realizar a arguição da tese de Doutorado de **WELLTON COSTA DE OLIVEIRA** intitulada: **Um estudo no Uso de feedbacks para Mudanças de Estados Afetivos do Estudante Usando Eletroencefalograma e Expressões Faciais**, sob orientação do Prof. Dr. ANDREY RICARDO PIMENTEL, que após terem inquirido o aluno e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de doutor está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

CURITIBA, 07 de Novembro de 2022.

Assinatura Eletrônica

07/11/2022 17:22:20.0

ANDREY RICARDO PIMENTEL  
Presidente da Banca Examinadora

Assinatura Eletrônica

09/11/2022 20:24:28.0

MAICI DUARTE LEITE

Avaliador Externo (UNIVERSIDADE TECNOLÓGICA FEDERAL DO  
PARANÁ - FRANCISCO BELTRÃO)

Assinatura Eletrônica

08/11/2022 14:03:46.0

SOELAINE RODRIGUES ASCARI

Avaliador Externo (UNIV .TECNOLÓGICA FEDERAL DO PARANÁ -  
PATO BRANCO)

Assinatura Eletrônica

09/11/2022 11:32:38.0

EDUARDO TODT

Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

Assinatura Eletrônica

07/11/2022 16:55:48.0

ERNANI GOTTARDO

Coorientador(a) (INSTITUTO FEDERAL DO RIO GRANDE DO SUL)

*À minha família do Pará: mãe Enilda e pai Raimundo; Irmãs Sheyla e Keyla e irmãos Ton e Williams; Sobrinhas Maria Clara, Letícia e Grazi e sobrinho Matheus. Minhas inspirações, meu porto seguro e meus orgulhos.*

*À minha família do Paraná: meu filhão Raimundo Matias e minha esposa Ana, por todo carinho e amor.*

*Amo vocês.*

## AGRADECIMENTOS

Primeiramente à minha mãe Enilda, ao meu pai Raimundo, às minhas irmãs Sheyla e Keyla, aos meus irmãos Ton e Williams, pois sem o incentivo de vocês, nada disso seria possível hoje. Era só lembrar do amor e apoio que eu recebia que tudo melhorava. À minhas sobrinhas Maria Clara, Letícia e agora a pequena Grazi e à meu sobrinho Matheus. É a melhor família desse mundo. Obrigado por tudo! Amo vocês.

À minha esposa Ana que com todo seu carinho, dedicação e força, me ajudou e me inspirou com o nascimento do Raimundo, que veio a este mundo para provar que tudo pode ser perfeito, assim como seu sorriso sincero e lindo. Amo vocês dois. Hoje não consigo pensar na vida sem essa duplinha maravilhosa. Também agradeço à família da Ana que me acolheu muito bem. Sempre desejarei as melhores coisas para vocês.

Ao professor Andrey Pimentel, uma exceção de orientador que tenta entender o seu orientado, certo ao propor uma solução aos desafios e firme quando tem que cobrar. Obrigado pelo desafio de fazer esta tese. Meus desesperos, agonias e ansiedades referente ao trabalho passavam logo após seus *feedbacks*, mostrando que este trabalho não é apenas teoria. Muito obrigado. Agradeço também meu co-orientador Ernani Gottardo por sempre estar presente nos vários momentos que surgiam dúvidas em detalhes técnicos da tese.

Aos coordenadores do PPGInf, Prof. Bona e Prof. Roberto por todo apoio e incentivo que deram e pela secretaria por sempre nos ajudarem a resolver os problemas que apareciam. Muito obrigado Jonas e Rafael.

Um grupo de professores da UTFPR se juntaram para fazer doutorado na UFPR. Depois de várias viagens bate-e-volta de 14 horas pra Curitiba, hoje são todos doutores, e me orgulho de fazer parte disso. Agradecimento ao Robison (por encabeçar a ideia), Soelaine, Eliane e Rúbia (Pato Branco), Marlon, André, Franciele, Newton e Evandro (Dois Vizinhos). Ao prof. Marcos Didonet, então coordenador do PPGInf que confiou na proposta, e ao prof. Roberto Pereira por estar junto desde o começo.

Meus colegas de trabalho, Edson da proposta deste doutorado. Aos meus chefes em todo esse período que apoiaram sempre, Gustavo, Paulo e Marcos. À Maici e ao Reinaldo, pelas conversas sobre o CEP. Ao Teruo por ajudar nas análises estatísticas. Aos professores Rafael, Mayara, Michel, Renato, Flávio e Adair por sempre estarem dispostos a conversar sobre a tese e outros assuntos.

Ao Leonam e ao Felipe do FAES, pelas idas ao RU encarar a fila ou pelas andadas ao campus botânico para assistir aulas de estatística. Obrigado pelos poucos momentos de lazer que tínhamos como ir ao cinema com a turma e depois comer hambúrguer e ficarmos lá até sermos expulsos, hehe.

Aos estudantes que participaram do experimento e também às ajudantes Pamella, Midyan e Jéssica e ao ajudante Marx que ficaram lá até o final dos experimentos.

Um agradecimento muito especial à toda comunidade de software livre que fazem projetos maravilhosos como OpenBCI, Brainflow, Python, PHP, MariaDB, EmoNet, Torch, Arduino,  $\LaTeX$ , pdfTeX, ShareLatex, TexStudio, Zotero, Bibtex, Nextcloud, Projeto Debian, Projeto GNU (Bash, glibc, Coreutils, Make, GCC, Binutils, Emacs, IceCat entre outros) e sua filosofia, Slic3r, Cura, Kernel Linux e aos vários outros que foram essenciais para este trabalho.

À todos que não foram citados mas que estiveram envolvidos de alguma forma com a finalização desta tese, recebam meus sinceros agradecimentos. Vocês, de uma forma ou de outra, foram muito importantes para a concretização deste trabalho.

## RESUMO

O estado afetivo é um dos fatores mais importantes quando se trata de motivação do estudante. Estudos apontam que emoções positivas contribuem para a aprendizagem, enquanto que emoções negativas dificultam. O papel dos *feedbacks* é importante, principalmente quando é direcionado e adaptado ao estudante, e podem ser *feedbacks* pós-processo, que são fornecidos depois da resposta, ou *feedbacks* em processo, que são apresentados antes da finalização da questão. Porém, no contexto educacional, o fator afetivo é pouco utilizado por diversos fatores, tais como a desproporcionalidade entre o número de alunos e o número de docentes, dificultando a identificação do estado afetivo individual, ou o fato da dificuldade na adaptação do conteúdo e dos *feedbacks* de acordo com cada variação de emoção individual. Uma possibilidade que pode auxiliar nessas tarefas é utilizar o contexto computacional para registrar e reconhecer os estados afetivos do estudante de acordo com suas expressões da face e também da atividade neural via Eletroencefalograma (EEG) e com isso, adaptar *feedbacks* utilizando Sistemas Tutores Inteligentes (ITS) de acordo com estas mudanças afetivas. Este trabalho apresenta um estudo no uso de *feedbacks* em processo para análise de mudanças afetivas. Para isso, uma abordagem modular chamada NeurAFFeed foi elaborada, realizando a coleta, análise e armazenamento de estados afetivos do estudante, enquanto resolve questões de linguagem de programação em um Ambiente Virtual de Aprendizagem (AVA), através de dados da face usando uma webcam e dados de EEG através de uma interface cérebro-computador (BCI, do inglês, *Brain-Computer Interface*) de baixo custo chamada OpenBCI, para que um módulo afetivo para STI faça a observação de tais estados e decida exibir ou não *feedbacks* em processo, que serão apresentados ao estudante na forma de notificações em um AVA. O experimento utilizou a abordagem NeurAFFeed em um grupo de vinte estudantes, sendo metade o Grupo Controle (GC), sem apresentação de *feedbacks*, e a outra metade o Grupo Experimental (GE), com exibição de *feedbacks*. A análise dos dados demonstrou que houve uma diferença significativa entre o GC e o GE, ocorrendo um aumento de 14,9% nas mudanças dos estados afetivos para quadrantes preferíveis nos dados de faces e um aumento de 12,5% para dados de EEG. Também foi evidenciado a possibilidade de elaboração de rankings dos melhores *feedbacks* de acordo com os dados de face e EEG. A análise dos resultados sinaliza que a abordagem NeurAFFeed permite a realização de estudos que usam *feedbacks* em processo para verificação de mudanças afetivas com dados de face e de EEG coletados com aparelhos não-clínicos e de baixo custo como webcam e OpenBCI, respectivamente. Este trabalho contribui com a possibilidade da utilização de sua abordagem para novos estudos nas áreas de STI afetivo, *feedbacks* em processo e análise acessível de atividade neural.

Palavras-chave: Sistemas Tutores Inteligentes. Emoções. *Feedback*. Eletroencefalograma. OpenBCI. Interface Cérebro-Computador. Expressões Faciais.

## ABSTRACT

The affective state is one of the most important factors when it comes to student motivation. Studies show that positive emotions contribute to learning, while negative emotions make it difficult. The role of feedback is important, especially when it is directed and adapted to the student, and can be post-process feedback, which is provided after the answer, or in-process feedback, which is presented before the finalization of the question. However, in the educational context, the affective factor is rarely used due to several factors, such as the disproportionality between the number of students and the number of teachers, making it difficult to identify the individual affective state, or the fact that it is difficult to adapt the content and feedbacks according to each individual emotion variation. A possibility that can help in these tasks is to use the computational context to record and recognize the student's affective states according to their facial expressions and also the neural activity via Electroencephalogram (EEG) and with that, adapt feedbacks using Intelligent Tutoring Systems (ITS) according to these changes affective. This work presents a study on the use of process feedbacks to analyze affective changes. For this, a modular approach called NeurAFFeed was elaborated, performing the collection, analysis and storage of the student's affective states, while solving programming language issues in a Virtual Learning Environment (VLE), through face data using a webcam and EEG data through a low-cost Brain-Computer interface (BCI) called OpenBCI, so that an affective module for ITS observes such states and decides whether or not to display feedbacks in process, which will be presented to the student in the form of notifications on a VLE. The experiment used the NeurAFFeed approach in a group of twenty students, half being the Control Group (GC), without feedback, and the other half being the Experimental Group (EG), with feedback. Data analysis showed that there was a significant difference between the CG and the EG, with an increase of 14.9% in changes from affective states to preferable quadrants in face data and an increase of 12.5% for EEG data. The possibility of developing rankings of the best feedbacks according to face and EEG data was also evidenced. The analysis of the results indicates that the NeurAFFeed approach allows the realization of studies that use in-process feedbacks to verify affective changes with face and EEG data collected with non-clinical and low-cost devices such as webcam and OpenBCI, respectively. This work contributes with the possibility of using his approach for new studies in the areas of affective ITS, in-process feedbacks and accessible analysis of neural activity.

Keywords: Intelligent Tutoring Systems. Emotions. Feedback. Eletroencephalogram. OpenBCI. Brain-Computer Interface. Facial Expressions.



## LISTA DE FIGURAS

2.1	Neurônios e sinapses. <b>a.</b> Neurônios vistos através da coloração de Golgi no ano de 1873 (adaptado de Hubel (1988)); <b>b.</b> Axônio (amarelo) e dendrito (azul) coletado por microscópio eletrônico (adaptado de Norton (2013)); <b>c.</b> Partes do neurônio (adaptado de Silverthorn (2010)); <b>d.</b> Sinapse neuromuscular (adaptado de USP (2022)); <b>e.</b> Detalhes do processo da sinapse química (adaptado de Teixeira (2012)).. . . . .	20
2.2	Divisão do Sistema Nervoso Central (SNC) em duas partes: Medula Espinal e Encéfalo. . . . .	21
2.3	Estrutura do Encéfalo. <b>a.</b> Imagem da estrutura do encéfalo coletada com fMRI; <b>b.</b> Nome das partes da estrutura do encéfalo.. . . . .	21
2.4	Telencéfalo. <b>a.</b> Vista lateral e identificação dos lobos; <b>b.</b> Vista superior e identificação dos hemisférios; <b>c.</b> Vista do corte transversal com identificação do córtex e das substâncias. . . . .	22
2.5	O circuito de Papez.. . . . .	23
2.6	Vias corticais e subcorticais. Via lenta e via rápida. . . . .	24
2.7	Técnicas de extração de emoções. <b>a.</b> cognitivo ou experiencial-subjetivo, <b>b.</b> neurofisiológica e bioquímica e <b>c.</b> Motor ou comportamental-expressivo.. . . .	25
2.8	Modelo Circumplexo de Afeto de Russell (1980). . . . .	26
2.9	Exemplos de Imagens e seus respectivos valores afetivos ( <i>valence</i> e <i>arousal</i> ). . . . .	27
2.10	Ao exibir uma imagem do IAPS, há uma ativação na amígdala, hipocampo, giros para-hipocampais, Córtex pré-frontal e córtex visual. . . . .	28
2.11	Posições atuais do Sistema Internacional 10-20. . . . .	29
2.12	Distância entre eletrodos no sistema 10-20. <b>a.</b> Visão lateral; <b>b.</b> Visão frontal; <b>c.</b> Visão superior. . . . .	30
2.13	Três diferentes métodos para registro de atividade elétrica cerebral. <b>a.</b> EEG, ECoG e Gravações Intracorticais; <b>b.</b> Métodos não-invasivo e invasivos com suas respectivas tensões elétricas e frequências. . . . .	31
2.14	Exemplo de oito sinais EEG (domínio do tempo). Fz, Cz, P3, Pz, P4, PO7, PO8, Oz.. . . . .	32
2.15	Bandas de Frequência de Sinal EEG . . . . .	32
2.16	Espectro EEG de canal único: <b>a.</b> um segmento do sinal EEG no domínio do tempo, <b>b.</b> o espectro do sinal de (a) no domínio da frequência usando DFT. . . . .	33
2.17	Parte eletrônica principal do OpenBCI: Placa Cyton, possui entradas para oito eletrodos e duas entradas para eletrodos utilizados para o terra e tem conexão sem fio via <i>bluetooth</i> . . . . .	34
2.18	Ultracortex. <b>a.</b> eletrodos do OpenBCI seguem o sistema internacional 10-20. <b>b.</b> Ultracortex impresso e montado com a Placa Cyton, eletrodos e <i>jumpers</i> para conexão.. . . . .	35

2.19	Interface Gráfica do Usuário do OpenBCI . . . . .	36
2.20	Processo de reconhecimento de emoções usando EEG. . . . .	37
2.21	Um exemplo do FACS. . . . .	38
2.22	Um exemplo de reconhecimento de emoção através de expressão facial. <b>a.</b> expressões faciais com seus respectivos valores. <b>b.</b> Estrutura de uma rede neural para reconhecimento classificação de emoções. . . . .	39
2.23	Imagens da AffectNet com faces em seus respectivos pontos no plano afetivo <i>valencearousal</i> . . . . .	40
2.24	Visão geral da arquitetura de reconhecimento de expressões faciais e <i>valencearousal</i> de Toisoul et al. (2021). . . . .	41
2.25	Exemplos de reconhecimentos de <i>valence</i> e <i>arousal</i> .. . . .	42
2.26	Resultados do algoritmo proposto por Toisoul et al. (2021) em comparação a quatro algoritmos. . . . .	42
2.27	Arquitetura básica de um STI clássico. . . . .	44
2.28	Processo de <i>feedback</i> no contexto de estudante agem . . . . .	46
3.1	Modelo de representação das emoções em quadrantes.. . . .	49
3.2	STIE e suas respostas e respostas de tutores humanos de acordo com cada estado afetivo identificado. . . . .	51
3.3	Arquitetura NORA, formada por coleta de dados (agentes A1, A2 e A3) e inferência do estado afetivo (agentes A4, A5 e A6) . . . . .	53
3.4	Diagrama de blocos do STIE.. . . .	54
3.5	Projeto do experimento. (a) A configuração, (b) o layout do eletrodos EEG (c) as áreas de interesse definidas no Eclipse.. . . .	55
4.1	Visão Geral da abordagem <b>NeurAFFeed</b> , utilizada para a realização do estudo proposto. . . . .	58
4.2	Etapas da impressão do <i>headset</i> : <b>a.</b> Carregamento dos arquivos STL no RepetierHost; <b>b.</b> Configuração da impressora 3D; <b>c.</b> impressão do <i>headset</i> ; <b>d.</b> comparação do modelo com impressão. . . . .	59
4.3	Localização dos eletrodos F3, F4, AF3 e AF4 (em vermelho) segundo o sistema internacional 10-20 . . . . .	60
4.4	Fluxograma da escolha dos <i>feedbacks</i> pelo Módulo Tutor . . . . .	63
4.5	AVA web utilizado para apresentação das atividades e <i>feedbacks</i> . . . . .	64
4.6	Ambiente Virtual de Aprendizagem exibindo uma questão da disciplina de Linguagem de Programação. . . . .	65
4.7	Exemplo de <i>feedback</i> exibido . . . . .	67
5.1	Ambiente 1: sala para extração de dados . . . . .	70
5.2	Ambiente 2: Sala de monitoramento . . . . .	70
5.3	Software OBS Studio capturando a tela do estudante . . . . .	71
5.4	Sala de Espera. . . . .	72

5.5	Estudante do GE antes de exibir o <i>feedback</i> . . . . .	73
5.6	Estudante do GE enquanto exibe o <i>feedback</i> . . . . .	73
5.7	Trecho dos dados de Face EEG coletados do GC. . . . .	74
5.8	Trecho dos dados de Face e EEG coletados do GE. . . . .	75
5.9	Trecho da tabela tutor com <i>feedbacks</i> apresentados ao estudante do GE. . . . .	75
6.1	Mudanças afetivas ocorridas nos dados da face do GC. . . . .	77
6.2	Mudanças afetivas ocorridas nos dados da face do GE. . . . .	77
6.3	valores totais de mudanças para quadrantes preferíveis (1 e 4) e para não-preferíveis (2 e 3) para os dados de faces do GC . . . . .	78
6.4	Valores da porcentagem proporcional de mudanças para quadrantes preferíveis (1 e 4) e para não-preferíveis (2 e 3) para dados de faces do GE. Em comparação com o gráfico anterior, ocorreu um ganho de <b>14,9%</b> . . . . .	78
6.5	Mudanças afetivas ocorridas nos dados de EEG do GC . . . . .	79
6.6	Mudanças afetivas ocorridas nos dados de EEG do GE . . . . .	79
6.7	valores totais de mudanças para quadrantes preferíveis (1 e 4) e para não-preferíveis (2 e 3) para os dados de EEG do GC. . . . .	80
6.8	valores de mudanças para quadrantes preferíveis (1 e 4) e para não-preferíveis (2 e 3), com dados de EEG do GE. Em comparação com o gráfico anterior, ocorreu um ganho de <b>12,5%</b> . . . . .	81
A.1	Impressora 3DCloner Lab. . . . .	105
A.2	Arquivos STL para impressão da estrutura 3D do OpenBCI. . . . .	106
A.3	Arquivos sendo configurados para o fatiamento . . . . .	107
A.4	Objetos impressos de acordo com os arquivos STL do OpenBCI . . . . .	108
A.5	Peças impressas: Estrutura que segura a placa eletrônica. . . . .	109
A.6	Peças impressas: Polcas que seguram os eletrodos. . . . .	109
A.7	Peças impressas: Clipes para segurar <i>jumpers</i> . . . . .	110
A.8	Peças impressas: <i>Frames</i> dividida em duas partes. . . . .	110
A.9	Material para pós-processamento das peças do <i>frame</i> . . . . .	111
A.10	Pós-processamento das peças do <i>frame</i> . . . . .	112
A.11	Pós-processamento das peças do <i>frame</i> . . . . .	112
A.12	Colagem das duas partes do <i>frame</i> . . . . .	113
A.13	Montagem: inserindo as polcas. . . . .	113
A.14	Pós-processamento das peças do <i>frame</i> . . . . .	114
A.15	Bateria de Lipo utilizada no OpenBCI, com o carregador USB. . . . .	114
A.16	Eletrodos secos de cloreto de prata. . . . .	115
A.17	<i>jumpers</i> para conexão entre eletrodos e pinos da placa Cyton. . . . .	115
A.18	Eletrodos em forma de pinça para fixação no lobo auricular, A1 e A2 no sistema 10-20, servindo como terra. . . . .	116

A.19	Eletrodos para serem fixados no lobo auricular (A1 e A2 no sistema 10-20, servindo como terra. . . . .	116
A.20	Montagem: fixação do compartimento da placa eletrônica no <i>frame headset</i> . . . . .	117
A.21	Montagem: encaixando um eletrodo no <i>frame</i> .. . . .	118
A.22	<i>jumpers</i> para conexão entre eletrodos e pinos da placa Cyton.. . . .	118
A.23	Montagem: encaixando os quatro eletrodos, F3, F4, AF3 e AF4, de acordo com o sistema 10-20, necessários para o FEA. . . . .	119
A.24	Montagem: eletrodos F3, F4, AF3 e AF4 no <i>frame</i> . . . . .	119
A.25	Montagem: detalhe dos eletrodos secos do lado esquerdo.. . . . .	120
A.26	Montagem: Eletrodos secos mais aproximados. . . . .	120
A.27	Montagem: conectando <i>jumpers</i> dos eletrodos na placa Cyton. . . . .	121
A.28	Montagem: encaixando a placa Cyton no compartimento.. . . . .	122
A.29	Montagem: encaixando a tampa do compartimento para proteção da placa Cyton. . . . .	123
A.30	Montagem: teste do funcionamento da placa Cyton . . . . .	124
A.31	Utilização do OpenBCI: Estudante se senta na cadeira e ao lado está o OpenBCI. . . . .	125
A.32	Utilização OpenBCI: O estudante veste o OpenBCI, fazendo contato com todos os eletrodos no couro cabeludo.. . . . .	125
A.33	Utilização OpenBCI: Visão lateral direita do estudante com OpenBCI. . . . .	126
A.34	Utilização OpenBCI: Visão lateral esquerda do estudante com OpenBCI.. . . .	127
A.35	Utilização OpenBCI: Aproximação da visão lateral direita do estudante com OpenBCI. . . . .	128
A.36	Utilização OpenBCI: Visão superior do estudante com OpenBCI, os <i>jumpers</i> não se tocam em momento algum. . . . .	129

## LISTA DE TABELAS

2.1	Tipos e subtipos de intervenções tutoriais. . . . .	48
6.1	Tabela de <i>feedbacks</i> com suas respectivas porcentagens de ocorrências em quadrantes preferíveis <b>antes</b> e <b>depois</b> de acordo com a face.. . . .	82
6.2	Tabela de diferenças entre a porcentagem dos quadrantes preferíveis antes e depois dos <i>feedbacks</i> com dados da face.. . . .	83
6.3	Tabela de <i>feedbacks</i> com suas respectivas porcentagens de ocorrências em quadrantes preferíveis <b>antes</b> e <b>depois</b> com dados de EEG . . . . .	84
6.4	Tabela de diferenças entre a porcentagem proporcional do número de registros que estiveram nos quadrantes preferíveis (1 e 4) <b>antes</b> e <b>depois</b> dos <i>feedbacks</i> com dados de EEG, de acordo com ao Tabela 6.3. . . . .	85

## LISTA DE ACRÔNIMOS

ABS	<i>Acrylonitrile Butadiene Styrene</i>
ATS	<i>Affective Tutoring Systems</i>
AVA	Ambiente Virtual de Aprendizagem
BCI	<i>Brain-Computer Interface</i>
CAI	<i>Computer-Assisted instruction</i>
CCC	Coeficiente de Correlação de Concordância
CPU	<i>Central Processing Unit</i>
DFT	<i>Discrete Fourier Transform</i>
ECG	Eletrocardiograma
ECoG	Eletrocotrigograma
EEG	Eletroencefalograma
EITS	<i>Emotionally Intelligent Tutoring System</i>
EMG	Eletromiograma
EOG	Eletrooculograma
FACS	<i>Facial Action Coding System</i>
FEA	<i>Frontal EEG Asymmetry</i>
fMRI	<i>Functional magnetic resonance imaging</i>
GPIO	<i>General Purpose Input/Output</i>
GPU	<i>Graphics Processing Unit</i>
GUI	<i>Graphical User Interface</i>
IA	<i>Inteligência Artificial</i>
IAPS	<i>International Affective Picture System</i>
ICAI	<i>Intelligent Computer-Assisted Instruction</i>
IDE	<i>Integrated development environment</i>
IHC	Interação Humano-Computador
ITS	<i>Intelligent Tutoring System</i>
LFP	<i>Local Field Potential</i>
LPA	<i>Left Pre-Auricular</i>
PFC	<i>Prefrontal Cortex</i>
PLA	<i>Polylactic Acid</i>
RPA	<i>Right Pre-Auricular</i>
SAM	<i>Self-Assessment Manikin</i>
SNC	Sistema Nervoso Central
SNP	Sistema Nervoso Periférico
STA	Sistemas Tutores Afetivos

STL	<i>Standard Triangle Language</i>
STI	Sistemas Tutores Inteligentes
STIE	Sistemas Tutores Inteligentes Emocionais
VLE	<i>Virtual Learning Environment</i>

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>16</b>
1.1	CONTEXTUALIZAÇÃO E PROBLEMA	16
1.2	QUESTÃO DE PESQUISA DA TESE	17
1.3	OBJETIVOS	17
1.3.1	Geral	17
1.3.2	Específicos	17
1.4	JUSTIFICATIVA	18
1.5	ESTRUTURA DO TRABALHO	18
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA</b>	<b>19</b>
2.1	NEURÔNIOS, SISTEMA NERVOSO E EMOÇÃO	19
2.1.1	Neurônios e Sinapses	19
2.1.2	Sistema Nervoso Periférico e Central	20
2.1.3	Emoção e Resposta Afetiva	23
2.2	EXTRAÇÃO DE EMOÇÕES	25
2.2.1	O Modelo Circumplexo do Afeto	26
2.2.2	Ferramenta SAM e Biblioteca IAPS	27
2.2.3	Eletroencefalograma (EEG) e <i>Brain-Computer Interface</i> (BCI)	29
2.2.4	Interface Cérebro-Computador Aberto (OpenBCI)	34
2.2.5	Reconhecimento de Estados Afetivos e EEG	37
2.2.6	Identificação de Emoção por Expressão Facial	38
2.3	EMOÇÃO E APRENDIZAGEM	43
2.4	SISTEMAS TUTORES INTELIGENTES (STI)	44
2.5	SISTEMAS TUTORES AFETIVOS OU SISTEMAS TUTORES INTELIGENTES EMOCIONAIS	45
2.6	<i>FEEDBACKS</i> NA APRENDIZAGEM	46
<b>3</b>	<b>TRABALHOS CORRELATOS</b>	<b>49</b>
3.1	ESTADOS AFETIVOS NA APRENDIZAGEM	49
3.2	<i>FEEDBACKS</i> NA APRENDIZAGEM	50
3.3	SISTEMAS TUTORES AFETIVOS	53
3.4	COLETA DE EEG COM OPENBCI	56
3.5	TRABALHOS CORRELATOS E A TESE	57
<b>4</b>	<b>METODOLOGIA DA ABORDAGEM NEURAFFEED</b>	<b>58</b>
4.1	VISÃO GERAL	58
4.2	COLETA E ANÁLISE DE ATIVIDADE NEURAL VIA EEG E FACE	59



4.3	MÓDULO AFETIVO PARA STI. . . . .	61
4.4	AVA, EXIBIÇÃO DAS ATIVIDADES E APRESENTAÇÃO DE <i>FEEDBACKS</i> . . . . .	64
<b>5</b>	<b>REALIZAÇÃO DO EXPERIMENTO . . . . .</b>	<b>68</b>
5.1	METODOLOGIA CIENTÍFICA EXPERIMENTAL . . . . .	68
5.2	ESTUDANTES VOLUNTÁRIOS PARTICIPANTES . . . . .	68
5.3	AMBIENTES PARA REALIZAÇÃO DO EXPERIMENTO . . . . .	69
5.3.1	Ambiente 1: Sala de extração de dados. . . . .	69
5.3.2	Ambiente 2: Sala de Monitoramento . . . . .	70
5.3.3	Ambiente 3: Sala de Espera . . . . .	71
5.4	METODOLOGIA DO EXPERIMENTO. . . . .	72
5.5	DADOS COLETADOS . . . . .	74
5.5.1	Coleta de dados do GC . . . . .	74
5.5.2	Coleta de dados do GE . . . . .	74
5.5.3	Coleta de dados <i>feedbacks</i> apresentados ao estudante . . . . .	75
<b>6</b>	<b>ANÁLISE DOS RESULTADOS . . . . .</b>	<b>76</b>
6.1	HIPÓTESES PARA ANÁLISE. . . . .	76
6.2	ANÁLISE DA HIPÓTESE 1 . . . . .	76
6.2.1	Estudo com dados da face. . . . .	76
6.2.2	Estudo com dados da EEG . . . . .	79
6.3	ANÁLISE DA HIPÓTESE 2 . . . . .	81
6.3.1	Análise do <i>ranking</i> do melhores <i>feedbacks</i> de acordo com a face . . . . .	82
6.3.2	Análise do <i>ranking</i> do melhores <i>feedbacks</i> de acordo com o EEG. . . . .	84
6.4	DISCUSSÃO DOS RESULTADOS . . . . .	86
6.5	AMEAÇAS À ANÁLISE DO EXPERIMENTO. . . . .	87
<b>7</b>	<b>CONSIDERAÇÕES FINAIS . . . . .</b>	<b>88</b>
7.1	TRABALHOS FUTUROS . . . . .	89
7.2	PUBLICAÇÃO . . . . .	90
	<b>REFERÊNCIAS . . . . .</b>	<b>91</b>
	<b>APÊNDICE A – IMPRESSÃO E MONTAGEM DO OPENBCI. . . . .</b>	<b>105</b>
A.1	IMPRESSÃO DO <i>HEADSET</i> DO OPENBCI . . . . .	105
A.2	ETAPA DE PÓS-PROCESSAMENTO. . . . .	111
A.3	COMPONENTES ELETRÔNICOS DO OPENBCI . . . . .	114
A.4	MONTAGEM FINAL DO OPENBCI . . . . .	117
A.5	UTILIZAÇÃO DO OPENBCI NOS DIAS DO EXPERIMENTO . . . . .	125

# 1 INTRODUÇÃO

## 1.1 CONTEXTUALIZAÇÃO E PROBLEMA

A dimensão afetiva é muito importante para a aprendizagem e pesquisas sugerem que um estudante aprende melhor quando ele sente emoções positivas (como a alegria) resultantes em entusiasmo, curiosidade, envolvimento ou desafio, enquanto as emoções negativas (como tristeza, raiva ou medo) causam ansiedade, apatia, frustração e com isso, tendo uma aprendizagem baixa (Cosenza e Guerra, 2011; Tyng et al., 2017; Elnicki, 2010; Immordino-Yang, 2015; Pekrun et al., 2002; D’Mello e Graesser, 2012; Barrón-Estrada et al., 2016; Ascari et al., 2021; Gottardo e Ricardo Pimentel, 2018; Bosch et al., 2014; Botelho et al., 2017; Paquette et al., 2014; Jaques et al., 2014; Conati, 2011). Ou seja, entender e conhecer o sistema afetivo de cada estudante é de extrema importância para que a escolarização atinja a qualidade social para todos, garantindo de forma sistemática, a apropriação do conhecimento acumulado pela humanidade e no desenvolvimento de habilidades e competências. Segundo Yamamoto et al. (2021), fornecer *feedback* às atividades de aprendizagem ao estudante é uma das questões mais importantes para realizar a aprendizagem adaptativa.

Porém, um professor entender e acompanhar a aprendizagem juntamente com o estado afetivo de cada um dos estudantes da sala de aula se torna uma atividade impraticável por conta do número de discentes em relação ao de docentes. Apesar de alguns professores reconhecerem a emoção de determinados estudantes enquanto respondem questões de provas ou de exercícios, identificar variações minuciosas de estados afetivos pode ser considerado complexo em se tratando de um docente e diversos estudantes. Assim, apresentam-se três problemáticas: 1) os professores tendem a não adaptar seu ensino de acordo com a aprendizagem de cada estudante, quiçá à dimensão afetiva; 2) reconhecer estados afetivos de estudantes não é uma tarefa tão simples e 3) mesmo que o professor consiga se adaptar à aprendizagem do estudante e identifique os seus estados afetivos, quais *feedbacks* ele forneceria ao estudante de acordo com tais emoções?

Uma alternativa encontrada é a utilização de tecnologias digitais tais como computadores, onde seus aprimoramentos constantes permitem a adaptação de conceitos e de problemas específicos. Este crescimento afeta diretamente no processo de ensino-aprendizagem e de certos paradigmas educacionais. Por exemplo, o problema da impossibilidade de adaptação do ensino do professor à aprendizagem de cada estudante pode ser compensado com a criação de Sistemas Tutores Inteligentes (STI) (Nwana, 1990; He et al., 2009), onde um computador pode fornecer instruções ou *feedback* personalizados (Fossati, 2008; Dāboliņš e Grundspenķis, 2013; Jiménez et al., 2018; Phobun e Vicheanpanya, 2010; Latham et al., 2012; Roll et al., 2011). Os STI’s podem ser utilizados juntamente com Ambientes Virtuais de Aprendizagem (AVA) (Muhardi et al., 2020; Kasim e Khalid, 2016; Ellis e Calvo, 2007), que podem ser projetados de acordo com a necessidade do ambiente educacional, facilitando a utilização de objetos de aprendizagem tais como multimídia interativa, materiais de ensino, tarefas, discussões online, vídeos educacionais, videoconferências interativas entre outros. Sobre a questão afetiva, existem formas de mensurar uma emoção de um estudante utilizando o plano *valence* e *arousal* (Russell e Mehrabian, 1977; Bradley e Lang, 2000), que consiste na modelagem da agradabilidade como eixo x e da ativação como eixo y, por exemplo, se a pessoa estiver agradável e agitada, sugere-se alegria, caso a pessoa estiver desagradável e agitada, raiva ou medo, ou caso esteja desagradável e calmo, sugere-se tristeza. Esta técnica pode ser utilizada através da face (Toisoul et al., 2021; Kollias et al., 2019; Mollahosseini et al., 2019; Adolph e Alpers, 2010) ou de técnicas neurofisiológicas

e bioquímicos, tais como ativação elétrica cerebral, ou eletroencefalograma (EEG), a ativação elétrica do coração, ou eletrocardiograma (ECG), ou a identificação elétrica da tensão muscular, ou eletromiograma (EMG) (Alam et al., 2019; Katsigiannis e Ramzan, 2018; Wiem e Lachiri, 2017; Kawde e Verma, 2017; Chen et al., 2015; Koelstra et al., 2012; Soares et al., 2011). A democratização da neurociência é um tópico importante no contexto atual e isso permite encontrar Interfaces Cérebro-Computador (BCI, do inglês, *Brain-Computer Interface*) (Frey, 2016; Ferreira et al., 2013; Nicolas-Alonso e Gomez-Gil, 2012), acessíveis para realizar estudos não-clínicos com dados de eletroencefalograma, tal como o projeto OpenBCI (OpenBCI, 2022a; Rashid et al., 2018), muito utilizado pela comunidade científica (OpenBCI, 2022b) em áreas fora da medicina ou da neurociência. Por fim, tal análise afetiva deveria ser feita durante a atividade, ou seja, antes da resposta do estudante análise, ou seja,

## 1.2 QUESTÃO DE PESQUISA DA TESE

**É possível realizar um estudo no uso de *feedbacks*, tais como dicas e *feedbacks* afetivos, fornecidos por um STI, para analisar mudanças de estados afetivos (variações de *valence* e *arousal*) do estudante inferidas por expressão facial e dados de eletroencefalograma enquanto realiza uma atividade em um ambiente virtual de aprendizagem?**

## 1.3 OBJETIVOS

### 1.3.1 Geral

Realizar um estudo que usa *feedbacks*, apresentados durante uma atividade, para análise de mudanças afetivas do estudante. Para isso, é necessário elaborar uma abordagem, chamada **NeurAFFeed**, para inferir estados afetivos (variação de *valence* e *arousal*) da face e da ativação neural via EEG, para que o módulo afetivo de STI realize sua estratégia e forneça *feedbacks* na forma de notificações em um AVA.

### 1.3.2 Específicos

- Elaborar uma lista de *feedbacks* (com dicas e *feedbacks* afetivos);
- Identificar os valores de *valence* e *arousal* com imagens oriundas de *webcam*.
- Identificar os valores de *valence* e *arousal* com sinais de EEG (eletroencefalograma) oriundos da interface cérebro-computador não-invasivo e não-clínico chamada OpenBCI.
- Elaborar um módulo para STI que forneça *feedbacks* baseado nos valores de *valence* e *arousal* da face do estudante;
- Criar um *plugin* para ambiente virtual de aprendizagem web que exiba e registre em disco *feedbacks* na forma de notificações, enquanto o estudante responde uma atividade.
- Aplicar a abordagem **NeurAFFeed** em um experimento com estudantes de graduação;
- Analisar os dados do experimento, verificando a hipótese nula dos dois grupos (GC e GE), verificando as mudanças de estados afetivos de acordo com o *feedback* fornecido, analisando os dados de expressões faciais e EEG separadamente.

## 1.4 JUSTIFICATIVA

Pesquisas científicas atuais no âmbito da influência dos estados afetivos no processo ensino-aprendizagem (Ascari et al., 2021; Sadoughi e Hejazi, 2021; Camacho-Morles et al., 2021; Horovitz e Mayer, 2021; Zheng et al., 2021) sugerem a importância de estudar mais profundamente formas de entender o que se passa com os estudantes enquanto eles estudam. Os *feedbacks* dos professores desempenham um papel importante na aprendizagem dos estudantes, pois melhora o desenvolvimento cognitivo destes (Duarte Leite. et al., 2013; Chen et al., 2022). Supondo realizar o seguinte questionamento a um docente: Quando você percebe, através da expressão facial, que um estudante está aborrecido, frustrado, confuso ou triste, com tédio, desmotivado (Gottardo e Ricardo Pimentel, 2018), qual *feedback* fornecer para possibilitar mais interesse ou mais confiança? qual resposta receberia? É um questionamento que provoca muito debate. Variadas respostas podem surgir depois deste questionamento como "não tenho tempo para isso" ou "mesmo que perceba a emoção, qual *feedback* fornecer?". De acordo com Yamamoto et al. (2021), o *feedback* fornecido após a resposta do estudante é chamado de "*feedback* pós-processo" e o *feedback* fornecido durante a atividade é chamado de "*feedback* em processo". Quando um estudante fica frustrado durante algum estágio da atividade, o *feedback* durante o processo é uma via importante a ser considerada.

Além disso, a forma de aquisição da atividade neural via EEG para pesquisas na área de computação até então era escassa por conta do alto custo de aparelhos de eletroencefalografia. Porém, nos últimos anos foi possível perceber o aumento de pesquisas científicas utilizando dados de EEG por conta de um movimento para democratização da tecnologia cognitiva (Ienca, 2019) onde um dos projetos mais promissores é o OpenBCI (OpenBCI, 2022a), uma interface cérebro-computador *open source*, não-clínico, de baixo custo (comparado com versões clínicas), que possibilita customização e com uma *API* (do inglês, *Application Programming Interface*) para integração com diversas linguagens de programação chamada Brainflow (2022) e sua estrutura é feita com impressora 3D (Ultracortex, 2022), tornando mais acessível.

A presente pesquisa objetiva elaborar uma abordagem chamada **NeurAFFeed** que possibilite realizar um estudo que usa *feedbacks* de forma em processo, ou seja, enquanto o estudante analisa a questão e antes de dar a resposta, utilizando um módulo de STI em um ambiente virtual de aprendizagem web. Para a análise dos valores de *valence* e *arousal*, utiliza-se expressão facial (usando uma *webcam*) e dados de sinais elétricos de EEG usando o OpenBCI (pouco explorado atualmente neste contexto educacional). Desta forma, pretende-se contribuir para quem quiser estudar mais sobre sensores neurofisiológicos e bioquímicos, reconhecimento de expressões faciais para melhorias de *feedbacks* que melhor ajudem um estudante a regular suas emoções enquanto realiza atividades.

## 1.5 ESTRUTURA DO TRABALHO

Capítulo 2 - Fundamentação teórica, abordando os temas de STI, Teoria e Extração de Emoções (EEG e Expressões Faciais) e *feedbacks*; Capítulo 3 - Trabalhos correlatos, onde serão abordados os estudos similares a esta tese, sugerindo a originalidade deste trabalho; Capítulo 4 - Proposta do Trabalho, contendo a visão geral da abordagem **NeurAFFeed** para realizar o estudo proposto e sua metodologia de experimentos; Capítulo 5 - Experimento, explicando com detalhes como ocorreu o processo de aplicação do experimento; Capítulo 6 - Análise dos resultados, junto com a discussão; e por fim, o Capítulo 7 - Conclusão e sugestões para trabalhos futuros.

## 2 REVISÃO BIBLIOGRÁFICA

Neste capítulo são apresentados inicialmente conceitos sobre os neurônios e sinapses, partes do sistema nervoso, o sistema límbico e resposta afetiva. Conceitos sobre emoção e sua extração, tais como SAM e IAPS, EEG e BCI e expressões faciais, são apresentados e logo após, são apresentados conceitos sobre a emoção e sua relação com a aprendizagem. Posteriormente, é discutido a importância dos Sistemas Tutores Inteligentes (STI) utilizarem *feedbacks* na aprendizagem.

### 2.1 NEURÔNIOS, SISTEMA NERVOSO E EMOÇÃO

O sistema nervoso é um dos mais importantes do corpo, sendo responsável pela coordenação das ações, informações sensoriais e pela transmissão de sinais em partes do corpo, possibilitando assim perceber eventos externos e reagindo da melhor forma a tais estímulos (Tortora e Derrickson, 2018). Isso é possível através dos neurônios, um tipo específico de célula que tem como objetivo realizar a identificação, processamento e reação aos eventos (Bear et al., 2020; Kandel et al., 2014).

#### 2.1.1 Neurônios e Sinapses

No ano de 1873, Camillo Golgi conduziu experimentos que utilizavam cromato de prata e amostras de tecidos neural e verificou que apareciam neurônios com coloração escura, uma técnica hoje conhecida como coloração de golgi (Figura 2.1a) (Bear et al., 2020). Nas últimas décadas, outras técnicas foram desenvolvidas para observar neurônios e permitiram visualizações mais detalhadas destas células, como na Figura 2.1b que exibe uma imagem de dois neurônios encostados, coletada usando microscópio eletrônico (Hubel, 1988). Porém, a coloração de Golgi possibilitou a identificação de uma região inchada, que hoje é conhecida como corpo celular, pericário ou soma, e diversos tubos pequenos, conhecidos hoje como neuritos, que são formados por dendritos e axônios com bainha mielina, que é uma gordura que age como isolante elétrico, ou não, e podem entrar em contato com outros neurônios e realizar a sinapse química ou elétrica (Figura 2.1c) (Bear et al., 2020).

As sinapses também acontecem entre neurônio e fibras musculares, ocorrendo assim o estímulo necessário para o controle de membros e outras partes do corpo, e isso é possível graças aos neurônios motores e seu axônios prolongados, a chamada sinapse neuromuscular (USP, 2022) (Figura 2.1d). No sistema nervoso, uma sinapse é a passagem de sinal elétrico ou químico entre dois neurônios ou entre um neurônio e outra célula nervosa, e seu processo com detalhe pode ser acompanhado na Figura 2.1e. O impulso nervoso chega pelo axônio do neurônio e com o acúmulo de neurotransmissores e elementos químicos (como sódio e potássio), o rompimento da membrana do axônio ocorre, transferindo-os para a fenda sináptica e são coletados pelos receptores da outra célula nervosa (Teixeira, 2012);

Hoje é sabido que o sistema nervoso possui bilhões de neurônios que têm como objetivo processar e transmitir informações para todo o corpo através de sinais eletroquímicos (Lent et al., 2012; Pakkenberg e Gundersen, 1997; Courchesne et al., 2011). Estes sinais são transmitidos através da sinapse, que é a troca de elementos químicos, tais como sódio e potássio quando acontece o contato entre dois ou mais neurônios (Bear et al., 2020).

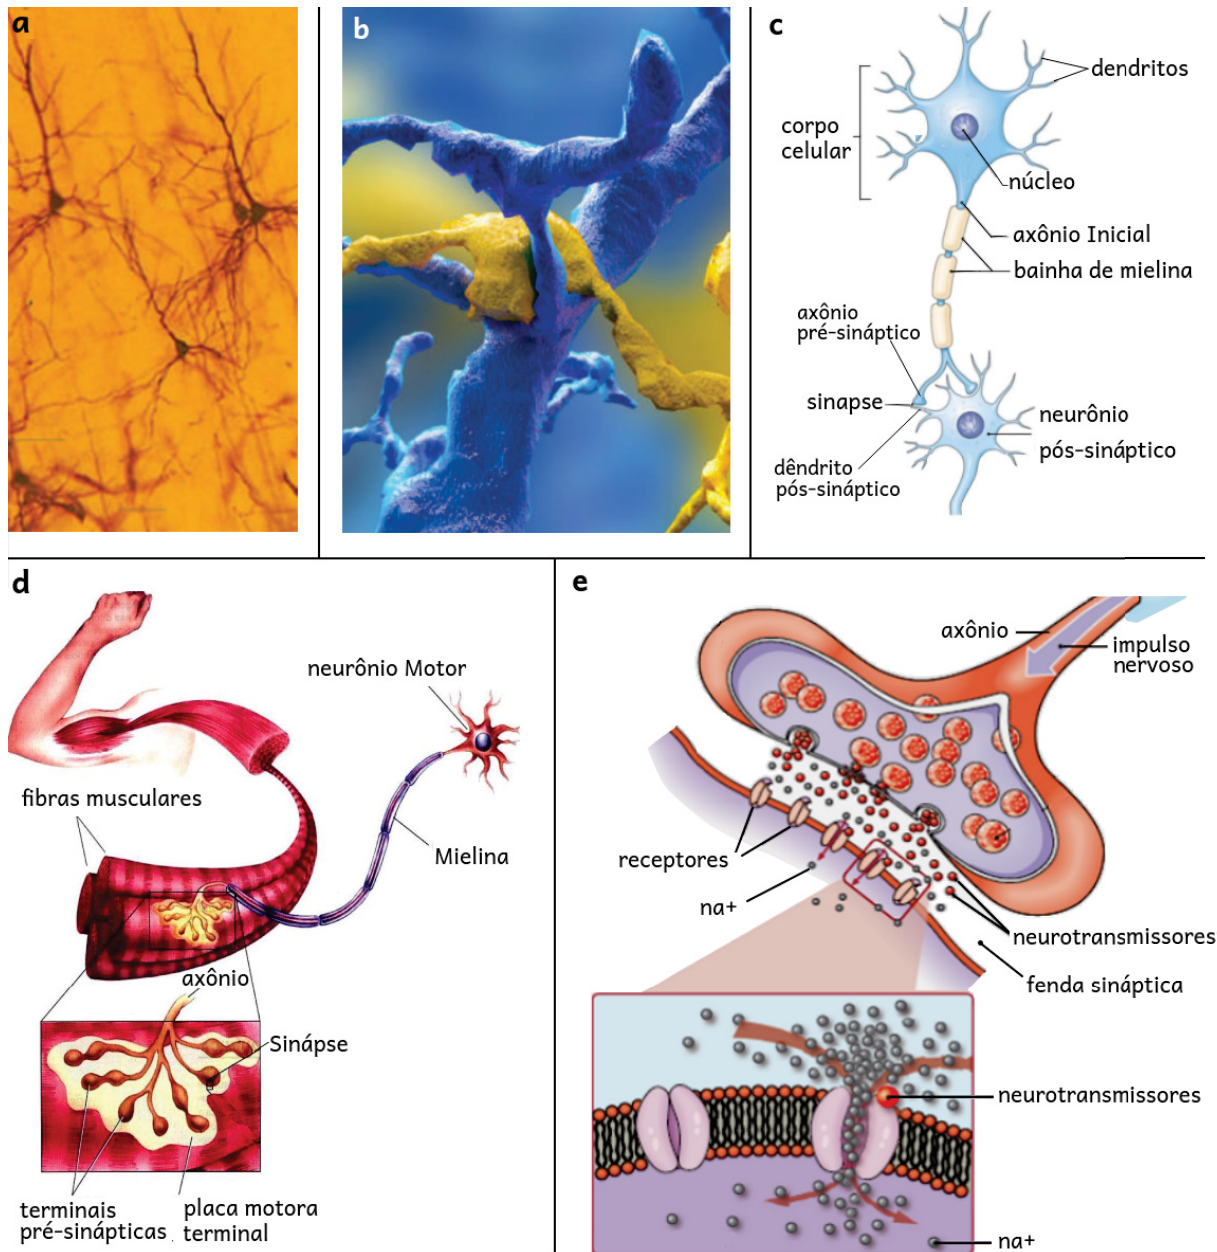


Figura 2.1: Neurônios e sinapses. **a.** Neurônios vistos através da coloração de Golgi no ano de 1873 (adaptado de Hubel (1988)); **b.** Axônio (amarelo) e dendrito (azul) coletado por microscópio eletrônico (adaptado de Norton (2013)); **c.** Partes do neurônio (adaptado de Silverthorn (2010)); **d.** Sinapse neuromuscular (adaptado de USP (2022)); **e.** Detalhes do processo da sinapse química (adaptado de Teixeira (2012)).

Fonte: Adaptado de Hubel (1988); Norton (2013); Silverthorn (2010); USP (2022); Teixeira (2012).

### 2.1.2 Sistema Nervoso Periférico e Central

Os neurônios constituem os nervos, gânglios e terminações nervosas do sistema nervoso, que está dividido em duas partes, o Sistema Nervoso Periférico (SNP), responsável por enviar ou receber informações sensoriais de cada parte do corpo e pela interligação com a segunda parte do sistema nervoso, que é chamado de Sistema Nervoso Central (SNC) (Kandel et al., 2014). O SNC é a parte principal do sistema nervoso responsável por receber as informações do SNP, realizar o processamento e enviar impulsos também ao SNP (Figura 2.2).

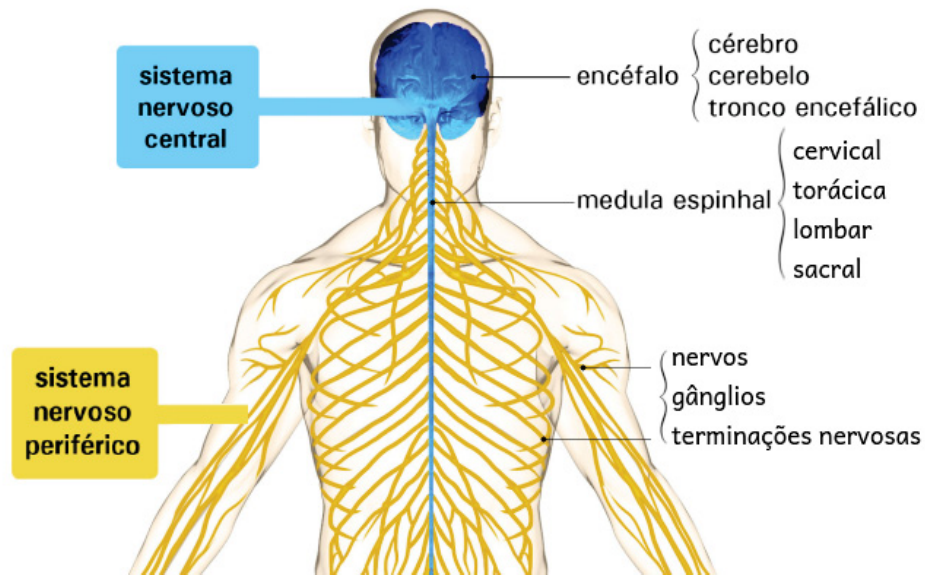


Figura 2.2: Divisão do Sistema Nervoso Central (SNC) em duas partes: Medula Espinhal e Encéfalo.  
 Fonte: Adaptado de Junior e Visconti (2014) e Kandel et al. (2014).

O SNC possui duas partes: a medula espinhal, responsável pelo recebimento e processamento inicial da informação sensorial da pele, dos músculos e articulações das pernas e braços e do tronco e é dividida em quatro regiões, cervical, torácica, lombar e sacral e é protegida pela coluna vertebral, e o encéfalo, a parte principal do SNC, responsável pelo processamento da informação pelo instinto de sobrevivência, controle motor, emoções, imaginação, criatividade, raciocínio lógico, tomada de decisão, sentidos (audição, visão, olfato, paladar e tato) e demais processamentos cerebrais, é dividida em tronco encefálico (bulbo, ponte e mesencéfalo), cerebelo e cérebro (telencéfalo, corpo caloso e diencéfalo) e é protegida pela caixa craniana (Bear et al., 2020; Kandel et al., 2014). Com o avanço das técnicas de formação de imagens da anatomia e dos processos fisiológicos do corpo, tal como a Ressonância Magnética Funcional (fMRI, do inglês, *Functional Magnetic Resonance Imaging*), foi possível entender com mais detalhes a estrutura do encéfalo (Valadares e Araújo, 2007). A Figura 2.3(1) exibe uma imagem da estrutura do encéfalo coletada utilizando técnica de fMRI, e a Figura 2.3(2) exibe as partes que compõem o encéfalo.




Figura 2.3: Estrutura do Encéfalo. **a.** Imagem da estrutura do encéfalo coletada com fMRI; **b.** Nome das partes da estrutura do encéfalo.

Fonte: Adaptado de Kandel et al. (2014).

O **tronco encefálico** conecta a membrana espinhal através do **bulbo**, que tem funções referentes à respiração, digestão, controle de batimentos do coração e da pressão arterial, e está envolvido com a mastigação, fala, piscada de olhos, movimentos intestinais, lágrimas e vômito. A **ponte** transmite informações dos movimentos dos hemisférios cerebrais para o **cerebelo**. O **mesencéfalo** (do latim, "cérebro médio"), controla funções sensoriais e motoras, tais como movimento dos olhos, coordenação dos reflexos visuais e auditivos (Kandel et al., 2014).

O **cerebelo** (do latim, "cérebro pequeno") modula a força e a intensidade do movimento e está relacionado com a aprendizagem das habilidades motoras. É um centro para o controle do movimento e possui conexões com o cérebro e a medula espinhal (Bear et al., 2020).

O **cérebro** é constituído pelas estruturas **telencéfalo** e **diencéfalo** (Toledo e Nogueira, 2021; Bear et al., 2020; Kandel et al., 2014). O **telencéfalo** é formado pelos lobos frontal, parietal, occipital e temporal 2.4a (Bear et al., 2020; Kandel et al., 2014). O lobo frontal é responsável pelos movimentos voluntários do corpo, linguagem, gerenciamento das habilidades cognitivas, controle comportamental e emocional e pela personalidade. O lobo parietal está envolvido com a integração das informações sensoriais, como toque, temperatura, pressão e dor, assim como avaliar tamanho, forma, distância, interpretação dos símbolos, audição, percepção visual e memória. O lobo occipital é responsável pela percepção visual, incluindo cor, forma e movimento. E o lobo temporal ajuda no processamento de informações auditivas, codificação da memória, processamento de afeto, percepção visual, compreensão da linguagem, no aprendizado e na lembrança de informações verbais e não-verbais como a música (Bear et al., 2020). O telencéfalo é formado pelo hemisférios esquerda e direito, onde cada lado controla o lado inverso do corpo 2.4b e cada lobo tem seu correspondente no outro hemisfério. Dentro do telencéfalo existe a substância cinzenta e a branca 2.4c, onde a cinzenta é formada por uma concentração alta de neurônios com seus axônios sem bainha de mielina, formando o córtex (do latim, "casca") cerebral, responsável pela cognição superior, como atenção, aprendizagem, memória, motivação, tomada de decisão, habilidade de abstração e solução de problemas. A substância branca é formado por axônios que possuem a bainha de mielina, formando uma gordura mais clara e sua função é conectar informações entre córtex e as demais estruturas (Kandel et al., 2014).




Figura 2.4: Telencéfalo. **a.** Vista lateral e identificação dos lobos; **b.** Vista superior e identificação dos hemisférios; **c.** Vista do corte transversal com identificação do córtex e das substâncias.

Fonte: Adaptado de Toledo e Nogueira (2021).

O **diencéfalo** (do latim, "entre encéfalos") é formado pelo tálamo, responsável pela regulação do sono, estado de alerta e consciência, além de transmitir sinais sensitivos e motores ao córtex, pelo epitálamo, responsável a liberação de melatonina e como a energia é conservada pelo corpo e pelo hipotálamo, responsável pelo comportamento, memória de longo prazo e é um centro para **sistema límbico**, relacionado ao córtex do lobo frontal, que é responsável pelo raciocínio lógico e resolução de problemas e está relacionado com a memória, aprendizado, motivação e **emoção** (Kandel et al., 2014).



### 2.1.3 Emoção e Resposta Afetiva

Definir emoção é um problema notório (Frijda, 2007). Segundo Scherer (2005), a definição de emoções tem sido um desafio constante para pesquisadores da emoção em diferentes disciplinas das ciências sociais e comportamentais durante um longo período de tempo. A emoção é um fenômeno comportamental complexo que envolve muitos níveis de integração neural e química (Lindsley, 1951). A palavra emoção é derivada do termo "*emovere*" do latim, que pode significar algo como "colocar em movimento", o que nos mostra que desde sua origem a definição de emoção está ligada à expressão fisiológica visível relacionada a um evento (Elnicki, 2010). Sentimento e emoção podem ser vistos como coisas distintas, onde sentimento refere-se à experiência subjetiva da emoção (Munezero et al., 2014).

Quando se fala em resposta afetiva, duas teorias cognitivas se destacam, que são a teoria cognitiva Schachter-Singer e Cannon-Bard e a teoria James-Lange (Bear et al., 2020; Broekens e Degroot, 2004). A teoria cognitiva, de Schachter-Singer, entende que as emoções são respostas fisiológicas do corpo a uma interpretação cognitiva de uma situação vivida pela pessoa. Assim sendo, os autores assumem que a emoção ocorre após o processamento mental envolvido com a situação e seria derivada deste. Neste caso, primeiro vêm a interpretação da situação emocional e depois a reação corporal, conforme a teoria Cannon-Bard (Bear et al., 2020). Já a teoria de James-Lange assume que a reação fisiológica relacionada a uma emoção é responsável pelo sentimento percebido pelo cérebro sobre aquela emoção. Assim, primeiramente o ser humano perceberia uma situação em nível inconsciente. Esta percepção geraria uma resposta fisiológica e através desta criado no cérebro um sentimento que a identificaria em nível consciente (Broekens e Degroot, 2004).

Baseado na teoria de Schachter-Singer e James-Lange, James Papez apresentou uma teoria que ligava o hipotálamo ao córtex, e a chamou de "sistema da emoção" (Bear et al., 2020). A Figura 2.5 exhibe à direita algumas estruturas do sistema límbico que formam o circuito de Papez, e à esquerda, o diagrama. Acreditava-se que uma emoção era determinada através da ativação no córtex cingulado, e que a expressão emocional era controlada pelo hipotálamo. O córtex cingulado está relacionado com o hipocampo, que está associado ao hipotálamo através de axônios de neurônios (fórnice). A saída do hipotálamo vai para o córtex através e assim o circuito finaliza.

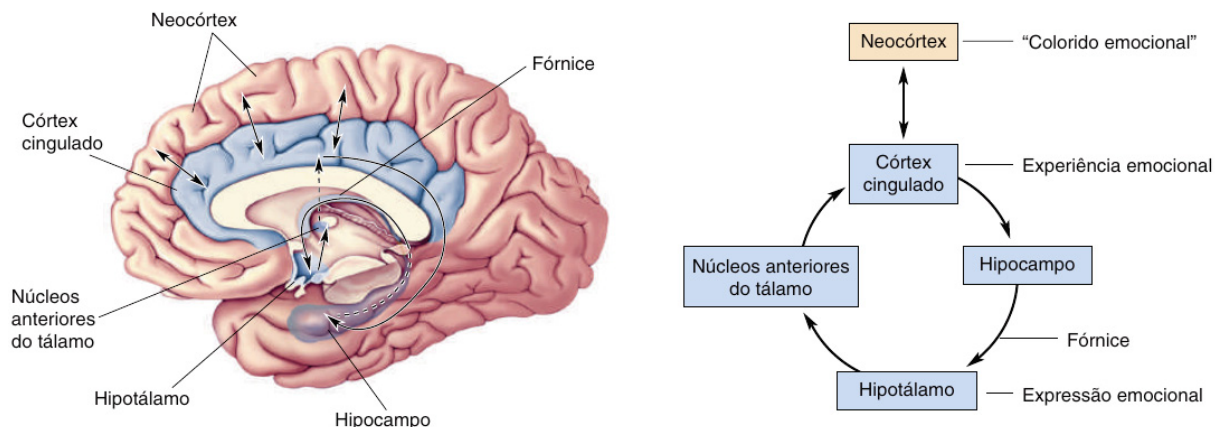


Figura 2.5: O circuito de Papez.

Fonte: Adaptado de Bear et al. (2020).

Neste circuito, o neocórtex e o hipotálamo estão intimamente ligados, conectando assim a expressão e a experiência da emoção. O córtex cingulado ativa o hipotálamo por meio do hipocampo e do fórnice, e o circuito fecha quando o hipotálamo atinge o córtex cingulado por meio do tálamo anterior. O circuito de Papez é compatível com as teorias de James-Lange e Cannon-Bard pois o contato entre córtex e hipotálamo é bidirecional (Bear et al., 2020).

LeDoux (1994) estudou a base neural da memória emocional em ratos usando o condicionamento do medo no caso de um som associado a um choque nas patas, que leva a uma postura de congelamento, comparável ao experimento de condicionamento de Pavlov. Em combinação com estudos de lesões nesses ratos, eles projetaram um modelo para dois circuitos de medo separados, mas inter-relacionados, que induzem a resposta de medo, chamadas de via lenta e via rápida (Figura 2.6). Os modelos de LeDoux podem explicar por que às vezes pessoas agem antes de pensar.

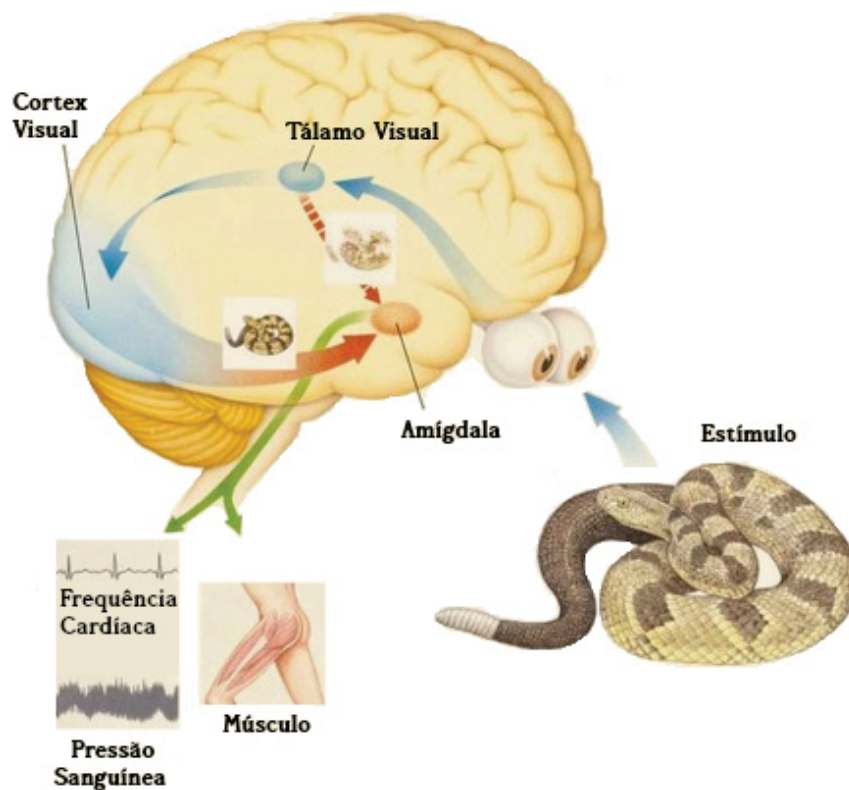


Figura 2.6: Vias corticais e subcorticiais. Via lenta e via rápida.

Fonte: Adaptado de LeDoux (1994).

Um estímulo visual é processado pelo tálamo e vai direto para a amígdala. Essa transmissão rápida permite que o cérebro comece a responder ao possível perigo, como aumento da frequência cardíaca, aumento da pressão sanguínea e contração muscular (reação de luta ou fuga). Enquanto isso, o córtex visual também recebe informações do tálamo. Através deste caminho é determinado se é realmente uma cobra que é vista. Essa informação é passada para a amígdala e, se for mesmo uma cobra, a resposta de medo do corpo aumenta. No caso de o estímulo visual ser um alarme falso e, portanto, nenhuma cobra, mas, por exemplo, uma vara de madeira, a mensagem para a amígdala suprimirá a resposta de medo (LeDoux, 1994).

A via rápida também é chamada de via direta. A informação dos órgãos dos sentidos, como nariz, orelhas, pele, olhos, língua, passa diretamente do tálamo para a amígdala através da via tálamo-amígdala inconsciente (LeDoux, 1994, 1996). A via lenta também é chamada de via indireta, com o hipocampo e o córtex em seu núcleo. Depois que a informação sensorial

entra no tálamo, essa informação é enviada para os circuitos hipocampal e cortical para avaliação posterior. Essa resposta é mais lenta, porque envolve mais transmissão sináptica e a percepção consciente está envolvida. Os córtices sensoriais, em conjunto com outras regiões do cérebro, como o hipocampo, para-hipocampo, associação e córtices pré-frontais, atribuem significado aos estímulos sensoriais com base no contexto e na experiência anterior (Bruggeman-Everts, 2010).

As reações emocionais não são tão simples como resposta estrutural como se acreditava há pouco tempo (Damásio, 2015). As atuais técnicas de neuroimagem permitiram verificar que diversas estruturas estão envolvidas no processamento de uma emoção. Em seu trabalho "O erro de Descartes", o neurocientista Antônio Damásio (Damasio, 2008), descreve como as emoções são importantes como mecanismos de sobrevivência e aprendizado humano. Em seu livro "O mistério da Consciência", Damásio (2015) identifica a relação entre a resposta emocional e a atribuição de pensamentos conscientes sobre situações específicas vividas pelo ser humano. O autor elabora uma posição naturalista biológica capaz de transformar o "mistério" em um "problema de consciência". Dividir emoções em categorias básicas e complexas também é uma maneira de se entender melhor as emoções, em que algumas emoções são consideradas fundamentais para a existência de outras (Ekman et al., 2013).

## 2.2 EXTRAÇÃO DE EMOÇÕES

Os maiores esforços feitos pela comunidade interessada em emoções estão relacionados com a extração e padronização das emoções. Uma maneira para se fazer tal estudo pode ser dividida em duas partes: (1) indução de estímulos e (2) Extração da emoção estimulada (Bradley e Lang, 2000). A indução de estímulos é provocada por algum artefato manipulável como imagens, sons e palavras, que possuam variações positivas (por exemplo, imagem agradável) e negativas (por exemplo, imagem desagradável). Estes artefatos irão provocar comportamentos biológicos externos e internos em uma determinada pessoa. A Figura 2.7 exhibe as principais maneiras de se extrair emoções.




Figura 2.7: Técnicas de extração de emoções. **a.** cognitivo ou experiencial-subjetivo, **b.** neurofisiológica e bioquímica e **c.** Motor ou comportamental-expressivo.

Fonte: Adaptado de Soares et al. (2011).

Soares et al. (2011) explica que a extração da emoção estimulada é o ato de quantificar uma emoção induzida e cita três tipos mais utilizados de medição das emoções:

1. Cognitiva ou experiencial-subjetivo: não há contato físico com o usuário. Esse método, descrito por Bradley e Lang (1994), é desenvolvido através de atribuições cognitivas do que a pessoa achou de um determinado estímulo, baseado em experimentos laboratoriais com voluntários que se submetem a ver ou escutar alguns estímulos e depois relatá-los,

conforme demonstram estudos realizados para o desenvolvimento de um instrumento que facilita o relato emocional chamado *Self-Assessment Manikin (SAM)*, exibido na Figura 2.7a.

2. Neurofisiológica e bioquímica: se enquadram os equipamentos de contato direto com o corpo como EEG (ondas cerebrais), medição de temperatura, tensão muscular, ritmo cardíaco, pulsação sanguínea, ritmo respiratório, etc. (Figura 2.7b);
3. Motor ou comportamental-expressivo: está relacionado com o reconhecimento de padrões faciais, conhecido pelos trabalhos de Paul Ekman (Ekman et al., 1987), que identificou as seis emoções básicas em um trabalho para comparações emocionais (Figura 2.7c).

Nas próximas seções, são abordadas de forma mais detalhadas as técnicas apresentadas na Figura 2.7.

### 2.2.1 O Modelo Circumplexo do Afeto

Russell (1980) apresentou seu Modelo Circumplexo de Afeto, que propõe que todos os estados afetivos resultam de dois sistemas neurofisiológicos fundamentais, que são as dimensões Prazer (*valence*), relacionada à *valence* (agradável-desagradável), e *arousal*, relacionada à excitação (alerta). Nesse modelo, as emoções são distribuídas em um espaço circular bidimensional, onde a Ativação representada no eixo vertical e o Prazer no eixo horizontal (Nogueira, 2018). A Figura 2.8 exhibe o Modelo Circumplexo de Afeto.

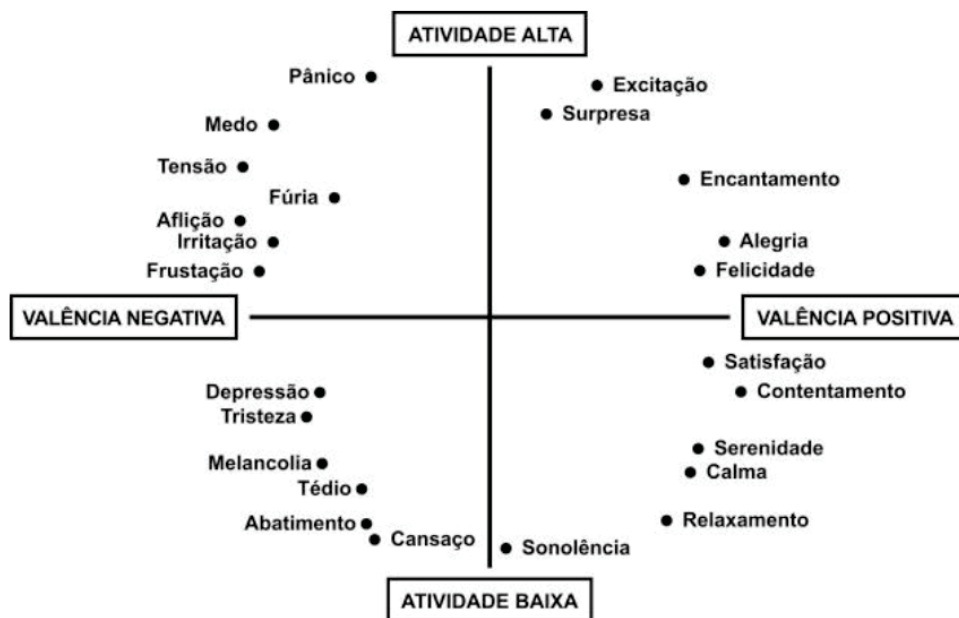


Figura 2.8: Modelo Circumplexo de Afeto de Russell (1980).

Fonte: Adaptado de Nogueira (2018).

Conforme visto, este modelo representa emoções ao longo de escalas semânticas diferenciais, onde uma escala (eixo X) é a variação de agradabilidade (*valence*) e a outra escala (eixo Y) é a variação de ativação em que uma pessoa se encontra (*arousal*). Por exemplo, uma pessoa que está se sentindo agradável e com ativação alta, presume-se que está alegre, se está desagradável e ativação alta, possivelmente está com raiva ou com medo, ou se está desagradável e com ativação baixa, presume-se que a pessoa está triste.

### 2.2.2 Ferramenta SAM e Biblioteca IAPS

O SAM (do inglês, *Self-Assessment Manikin*) é um instrumento bastante utilizado para a obtenção dos valores de *valence* e *arousal* (Lang, 1980). É formado por três grupos de bonecos impressos em papel ou em ambiente web (Oliveira et al., 2010), representando a resposta do usuário em cada dimensão da emoção. O primeiro grupo de bonecos representa a dimensão *valence*, o segundo grupo representa a dimensão *arousal* e o terceiro grupo representa a dimensão *dominance*. A escala de variação é graduada em dez divisões, sendo cinco representadas por bonecos e as outras cinco representadas por espaços entre dois bonecos vizinhos. Para realizar a marcação corretamente, uma vez que a representação dimensional não é intuitiva para a maior parte das pessoas, é necessário que um conjunto de instruções claras sobre o procedimento sejam repassadas aos voluntários antes do início do procedimento (Lang, 1980). O SAM possui boas qualidades psicométricas e é um instrumento válido de acordo com suas classificações de *valence* e *arousal*, que estão correlacionadas com o modelo de afeto (Mehrabian e Russell, 1974).

Para que estímulos específicos fossem estudados, Lang e Bradley (2007), apresentou uma biblioteca de imagens com centenas de fotografias coloridas que representam vários aspectos da realidade (esportes, moda, paisagens, violência, etc.) com seus respectivos valores de *valence*, *arousal* e *dominance* chamada IAPS (do inglês, *International Affective Picture System* (Lang e Bradley, 2007). Esta biblioteca é disponibilizada através de solicitação direta aos pesquisadores do centro para estudos de emoção e atenção da Universidade da Flórida (Bradley e Lang, 2022) e não pode ser divulgada, exceto durante os experimentos e suas avaliações foram realizadas utilizando SAM em ambientes controlados (Lang et al., 2005).

Para ilustrar o funcionamento do IAPS, apresenta-se a Figura 2.9, contendo três imagens com estímulos distintos à esquerda, onde a primeira imagem é de uma pessoa pulando de *bung jump*, a segunda imagem exibe uma cobra naja em um mato e a terceira, mostra um cemitério. Do lado direito da Figura 2.9, há suas respectivas posições representadas com um ponto preto no plano *valence* e *arousal*, com seus eixos exibindo o SAM.

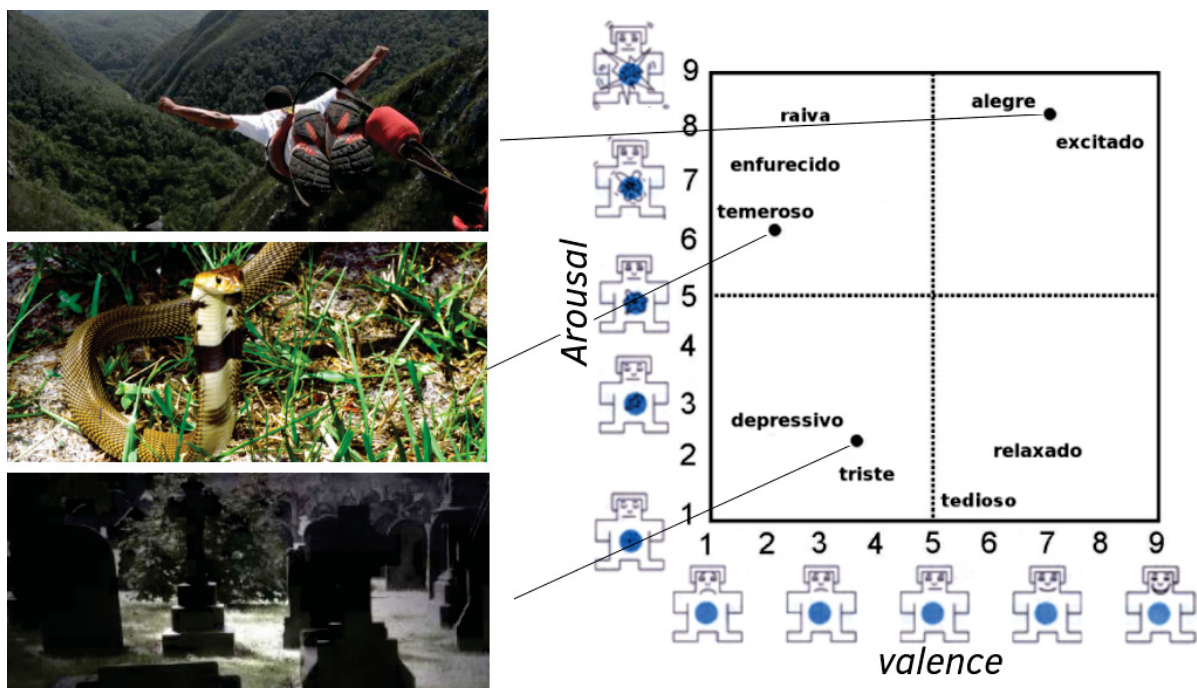


Figura 2.9: Exemplos de Imagens e seus respectivos valores afetivos (*valence* e *arousal*)

Fonte: Adaptado de Oliveira et al. (2010); Lang e Bradley (2007).

Neste exemplo, o nível de agradabilidade da imagem é um pouco desagradável, e sua ativação também é baixa. Inserindo os valores no gráfico *valence* e *arousal*, nota-se que o valor afetivo desta imagem estaria localizada entre a depressão e a tristeza, de acordo com a imagem do lado direito da Figura 2.9 (Lang e Bradley, 2007). Isso é um exemplo de uma imagem que estimula uma emoção específica em uma pessoa.

Para validar os dados do IAPS, foram utilizados experimentos de fMRI que correlacionam a ativação das estruturas do sistema límbico com os valores de *valence* e *arousal* do IAPS (Lang et al., 1998; Bradley et al., 2003; Sabatinelli et al., 2005, 2006, 2007). Por exemplo, Sabatinelli et al. (2005) explica que os estímulos emocionais levam estão relacionados com o aumento da ativação da amígdala e do córtex visual, e fazem um estudo onde medem a atividade funcional no córtex visual e na amígdala com fMRI, enquanto participantes visualizam algumas imagens neutras, e outras relevantes para o medo, e sugerem uma relação linear positiva entre a qualidade dos estímulos visuais e a ativação na amígdala e no córtex visual, apoiando assim a hipotética conectividade funcional descrita no modelo animal.

Exemplos de imagens de fMRI com estruturas cerebrais sendo ativadas de acordo com estímulos visuais podem ser vistos na Figura 2.10, que exibe cinco imagens de fMRI onde cada uma representa a emoção específica (alegria, tristeza, raiva, medo e desgosto) e suas respectivas ativações ocorridas.




Figura 2.10: Ao exibir uma imagem do IAPS, há uma ativação na amígdala, hipocampo, giros para-hipocampais, Córtex pré-frontal e córtex visual.

Fonte: Adaptado de Bear et al. (2020).

Para cada emoção, a intensidade da ativação das estruturas cerebrais está indicada por cores, onde o amarelo é maior que o vermelho. Pode-se dizer que a atividade da amígdala está mais associada ao **medo** que à tristeza, e a atividade do córtex pré-frontal medial está mais associada à **tristeza** (Bear et al., 2020). A amígdala é ativada em situações positivas como **alegria** e o cerebelo também relaciona-se tanto ao sorriso quanto ao choro. A alegria ativa os gânglios basais, também relacionados ao **desgosto**, que recebem uma grande intervenção de neurônios dopaminérgicos através circuito mesolímbico que conecta o mesencéfalo ao sistema límbico. Já a **raiva** tem como estrutura principal o hipotálamo, e o córtex age como inibidora desta emoção e assim como no medo, a amígdala está relacionada com a raiva (Esperidião-Antonio et al., 2008).

Diversos estudos na área de utilizaram as imagens da biblioteca IAPS para estimular seus participantes com uma emoção específica (Aldhafeeri et al., 2012; Pfaff et al., 2019; Hartling et al., 2021; Bo et al., 2019). No geral, os voluntários são convidados a entrarem em uma máquina de fMRI, e imagens do IAPS são apresentadas a eles dentro do equipamento, e assim, realiza-se o *scanner* para coleta da ativação cerebral em forma de imagem.

### 2.2.3 Eletroencefalograma (EEG) e *Brain-Computer Interface* (BCI)

O corpo produz fenômenos elétricos que acontecem em neurônios ou células musculares chamados de biopotenciais, que podem ser percebidos em algum lugar fora da célula em lugares distantes de sua origem, e por conta disso, são muito importantes para a compreensão do funcionamento de órgãos e sistemas biológicos (Prutchi e Norris, 2005).

Estes biopotenciais podem acontecer no encéfalo, no coração, nos músculos, nos olhos entre outros. O Eletroencefalograma (EEG) captura o biopotencial que acontecem nos neurônios do encéfalo (Blinowska e Durka, 2006). O Eletrocardiograma (ECG) obtém sinais elétricos da atividade celular gerada pelo músculo cardíaco (Mirvis e Goldberger, 2001). O Eletromiograma (EMG) captura biopotenciais gerados nas fibras musculares (Mills, 2005). E o Eletrooculograma (EOG) captura biopotenciais de atividade elétrica ocular (Tsang e Sharma, 2018).

O EEG mede as alterações de tensão elétrica dos neurônios do encéfalo (Henry, 2006). Clinicamente, o EEG refere-se ao registro da atividade elétrica espontânea do cérebro durante um período de tempo, conforme registrado a partir de eletrodos distribuídos no escalpo em posições que seguem o Sistema Internacional 10-20 (Jasper, 1958; Sazgar e Young, 2019). A Figura 2.11 exhibe as posições atuais dos eletrodos de acordo com este sistema.

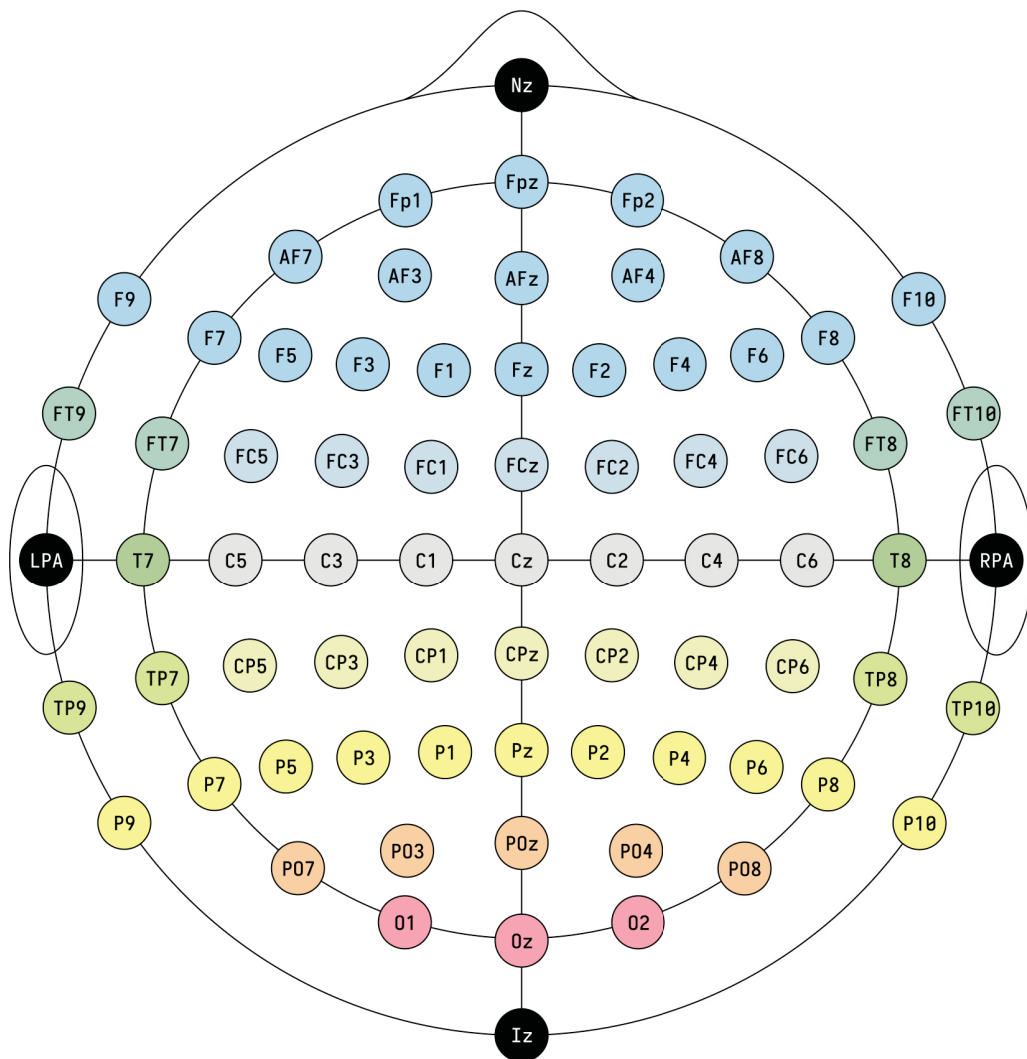


Figura 2.11: Posições atuais do Sistema Internacional 10-20.  
Fonte: Adaptado de Sazgar e Young (2019).

Cada eletrodo possui uma nomenclatura que mistura uma ou mais letras com um número, exceto os pontos pretos LPA e RPA que são os pré-auricular esquerdo e direito (do inglês, *Left e Right Pre-Auricular*). O Nz está localizado acima da narina chamado nácio (ou nasion) e o Iz está localizado na nuca, chamado ínio (inion). A letra z representa o centro vertical.

Os números ímpares estão no hemisfério esquerdo e números par, no hemisfério direito e quanto mais próximo do centro vertical, menor é o número e vice-versa. A letra z representa os eletrodos que estão no centro vertical. As cores dos eletrodos seguem o padrão da Figura 2.4, onde o azul é o lobo frontal, o amarelo é o lobo parietal, o rosa é o occipital e os verdes, lobo temporal. As letras estão relacionadas aos lobos, de acordo a lista abaixo:

- Fronto-polar (Fp1, Fpz e Fp2)
- Intermediação Anterior-Frontal (AF7, AF3, AFz, AF4 e AF8)
- Frontal (F9, F7, F5, F3, F1, Fz, F2, F4, F6, F8 e F10)
- Intermediação Fronto-Central (FC5, FC3, FC1, FCz, FC2, FC4 e FC6)
- Central horizontal (C5, C3, C1, Cz, C2, C4 e C6)
- Intermediação Central-Parietal (CP5, CP3, CP1, CPz, CP2, CP4 e CP6)
- Parietal (P9, P7, P5, P3, P1, Pz, P2, P4, P6, P8 e P10);
- Intermediação Parietal-Occipital (PO7, PO3, POz, PO4 e PO8);
- Occipital (O1, Oz e O2);
- Intermediação Temporal-Parietal (TP9, TP7, TP8 e TP10);
- Temporal (T7 e T8);
- Intermediação Fronto-Temporal (FT9, FT7, FT8 e FT10).

O sistema recebeu o nome de 10-20 por utilizar valores de distância correspondentes a 10% ou 20% da seção do crânio, medidos a partir de pontos de referência (Jasper, 1958; Silverman, 1963), conforme ilustrado nas Figura 2.12.




Figura 2.12: Distância entre eletrodos no sistema 10-20. **a.** Visão lateral; **b.** Visão frontal; **c.** Visão superior.

Fonte: Adaptado de Jasper (1958).



O EEG é apenas uma das formas utilizados para coletar atividade elétrica cerebral, porém, um dos menos invasivos (Kawala-Sterniuk et al., 2021). Além do EEG, existem outras duas formas de realizar a coleta de biopotenciais cerebrais:

- o Eletrocorticograma (ECoG), é um método invasivo que consiste em uma camada de eletrodos colocada por cima do córtex exposto. Para isso, é necessária uma cirurgia para introduzir a camada (Miller et al., 2020);
- Registros intracorticais, método invasivo que usa microeletrodos implantados dentro do córtex, tais como Potencial de Campo Local (LFP, do inglês *Local Field Potential*) e *spikes* (potencial de ação) (Graumann et al., 2010).

A Figura 2.13a identifica a forma de aquisição de dados do EEG, do ECoG e das gravações intracorticais. E a Figura 2.13b apresenta o EEG, ECoG e gravações intracorticais tipo LFP e *spikes* com suas respectivas variações de tensão elétrica e frequência.




Figura 2.13: Três diferentes métodos para registro de atividade elétrica cerebral. **a.** EEG, ECoG e Gravações Intracorticais; **b.** Métodos não-invasivo e invasivos com suas respectivas tensões elétricas e frequências.

Fonte: Adaptado de Kawala-Sterniuk et al. (2021).

Os sinais de EEG são considerados lentos, variam de 5 a 300 µV em uma frequência menor que 100 Hz, porém, como já foi visto, podem ser registrados de forma não-invasiva. Os sinais de ECoG são menos lento um pouco, variando entre 0,01 a 5 mV com frequência menor que 200 Hz, sendo monitorados por eletrodos colocados na superfície do cérebro, que é algo invasivo e por fim, os eletrodos penetrantes são usados para registrar biopotenciais locais e estão abaixo de 1 mV com uma frequência menor que 200 Hz, e biopotenciais de ação, 500 µV em uma frequência entre 0,1 a 7 kHz (Fattahi et al., 2014).

Com o rápido desenvolvimento de tecnologias na área de observação de sinais elétricos cerebrais dentro da medicina e também do crescimento exponencial da ciência da computação e tecnologias digitais, houve uma combinação dessas duas áreas, dando origem à inovadoras ferramentas que podem agora realizar o processamento em tempo-real das atividades cerebrais, que são chamadas de Interfaces Cérebro-computador (BCI, do inglês, *Brain-Computer Interface*) (Vidal, 1977; Kawala-Sterniuk et al., 2021). Pesquisadores como Vidal (1977) foi um dos pioneiros na utilização do computador para realizar análises e processamento de sinais de EEG através de uma conexão com BCI, abrindo um campo muito amplo para pesquisas, que inclui médicos, neurocientistas e até cientistas da computação. Pode-se dizer que uma BCI é um dispositivo que faz uma conexão entre o cérebro de uma pessoa a um computador, decodificando em tempo-real os sinais de uma atividade cerebral.

Segundo Duffy et al. (1989), estes sinais (tensão elétrica) recebidos do BCI são pequenos e circundados por uma variedade de grandes potenciais elétricos, razão pela qual necessitam ser amplificados. O registro de uma atividade elétrica do cérebro requer um bom equipamento, técnicas de registro e interpretação adequada dos dados. O EEG padrão registra as diferenças amplificadas de potenciais (tensão elétrica) entre dois pontos no do couro cabeludo. Os sinais coletados podem ser visualizados em um plano 2D de acordo com o tempo, ou, no domínio do tempo (Figura 2.14) exhibe um exemplo de visualização de oito eletrodos.




Figura 2.14: Exemplo de oito sinais EEG (domínio do tempo). Fz, Cz, P3, Pz, P4, PO7, PO8, Oz.  
Fonte: Adaptado de Ramele et al. (2018).

Essas frequências são divididas em faixas ou bandas e nomeadas com nome de letras gregas: *delta* (0,1 a 3,5 Hz), *theta* (4 a 7,5 Hz), *alpha* (8 a 13 Hz), *beta* (14 a 30 Hz) e *gamma* (maior que 30 Hz), onde *delta* sendo por exemplo uma pessoa dormindo, *theta* sendo profundamente relaxado, *alpha* seria relaxado, *beta* seria alerta e focado e *gamma* seria alto desempenho (Nowack, 1995; Pandey et al., 2021). A Figura 2.15 exhibe as faixas de bandas com suas respectivas frequências.




Figura 2.15: Bandas de Frequência de Sinal EEG  
Fonte: Adaptado de Pandey et al. (2021).

Uma análise quantitativa muito utilizada consiste em determinar a composição de frequências do sinal do EEG, ou seja, transformar de domínio do tempo, formado por dois eixos, um representando o tempo (em milissegundos) e outro representando a amplitude calculado pela tensão elétrica em micro volts (Figura 2.16a) para domínio da frequência utilizando a transformada discreta de fourier (DFT, do inglês, *Discrete Fourier Transform*) que após o processamento, é apresentada em dois eixos, um representando a frequência em hertz e outro a amplitude do sinal que são as vezes em que uma determinada frequência foi decomposta (Figura 2.16b) (Ferrero et al., 1995).




Figura 2.16: Espectro EEG de canal único: **a.** um segmento do sinal EEG no domínio do tempo, **b.** o espectro do sinal de (a) no domínio da frequência usando DFT.

Fonte: Adaptado de Ferrero et al. (1995).

Uma das formas mais utilizadas e eficazes para realizar a decomposição de frequências de um sinal é a DFT. Qualquer sinal dependente do tempo pode ser dividido em uma coleção de senoides (Wang et al., 2014). Desta forma, gravações de EEG longas e ruidosas podem ser plotadas em um espectro de potência de frequência. Ao fazer isso, recursos ocultos podem se tornar aparentes. Ao adicionar todas as senoides após a DFT, o sinal original pode ser restaurado, de modo que nenhuma informação seja perdida (Wang et al., 2014). De acordo com Frigo e Johnson (1998), uma DFT pode ser descrita assim:

Suponha que  $x = [x_0, \dots, x_{N-1}]$  seja um vetor dimensional  $N$ . Seja  $\omega = \exp(-2\pi \frac{i}{N})$ . Então a DFT,  $c = F_N(x)$  é dada pela Equação 2.1.

$$c_k = \sum_{j=1}^N x_j \omega^{jk}. \quad (2.1)$$

Este processo retorna as frequências que compõem o sinal de entrada, obtendo assim os sinais agora no domínio da frequência. Desta maneira obtém-se o sinal do EEG, inicialmente no domínio do tempo e posteriormente no domínio da frequência. Estes dados podem ser agrupados nas bandas clássicas de interesse clínico (*delta, theta, alpha, beta* e *gamma*) para uma melhor compreensão e facilidade na comparação com valores normais contidos numa base de dados (Ferrero et al., 1995). E assim têm-se o espectro de potências, em que os componentes de frequências se ordenam nas abscissas e sua correspondente potência nas ordenadas (Sanei e Chambers, 2013).

## 2.2.4 Interface Cérebro-Computador Aberto (OpenBCI)

O OpenBCI é uma BCI de baixo custo e *Open Source* (OpenBCI, 2022a). Diversos estudos científicos utilizaram este aparelho para realizar seus experimentos de validação do OpenBCI em comparação a outros aparelhos e envolvendo análise de atividade cerebral, evidenciando a confiança perante a comunidade acadêmica (Rahma e Nurhadi, 2017; Samson et al., 2018; Gunawardane et al., 2019; Aldridge et al., 2019; Tae-Gyu, 2019; Albawardi et al., 2021). Para mais artigos científicos, a página oficial do projeto (OpenBCI, 2022b) disponibiliza todos os mais recentes estudos publicados em revistas e periódicos de grande credibilidade.

Para utilizar o OpenBCI, é preciso obter algumas partes do projeto, que são:

1. Equipamento eletrônico, composto pelos eletrodos e pela placa Cyton, que vem com um *dongle bluetooth* para comunicação;
2. *Headset* Ultracortex, a estrutura 3D que forma o *frame* que segura os eletrodos e a placa Cyton;
3. Renderização dos dados, que pode ser utilizando a interface gráfica do usuário (GUI, do inglês *Graphical User Interface* do projeto OpenBCI (que não foi utilizada no experimento deste trabalho, mas é apresentada para entendimento do funcionamento) ou diretamente pela biblioteca Brainflow (2022) que pode ser usado com a linguagem de programação python, entre outras.

### 2.2.4.1 Equipamento Eletrônico: Placa Cyton

O equipamento eletrônico principal é a placa Cyton, que usa o chip ADS1299 (ADS1299, 2022) para processar o sinal de EEG produzido pela *Texas Instruments*. Esta placa vem com oito canais e a transferência de dados EEG para computador funciona através de um *dongle* contendo o módulo *bluetooth 4.0* 802.15.1 (rfd22301, 2022). A alimentação é feita através de uma bateria, funcionando entre 3V a 12V. A estrutura da placa Cyton é exibida na Figura 2.17.




Figura 2.17: Parte eletrônica principal do OpenBCI: Placa Cyton, possui entradas para oito eletrodos e duas entradas para eletrodos utilizados para a terra e tem conexão sem fio via *bluetooth*.

Fonte: Adaptado de OpenBCI (2022a)

A placa Cyton é constituída por seis características:

- Front-end analógico de alta potência: AD1299 para processamento de sinal, o conversor analógico para digital de alto ganho e baixo ruído, resolução de canal de 24 bits e taxa de amostragem de até 16kHz;
- Acelerômetro: ST LIS3DH, acelerômetro de 3 eixos e saída de dados de 16 bits;
- 8 canais de entrada biopotencial: funciona para EEG, EMG e ECG. Possui o terra com ruído de modo-comum invertido, com eletrodos para serem posicionados nos lóbulos auriculares;
- Programável: tem o microchip PC32  $\mu C$  compatível com arduino com cinco pinos GPIO (do inglês, *General Purpose Input/Output*);
- Armazenamento SD local: com taxas máximas e portabilidade melhorada;
- Comunicação sem fio: RFDigital RFD22301, *bluetooth* de baixa energia, rádio de alta taxa de dados e compatível com arduino.

#### 2.2.4.2 Headset Ultracortex: estrutura 3D

O OpenBCI segue os padrões o sistema internacional 10-20, com possibilidade de configuração com até 35 eletrodos (2.18a) para localização de eletrodos através de uma estrutura 3D chamada Ultracortex (Ultracortex, 2022). Este provê vários arquivos que formam *headsets* de vários tamanhos para serem impressos em 3D (Apêndice 1). Para sua montagem, foi necessária a aquisição de uma impressora 3D para impressão e da impressão dos arquivos. Para sua impressão, foi utilizada a impressora 3D ClonerLab (Figura A.1 do Apêndice 1), para a impressão dos em arquivos 3D no formato STL (*Standard Triangle Language*). Foi impresso no material poliácido láctico (PLA, do inglês, *polylactic acid*), que é um dos polímeros mais utilizados nesse tipo de impressão, juntamente com o material ABS (*Acrylonitrile Butadiene Styrene*) e o formato PetG (feito com garrafa pet). Os arquivos depois de impressos são colados e montados, encaixando a placa Cyton, os eletrodos e as conexões via fios chamados *jumpers* 2.18b.

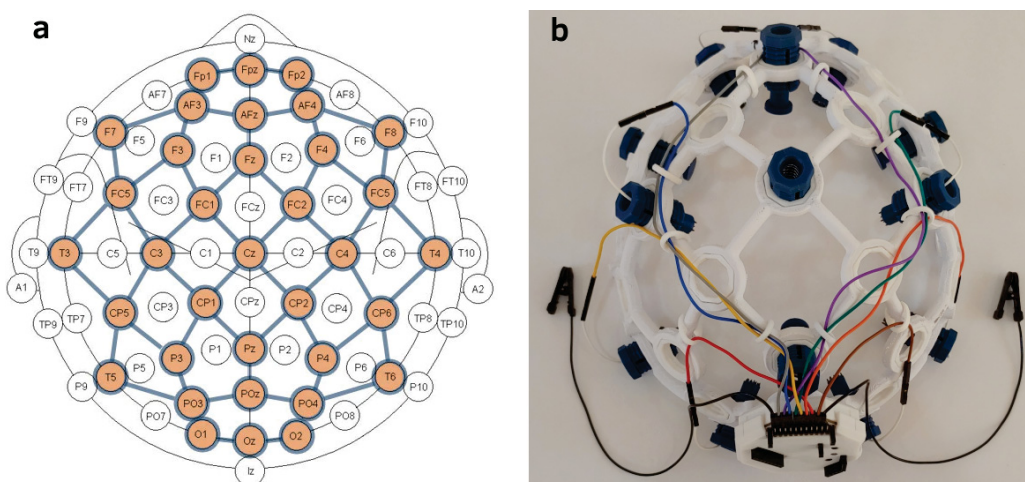


Figura 2.18: Ultracortex. **a.** eletrodos do OpenBCI seguem o sistema internacional 10-20. **b.** Ultracortex impresso e montado com a Placa Cyton, eletrodos e *jumpers* para conexão.

Fonte: Adaptado de Ultracortex (2022).

### 2.2.4.3 Processamento e renderização dos dados EEG

A placa Cyton envia os dados para o *dongle* via *bluetooth*, e assim, realiza-se o processamento dos sinais. A GUI do OpenBCI permite a visualização dos dados EEG de formas distintas, tal como sinais no domínio do tempo, sinais no domínio da frequência, a ativação de cada eletrodo na cabeça do voluntário, as bandas de potência, entre outras (OpenBCI, 2022a). Foi desenvolvida na linguagem *processing* e tem seu código aberto, possibilitando assim modificações. Esta GUI não foi utilizada neste trabalho mas apresenta-se para entendimento do funcionamento dos sinais de EEG. A Figura 2.19 mostra a interface gráfica do usuário do OpenBCI.

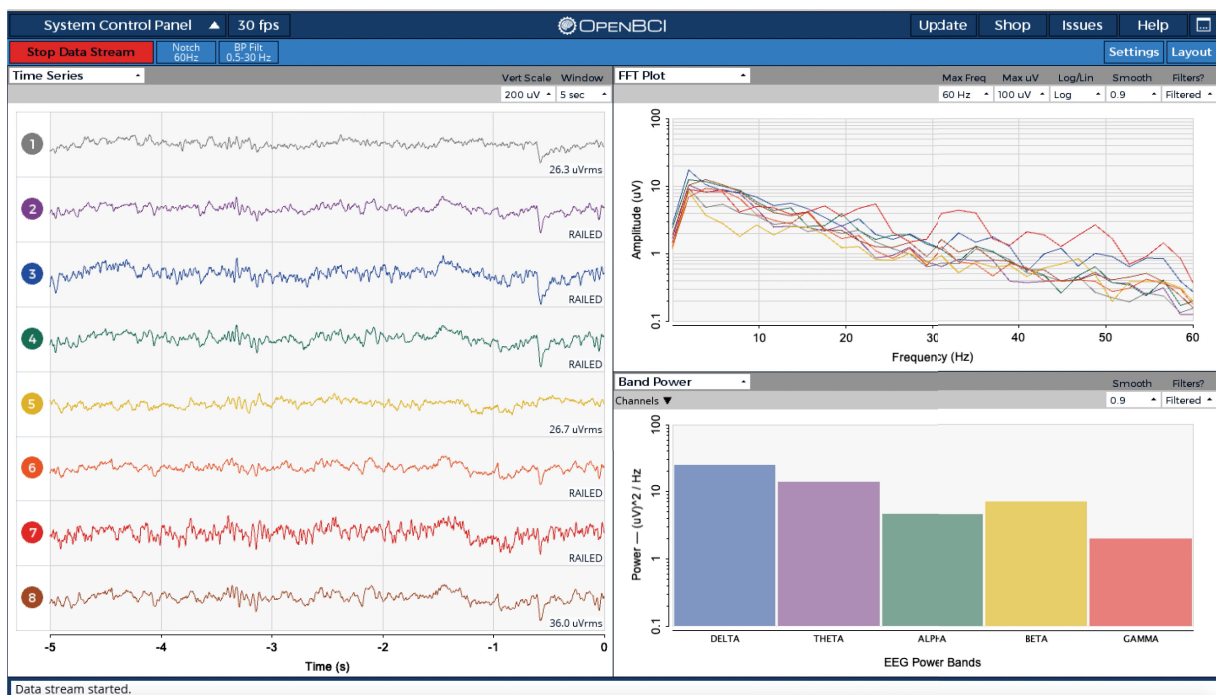


Figura 2.19: Interface Gráfica do Usuário do OpenBCI  
Fonte: Adaptado de OpenBCI (2022a).

Na esquerda, são exibidos oito canais do OpenBCI, representados em sinais no domínio do tempo. Do lado superior direito, são os sinais dos oito canais no domínio da frequência (que varia de 0Hz a 60Hz na GUI), que foi obtida através de Estimativas de densidade espectral de potência (PSD, do inglês *Power Spectral Density*) usando DFT implementada pela GUI (Matlab, 2022). E do lado inferior direito, o *powerband*, que é a separação da frequência do PSD em até cinco ondas cerebrais, que são delta (0.5 Hz a 4 Hz - dormindo), theta (4 Hz a 8Hz - relaxado profundamente), alpha (8 Hz a 13Hz - relaxado), beta (13 Hz a 30Hz - alerta e focado) e gamma (30 Hz a 55 Hz - alto desempenho) (Keizer, 2018).

A GUI utiliza uma biblioteca chamada *Brainflow* para análise de dados EEG, EMG, ECG e outros tipos de dados de biossensores (Brainflow, 2022). Ela fornece uma API de aquisição de dados uniforme para todas as placas suportadas, o que significa que pode alternar as placas sem nenhuma alteração no código e os aplicativos no topo do *Brainflow* são independentes da placa. Também há uma API para executar o processamento de sinal que pode usar mesmo sem o *headset* BCI e ambas APIs são as mesmas em todas as ligações.

### 2.2.5 Reconhecimento de Estados Afetivos e EEG

Conforme Alarcão e Fonseca (2019), para reconhecer emoções usando sinais de EEG, é necessário executar as seguintes etapas (Figura 2.20):

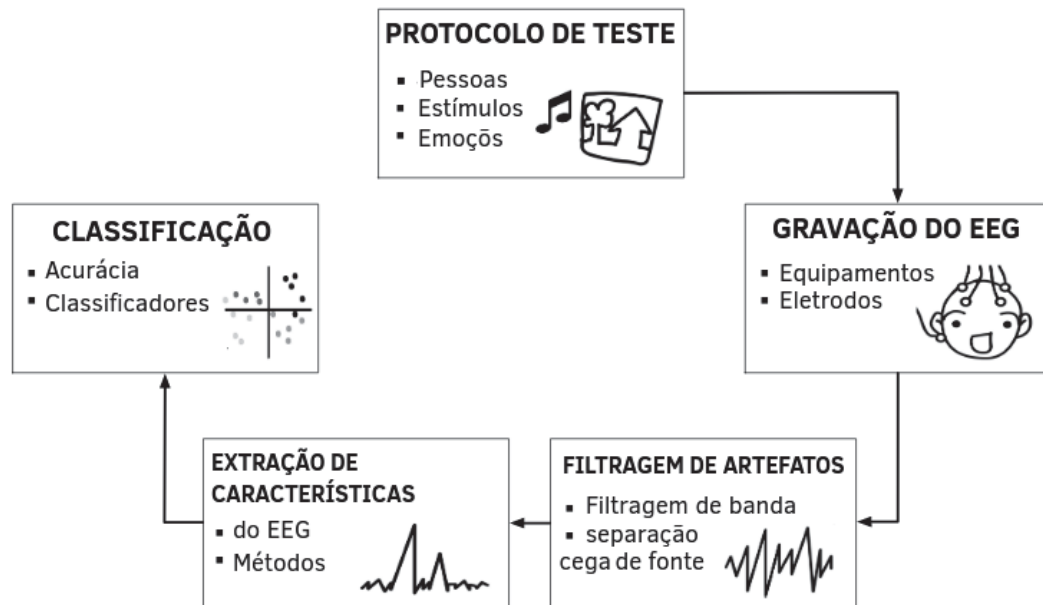


Figura 2.20: Processo de reconhecimento de emoções usando EEG

Fonte: Adaptado de Alarcão e Fonseca (2019).

1. A pessoa deve estar exposta ao estímulo com um valor emocional específico que está sendo testado;
2. As mudanças de tensão elétrica observadas no cérebro do usuário são registradas em um computador ou outro dispositivo de armazenamento;
3. Ruídos e artefatos dos sinais registrados são analisados e removidos através da aplicação de filtros de remoção;
4. Os dados resultantes são analisados e as características relevantes são extraídas para serem aplicadas na classificação;
5. Um classificador é treinado com base em um conjunto de treinamento e usando os recursos computados, levando à interpretação dos sinais cerebrais brutos originais.

Outra forma de se fazer o reconhecimento de emoções a técnica chamada *Frontal EEG Asymmetry* (FEA) (Palmiero e Piccardi, 2017; Pomer-Escher et al., 2014; Coan e Allen, 2004; Allen et al., 2004; Davidson, 2004) que consiste um modelo que argumenta que o aumento da atividade pré-frontal esquerda está associado a emoções relacionadas à aproximação (por exemplo, positivas), enquanto um aumento da atividade pré-frontal direita está associado a emoções relacionadas à retirada (por exemplo, negativo).

## 2.2.6 Identificação de Emoção por Expressão Facial

Na década de 1990, a pesquisa automática de análise da expressão facial ganhou muito interesse, principalmente graças ao progresso, nos campos relacionados, como o processamento de imagens (detecção de faces, rastreamento e reconhecimento) e a crescente disponibilidade de poder computacional relativamente barato. O reconhecimento de emoções através de expressões faciais se tornou uma nova tendência em *marketing*, ajudando a empresa a entender a opinião expressa nos produtos (Bouzakraoui et al., 2017). A área de Interação Humano-Computador (IHC) também usa o reconhecimento de emoções para criar assistentes afetivos para que ofereça uma melhor experiência para o usuário (Ruiz et al., 2017).

Os seres humanos expressam suas emoções nas interações cotidianas com os outros. Emoções são frequentemente refletidas no rosto, na mão e gestos corporais, na voz, para expressar nossos sentimentos ou gostos (Busso et al., 2004). Pesquisas recentes em Psicologia mostraram que a forma mais expressiva como os humanos exibem emoções é através de expressões faciais (Arumugam e Dr. S. Purushothaman B.E, 2011).

As expressões faciais desempenham um papel importante no reconhecimento das emoções e são utilizadas no processo de comunicação não-verbal, na identificação de pessoas e na comunicação emocional diária, (Tarnowski et al., 2017). As pessoas podem reconhecer um estado emocional de uma pessoa através das expressões faciais. Como consequência, informações desse tipo são frequentemente utilizadas em sistemas automáticos de reconhecimento de emoções.








As origens da análise da expressão facial remontam ao século XIX, quando Darwin originalmente propôs o conceito de expressões faciais universais no homem e nos animais (Ioannou et al., 2005). Desde o início dos anos 1970, Friesen (1975) realizaram extensos estudos de expressões faciais humanas, fornecendo evidências para apoiar essa teoria da universalidade. Estas "expressões faciais universais" são aquelas que representam felicidade, tristeza, raiva, medo, surpresa e nojo. Para provar isso, eles fornecem resultados do estudo de expressões faciais em diferentes culturas, mesmo primitivas ou isoladas. Esses estudos mostram que os processos de expressão e reconhecimento de emoções na face são bastante comuns, apesar das diferenças impostas pelas regras sociais. Friesen (1975) desenvolveram o FACS (do inglês, *Facial Action Coding System*) para descrever manualmente as expressões faciais, usando imagens estáticas de expressões faciais, geralmente extremas. Uma parte do FACS pode ser visto na Figura 2.21.



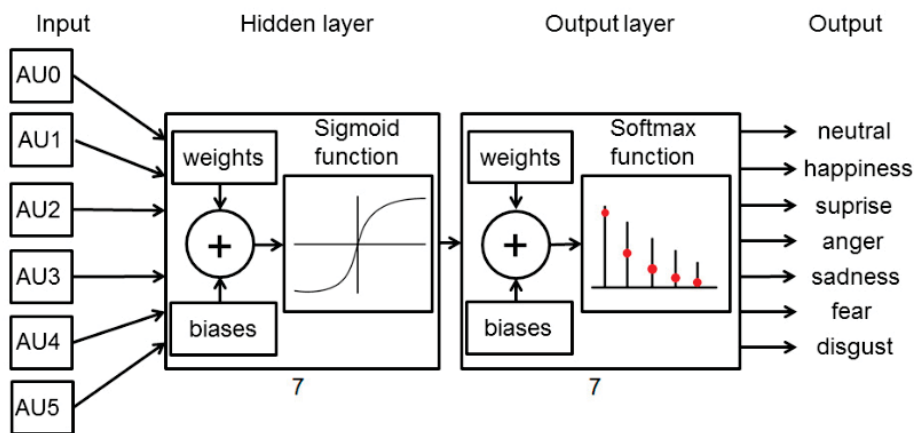
Figura 2.21: Um exemplo do FACS.  
Fonte: Adaptado de Friesen (1975).



Várias abordagens têm sido propostas para classificar estados afetivos humanos. Os recursos usados são geralmente baseados na posição espacial local ou no deslocamento de pontos de regiões específicas da face. As pesquisas também estão relacionadas ao desenvolvimento de algoritmos de alto desempenho e custo baixo para reconhecer sete estados emocionais básicos: neutro, alegria, surpresa, raiva, tristeza, medo e nojo baseados em expressões faciais (Figura 2.22).

ES	neutral	joy	surprise	anger	sadness	fear	disgust
							
AU0	0.21	0.77	-0.10	0.30	0.17	-0.11	0.91
AU1	-0.06	0.09	0.60	-0.07	-0.04	0.20	0.13
AU2	-0.25	1.00	-0.49	0.06	-0.37	-0.60	0.88
AU3	-0.21	0.00	-0.13	0.04	-0.09	-0.17	0.00
AU4	-0.04	-0.47	0.58	-0.19	-0.02	0.28	-0.32
AU5	-0.23	-0.30	0.10	-0.34	-0.27	-0.02	-0.39

(a)



(b)

Figura 2.22: Um exemplo de reconhecimento de emoção através de expressão facial. **a.** expressões faciais com seus respectivos valores. **b.** Estrutura de uma rede neural para reconhecimento classificação de emoções.

Fonte: Adaptado de Tarnowski et al. (2017).

Já outras pesquisas (Mollahosseini et al., 2017) indicam que classes emocionais discretas (como raiva, alegria, medo, tristeza, desgosto e desprezo) não são representativas de todo o espectro de emoções exibidas pelos humanos diariamente, e explicam que há mais confiança em medidas dimensionais, ou seja, *valence* e *arousal*, porém, em condições naturalistas (ou seja, fora de ambiente controlado) é um problema em aberto. Em seu trabalho, Mollahosseini et al. (2017) apresenta uma nova arquitetura de rede neural profunda para analisar o efeito facial em condições naturalistas com alto nível de precisão, estimando conjuntamente emoções discretas e contínuas (*valence* e *arousal*) em um único treinamento, tornando-a adequada para aplicações em tempo-real.

Para isso, foi criada uma biblioteca contendo imagens de faces naturalística (fora de ambiente controlado) com valores de suas respectivas dimensões *valence* e *arousal* chamada *AffectNet* (Mollahosseini et al., 2017). Os bancos de dados de imagens etiquetadas existentes de expressões faciais na natureza são pequenos e cobrem principalmente emoções discretas (também conhecido como modelo categórico). Existem bancos de dados faciais anotados muito limitados para computação afetiva no modelo dimensional contínuo (por exemplo, *valence* e *arousal*). O *AffectNet* contém mais de um milhão de imagens de faces da Internet, consultando três principais mecanismos de pesquisa usando 1.250 palavras-chave relacionadas a emoções em seis idiomas diferentes.

Cerca de metade das foram anotadas manualmente para a presença de sete expressões faciais discretas e a intensidade de *valence* e *arousal* (Mollahosseini et al., 2017). *AffectNet* é um dos maiores banco de dados de expressões faciais *valence* e *arousal* em estado selvagem, permitindo pesquisas em reconhecimento automatizado de expressão facial em dois modelos de emoção diferentes. Duas redes neurais profundas de linha de base são usadas para classificar imagens no modelo categórico e prever a intensidade de *valence* e *arousal* (Figura 2.23).

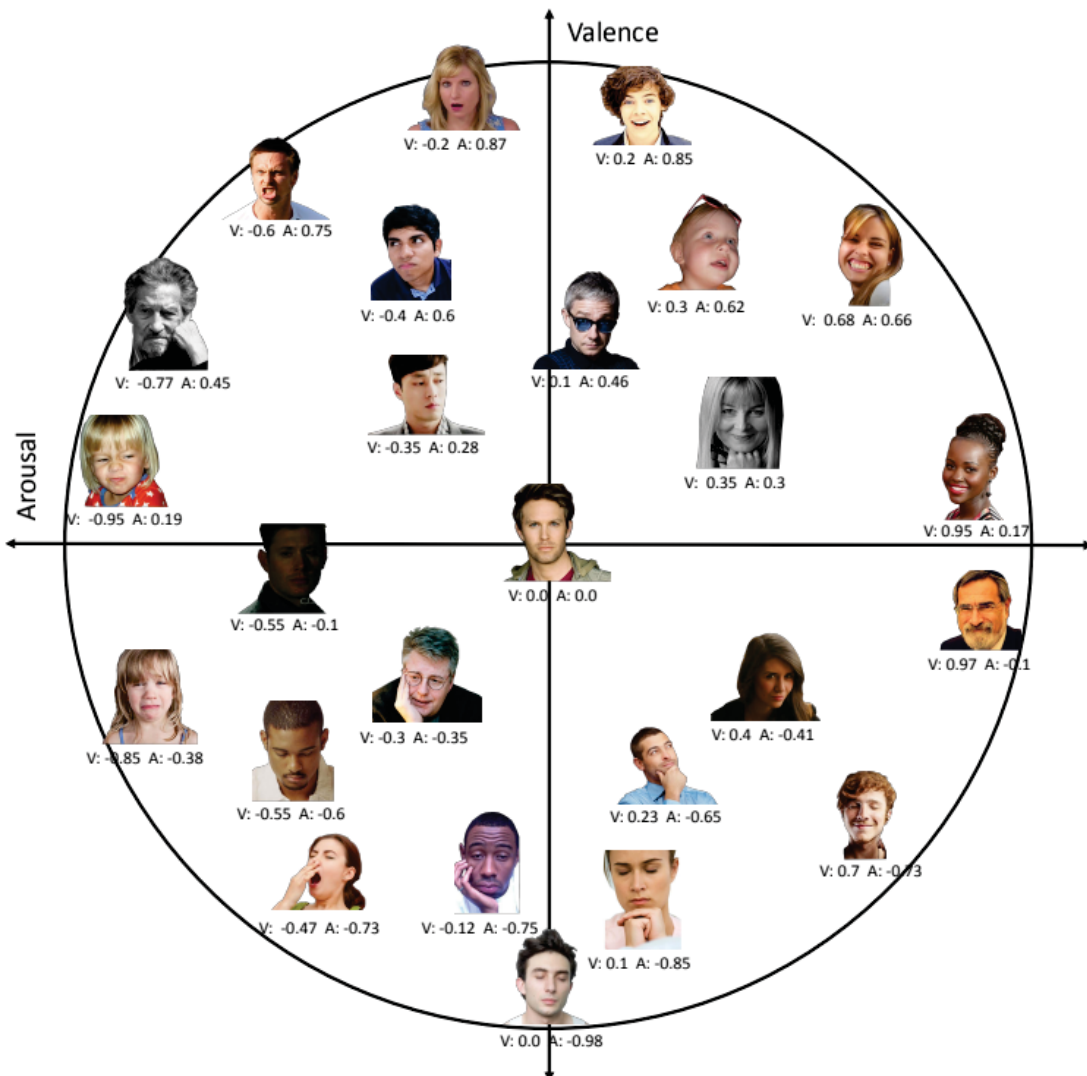


Figura 2.23: Imagens da AffectNet com faces em seus respectivos pontos no plano afetivo *valence/arousal*  
 Fonte: Adaptado de Mollahosseini et al. (2017).

Segundo Mollahosseini et al. (2017) Várias métricas de avaliação mostram que as linhas de base de rede neural profunda podem ter um desempenho melhor do que os métodos convencionais de aprendizado de máquina e sistemas de reconhecimento de expressão facial prontos para uso.

Para o treinamento foi utilizada uma arquitetura de rede neural profunda desenvolvida pela *Imperial College* e Samsung chamada EmoNet para analisar o o reconhecimento facial de estados afetivos em condições naturalistas (em ambiente não controlado) com alto nível de precisão descrita em Toisoul et al. (2021). Essa proposta reconhece e recorta a face da imagem, identifica e alinha os *landmarks*, que são os pontos de controle da face, e estima emoções categóricas e contínuas em uma único treinamento. A Figura 2.24 exhibe a configuração da rede para o treinamento e classificação das emoções categóricas e também os valores de *valence* e *arousal*.

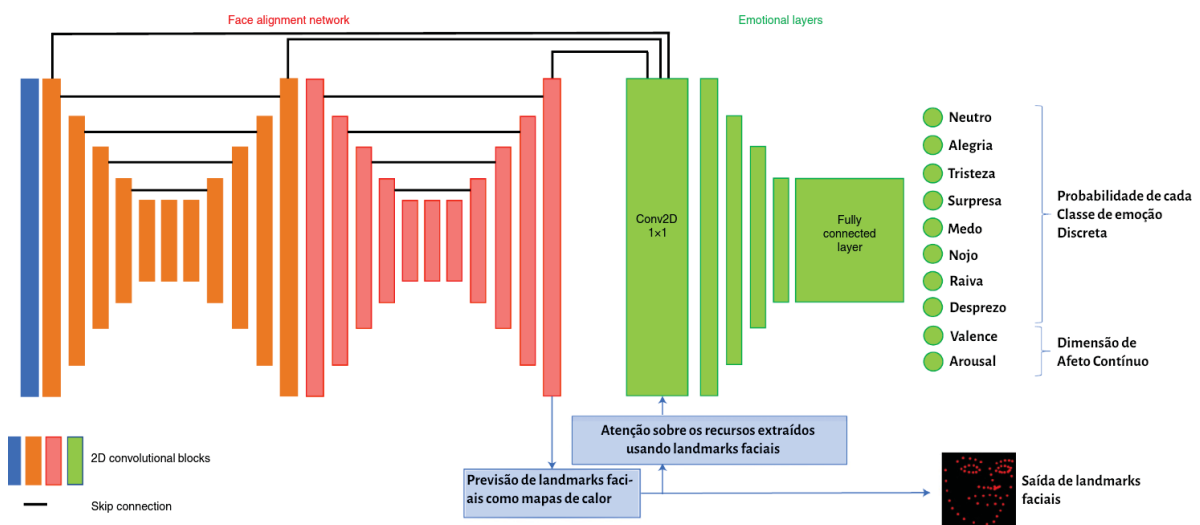


Figura 2.24: Visão geral da arquitetura de reconhecimento de expressões faciais e *valence/arousal* de Toisoul et al. (2021).

Fonte: Adaptado de Toisoul et al. (2021).

Inicialmente, os dados passam pela rede de alinhamento de face, e depois a rede faz a previsão de pontos de controle da face como mapa de calor. No total são 65 pontos de controle que são utilizados para treinamento e comparação com a base de conhecimento. A próxima etapa é um dos diferenciais desta rede, que consiste na atenção sobre os recursos extraídos usando os pontos de controle da face, que entram nas camadas afetivas de blocos convolucionais 2D da *deep learning* e por fim, a saída da probabilidade de cada classe de emoção discreta e também da dimensão de afeto contínuo inferida.

O EmoNet utiliza uma rede de alinhamento facial 16 para prever classes emocionais discretas conjuntamente, dimensões de afeto contínuas e pontos de controle (*landmarks*). Um mecanismo de atenção usando esses pontos de referência faciais é empregado nos mapas de características para atender às partes mais relevantes da face.

Os resultados no conjunto de teste limpo do *AffectNet* para 5 classes (neutro, alegria, tristeza, surpresa e medo) para expressão facial tem acurácia de 82%. Para *valence*, o Coeficiente de Correlação de Concordância (CCC) é de 90%. Para *arousal*, o CCC foi de 80%. Para 8 classes (neutro, alegria, tristeza, surpresa, medo, nojo, raiva e desprezo) para expressão facial tem acurácia de 75%. Para *valence*, o CCC é de 82%. Para *arousal*, o CCC foi de 75%. A Figura 2.25 exhibe um exemplo de reconhecimento de *valence* e *arousal* utilizando a base de dados *AffectNet*.



Figura 2.25: Exemplos de reconhecimentos de *valence* e *arousal*.  
Fonte: Adaptado de Toisoul et al. (2021).

Toisoul et al. (2021) explica que método foi testado em três conjuntos de imagens com faces coletados em condições naturalistas e mostrou que sua abordagem supera todos os métodos anteriores (um deles é o método desenvolvido pelos criadores da base de imagens *AffectNet*) e seu resultado em comparação a quatro algoritmos são exibidos na Figura 2.26

Network	Acc.	Valence				Arousal			
		RMSE	SAGR	PCC	CCC	RMSE	SAGR	PCC	CCC
AffectNet baseline <sup>5</sup>	0.58	0.37	0.74	0.66	0.60	0.41	0.65	0.54	0.34
Face-SSD <sup>15</sup>	-	0.44	0.73	0.58	0.57	0.39	0.71	0.50	0.47
VGG-FACE+2M images <sup>14</sup>	0.60	0.37	0.78	0.66	0.62	0.39	0.75	0.55	0.54
ResNet-18	-	0.39	0.78	0.66	0.66	0.34	0.77	0.60	0.60
<b>Ours (original set)</b>	<b>0.62</b>	<b>0.33</b>	<b>0.81</b>	<b>0.73</b>	<b>0.73</b>	<b>0.30</b>	<b>0.81</b>	<b>0.65</b>	<b>0.65</b>
<b>Ours (clean set)</b>	<b>0.75</b>	<b>0.29</b>	<b>0.84</b>	<b>0.82</b>	<b>0.82</b>	<b>0.27</b>	<b>0.80</b>	<b>0.75</b>	<b>0.75</b>

Our methods performs best on all metrics. In particular, we outperform all previous works, including VGG-FACE+2M images, in which the authors trained their model on AffectNet with an additional 2.5 million synthetic images. Unless specified, results were computed on the original test set.

Figura 2.26: Resultados do algoritmo proposto por Toisoul et al. (2021) em comparação a quatro algoritmos.  
Fonte: Adaptado de Toisoul et al. (2021).

Como conclusão, Toisoul et al. (2021) ressalta a importância das informações geométricas faciais, identificam um problema significativo com a anotação dos dados, que pode ser resolvido limpando ainda mais os conjuntos de validação e teste e indicam que seu método supera todo o trabalho existente na estimativa automática da identificação da emoção via dados faciais por uma grande margem.

### 2.3 EMOÇÃO E APRENDIZAGEM

O avanço da ciência da computação e das novas tecnologias digitais aumentam as possibilidades de extração de emoção de humanos, e isso pode contribuir com a área da educação, já que a emoção tem uma influência substancial nos processos cognitivos em humanos, incluindo percepção, atenção, aprendizado, memória, raciocínio e resolução de problemas (Cosenza e Guerra, 2011; Tyng et al., 2017; Immordino-Yang, 2015). A emoção tem uma influência particularmente forte na atenção, especialmente modulando a seletividade da atenção, e também motivando a ação e o comportamento. Esse controle de atenção está intimamente ligado aos processos de aprendizagem, pois as capacidades de atenção intrinsecamente limitadas são mais bem focadas em informações relevantes. A emoção também facilita a codificação e ajuda na recuperação de informações de forma eficiente (Tyng et al., 2017).

Segundo Immordino-Yang (2015), a compreensão científica das emoções na aprendizagem passou por uma grande transformação nos últimos anos. Em particular, uma revolução na neurociência nas últimas duas décadas derrubou noções iniciais de que as emoções interferem no aprendizado, revelando, em vez disso, que as emoções e a cognição são sustentadas por processos neurais interdependentes. A capacidade de aprender, de acordo com Immordino-Yang (2015), depende da capacidade de sentir emoções. Por exemplo, indivíduos que sofreram danos cerebrais em uma parte do lobo frontal que afetou seu comportamento social e emocional foram posteriormente incapazes de desenvolver intuições em novas situações de aprendizado para orientar o pensamento ou a ação racional. Os estudantes se beneficiam quando as emoções, como interesse e inspiração, são aproveitadas na sala de aula e quando os educadores respeitam as intuições emocionais dos estudantes.

Sadoughi e Hejazi (2021) cita o papel do professor como mediador das emoções positivas. Assim como Xu et al. (2018a) explica que os estudantes experimentam emoções em uma variedade de *valences* de tal forma que afeta o processo cognitivo e o sucesso da aprendizagem. Os componentes afetivos são tão importantes quanto os componentes cognitivos no processo de aprendizagem (Jimnez et al., 2018). Nesses casos, o interesse e a motivação para aprender dos estudantes podem ser afetados negativamente. Porém, Pekrun (1992) argumenta que a relação entre emoção e desempenho não é de forma alguma simples, do tipo "emoções positivas, bons resultados e emoções negativas, maus resultados". A influência das emoções pode ser mediada por diferentes mecanismos, implicando efeitos cumulativos ou contraditórios, tornando difícil prever os efeitos gerais sobre o desempenho. Especificamente, enquanto os efeitos das emoções positivas podem ser benéficos na maioria dos casos, o impacto das emoções negativas, como insatisfação ou ansiedade, pode ser ambivalente. Abril e Peixoto (2012) realizaram um estudo e os resultados orientam para a necessidade de reflexão acerca do papel das emoções e do clima de sala de aula nos contextos de aprendizagem. Jaques e Vicari (2005) realizou uma revisão na área de emoções e aprendizagem e concluiu que as emoções têm um importante papel na aprendizagem e não podem ser negligenciadas por professores ou ambientes educacionais.

Estudos da literatura de teorias de Piaget, Vygotsky e Wallon consideraram o estado afetivo do estudante um fator importante em sua formação, como um ser que pensa, sente e age conforme suas emoções (Kochhann e ROCHA, 2015; VIGOTSKY e da Mente, 1994). A falta de uma mediação entre o ensino e o estado afetivo do estudante pode ocorrer problemas em relação à aprendizagem, e os objetivos de ensino e aprendizagem podem não ser atingidos em sua totalidade (Kochhann e ROCHA, 2015). O *feedback* dos professores é essencial para manter os estudantes motivados, Porém, várias estruturas educacionais não incluem esse tipo de interação entre estudantes e professores, muito menos entre estudantes e sistemas que possibilitem isso (Jimnez et al., 2018).

## 2.4 SISTEMAS TUTORES INTELIGENTES (STI)

Os Sistemas Tutores Inteligentes (STI, ou ITS, do inglês, *Intelligent Tutoring Systems*) têm mostrado grande potencial para melhorar o processo de aprendizagem, sendo capazes de se adaptar ao nível de conhecimento, habilidades e dificuldades do estudante. Um aspecto que pode afetar o processo de aprendizagem, mas não é levado em consideração pelos STI tradicionais, é o estado afetivo do estudante (Alqahtani et al., 2021).

O STI surgiu rotulado como CAI (do inglês, *Computer-Assisted instruction*), uma vez que esta nova modalidade deu-se com o crescimento da Inteligência Artificial (IA), domínio em que se iniciaram investigações sobre a modalidade CAI, do qual emergiu o nome ICAI (do inglês, *Intelligent Computer-Assisted Instruction*) na década de 60 e 70 (Silva, 2014). O termo "Sistemas Tutores Inteligentes" só veio surgir em 1982, cunhado por Sleeman e Brown (1982). Estes são programas de computador que utilizam técnicas de IA com finalidade educacional (Nwana, 1990).

Estes sistemas devem ser capazes de auxiliar um estudante, saber o que ensinar e como ensinar. O propósito de um STI é propiciar a cada estudante um ensino individualizado. Sua arquitetura é constituída de quatro módulos: Módulo Especialista, Módulo do estudante, Módulo do tutor e interface (Gavidia e Andrade, 2003; Nwana, 1990; Ahuja e Sille, 2013). A Figura 2.27 representa a arquitetura básica, os módulos.




Figura 2.27: Arquitetura básica de um STI clássico.

Fonte: Adaptado de Ahuja e Sille (2013).

- Interface: Este módulo é importante para o sucesso de um tutor ou um sistema interativo. É responsável pela interação do estudante com o sistema, por apresentar o material instrucional e receber as solicitações do usuário;
- Módulo do especialista: É neste módulo que as informações que serão mostradas ao estudante ficam armazenadas. Ele é responsável por fornecer os conteúdos;
- Módulo do tutor: Este módulo está profundamente ligado ao módulo do estudante. Contém estratégias pedagógicas de ensino e decide quais serão utilizadas, isto é, quem determina qual informação será apresentada e como será apresentada;
- Módulo do estudante: estão armazenadas as características do estudante. É a representação de seu conhecimento e dos erros cometidos.

Guo et al. (2021) argumenta que os STI's são ferramentas educacionais promissoras para personalizar a educação formal usando instrução ou *feedback* inteligente. Nas últimas décadas, os STI's transformaram o ensino e a aprendizagem e a pesquisa associada e este campo ainda está em estágio inicial, onde Ciência da computação, educação, psicologia e engenharia foram as principais fontes de conhecimento de pesquisa de STI, com publicações de ciências sociais de ITS desde 2007 sendo superiores às publicações de ciências naturais (Guo et al., 2021). Segundo o autor, ambientes de aprendizagem interativos, modelagem de alunos, estratégias de ensino/aprendizagem e *machine learning* têm sido os focos de pesquisa mais populares.

## 2.5 SISTEMAS TUTORES AFETIVOS OU SISTEMAS TUTORES INTELIGENTES EMOCIONAIS

A neurociência evidenciou que os processos cognitivos e afetivos estão associados, onde fenômenos afetivos influenciam nos processos cognitivos como tomada de decisão (LeDoux, 1996; Damasio, 2008; Longhi et al., 2007). Já o processo de aprendizagem está relacionado com aspectos cognitivos e emocionais, e como consequência disso, ensinar implicaria na observação do comportamento dos estados afetivos do estudante que podem expressar interesse, engajamento, confusão, tédio, frustração, satisfação, desapontamento, etc. e assim sugerir diversas formas de interação tais como os *feedbacks* (Ben Ammar et al., 2010).

Estas afirmações contribuem para o interesse na elaboração de novas tecnologias digitais para o uso em sistemas educacionais que consigam reconhecer fenômenos afetivos (Longhi et al., 2007). A Computação Afetiva é uma subárea da Inteligência Artificial que estuda formas de introduzir o reconhecimento de emoções humanas em computadores (Picard, 2000; Ben Ammar et al., 2010). A moção não é apenas o fator impulsionador que promove a aprendizagem, mas também o principal fator que também dificulta o processo de aprendizagem (Hasan et al., 2020).

Petrovica (2014) afirma que o incremento de um componente emocional à interação homem-computador é de grande importância, onde uma nova geração de STI foi criada, chamados de Sistemas Tutores Inteligentes Emocionais (STIE ou EITS, do inglês *Emotionally Intelligent Tutoring System*) ou Sistemas Tutores Afetivos (STA, ou ATS, do inglês, *Affective Tutoring Systems*). Estudos de sistemas adaptados devem levar não apenas as questões de cognição e conhecimento do estudante, mas também o contexto dos estados afetivos de forma mais aprofundada, pois abre possibilidades ainda não exploradas já que, segundo a neurociência, a cognição e a emoções estão correlacionadas. A principal diferença entre um ITS e um EITS é a capacidade de detectar, monitorar e responder às emoções humanas Mohanan et al. (2017). O trabalho de Mohanan et al. (2017) confirma o papel importante das emoções em um ambiente de aprendizagem e que formas de reconhecimento de estados afetivos devem ser integrados a um STI pois pode oferecer estilos de ensino diferenciados.

Xu et al. (2018b) explica que o STI reformula as aulas convencionais a partir de abordagens de métodos de avaliação. Os reconhecimentos de estados afetivos através de sensores fisiológicos, expressões faciais, comportamento, etc. tenta analisar a emoção humana, o que abre uma nova página para estudar o processamento da aprendizagem. Ben Ammar et al. (2010) chegou à conclusão de que o STA pode ser uma solução promissora sistema de tutoria para o ambiente de aprendizagem de próxima geração, afiliando canais adequados de reconhecimento de emoções, juntamente com abordagens de inteligência computacional.

O estado afetivo é predominante na aprendizagem e pode ter grande influência na qualidade da aprendizagem dos estudantes, logo, adicionar uma camada de empatia em um STI aumentaria sua eficácia (Fwa, 2018). Identificar e responder a estados afetivos pode ser mais influente do que a inteligência para o sucesso da tutoria (Zataraín-Cabada et al., 2014).

## 2.6 FEEDBACKS NA APRENDIZAGEM

O *feedback* pode ser informal ou formal. Por exemplo, um *feedback* informal é o dia-a-dia entre professores e estudantes ou estagiários, entre pares ou entre colegas. Avaliações escritas ou clínicas são exemplos de *feedbacks* formais. O *feedback*, segundo Jiménez et al. (2018), pode ser classificado em três tipos: motivacional, avaliativo e descritivo. O *feedback* motivacional tem o objetivo de fazer com que o estudante se sinta bem em estabelecer um ambiente de aprendizado respeitoso.

O *feedback* avaliativo tem o objetivo de medir o desempenho do estudante com uma nota ou nota, mas não transmite as informações e orientações que os estudantes podem usar para melhorar seu desempenho. Por outro lado, o *feedback* afetivo fornece aos estudantes informações detalhadas e específicas sobre como melhorar seu aprendizado. Os principais objetivos do *feedback*, segundo Jiménez et al. (2018) são:

- justificar aos estudantes como sua nota foi atribuída;
- identificar e recompensar qualidades específicas no trabalho do estudante;
- orientar os estudantes sobre as medidas a serem tomadas para melhorar;
- motivá-los a agir em sua avaliação;
- desenvolver sua capacidade de monitorar, avaliar e regular sua própria aprendizagem.

O *feedback* é um elemento chave no processo educacional, comumente usado para dar suporte ao estudante durante seu processo de estudante agem (Jiménez et al., 2018). O *feedback* é uma das influências na estudante agem e no desempenho acadêmico, mas esse impacto pode ser positivo ou negativo. De acordo com Hattie e Timperley (2007), o *feedback* é conceituado como a informação fornecida por um agente (professor, colega, livro, pai, ele próprio) em relação a aspectos de desempenho ou compreensão. É um processo no qual estudantes e tutores compartilham informações específicas para incentivá-los a melhorar o desempenho acadêmico dos estudantes. A Figura 2.28 mostra o processo de *feedback*.




Figura 2.28: Processo de *feedback* no contexto de estudante agem  
Fonte: Adaptado de Jiménez et al. (2018).

Para Fossati (2008), o *feedback* é uma forma importante de interação estudante-tutor. O *feedback* negativo pode ser fornecido pelo tutor em resposta aos erros dos estudantes. Um uso eficaz de *feedback* negativo pode ajudar o estudante a corrigir um erro e impedir que ele repita o mesmo erro ou um erro semelhante novamente, proporcionando efetivamente uma oportunidade de estudante ado ao estudante. O *feedback* positivo é geralmente fornecido em resposta a alguma informação correta do estudante. O *feedback* positivo pode ajudar os estudantes a reforçar o conhecimento correto que já possuem ou integrar com sucesso novos conhecimentos, se a entrada correta fornecida pelo estudante tiver sido originada por uma etapa aleatória ou provisória.



Dāboliņš e Grundspenķis (2013) explica que o processo de estudante agem na compreensão clássica é o relacionamento entre professor e estudante. Este processo de estudante agem traz os melhores resultados com a condição de que o professor seja capaz de responder a todas as perguntas - fornecer *feedback* imediato. Ao se adaptar a um público em particular, compreendendo suas necessidades, um palestrante pode desviar-se do tópico até certo ponto e fornecer um *feedback* imediato sobre os aspectos do assunto que o público está diretamente interessado, ampliando assim o conhecimento dos estudantes

O *feedback* permite que o próprio estudante adquira informações importantes sobre o material, compreenda as tarefas futuras e forneça ao professor as informações sobre o progresso dos estudantes, retrocessos e as mudanças necessárias no processo de ensino (Brookhart, 2012; Peska, 2012). Se o *feedback* entre o STI e o estudante for fornecido, melhores resultados de treinamento serão obtidos (He et al., 2009) (Anohina-Naumeca e Grundspenkis, 2010; Roll et al., 2011), se o STI corrige instantaneamente os erros cometidos pelo estudante ou mostra o caminho certo para evitar o erro, conhecimento do estudante se torna mais profundo (Woo et al., 2006).

No entanto, o *feedback* em si não garante que o estudante aprenda (Medina-Medina et al., 2003). O *feedback* é a atividade do professor, mas não reflete a atividade do estudante. O *feedback* é parte dos controles do processo de estudante ado externo. O STI proposto em Medina-Medina et al. (2003) oferece uma forma interessante ao estudante onde introduz a operação a ser respondida pelo estudante, tipos de *feedback* e seu significado, favorecendo assim uma compreensão sobre os assuntos relacionados ao STI (Medina-Medina et al., 2003).

Segundo Gouli et al. (2006), uma *feedback* efetivo visa:

- Ajudar os estudantes a identificar suas falsas crenças, tomando consciência de seus equívocos e inadequações e reconstruindo seus conhecimentos;
- Ajudar os estudantes a determinar as expectativas de desempenho, identificar o que eles já aprenderam e o que eles são capazes de fazer e julgar seu progresso pessoal de estudante ado;
- Apoiar os estudante no sentido de alcançar os objetivos de estudante agem subjacentes.

O *feedback* deve ser alinhado, tanto quanto possível, à individualidade do estudante, necessidades especiais, autoavaliação, autoexplicação, autorregulação, etc. Para avaliação das diferentes formas de *feedback*, o STI com o mapeamento conceitual baseado em computador foi analisado. O *feedback* em tais sistemas é fornecido sobre a pontuação quantitativa para o mapa do estudante acompanhado de como a pontuação é obtida (Anohina-Naumeca e Grundspenkis, 2010; Gouli et al., 2006; Lee e Brusilovsky, 2009).

Os *feedbacks* têm o papel mais importante no processo de estudo, além de ser uma das principais possibilidades de adaptabilidade do STI. Através do *feedback*, o estudante tem a possibilidade de entender o que ele já sabe e o que é capaz de realizar, quais atividades são necessárias para o processo de estudante agem. Para aprender, o estudante deve entender o objetivo de estudante agem, reconhecer o nível atual de conhecimento em relação aos objetivos de estudante agem e aprender a melhorar o conhecimento. Assim, o *feedback* pode ser a base de mais processos de cognição e motivação do estudante (Dāboliņš e Grundspenķis, 2013).

Estes objetivos são muito importantes para que o estudante o estudante se sinta mais motivado para desenvolver as atividades. Porém, não há apenas *feedbacks*, existem outros tipos de intervenções estudantis, como *scaffolding* e dicas Ascari et al. (2021), que possibilita uma expansão das formas como o professor pode interagir com os estudantes. Ascari et al. (2021) realizou uma pesquisa sobre os principais tipos e apresenta uma classificação de tipos e subtipos das intervenções. Os dados podem ser vistos na Tabela 2.1.

Tabela 2.1: Tipos e subtipos de intervenções tutoriais.

Tipos	Subtipos
<i>Scaffolding</i>	Conceitual; Processual; Estratégico e Metacognitivo
<i>Feedback</i> baseado na função	Confirmação; Corretivo; Explicativo; Diagnóstico e Elaborativo
<i>Feedback</i> baseado no conteúdo	Conhecimento da resposta
	Resposta até que seja correta; Tópico contingente; Resposta contingente; <i>bug</i> relacionado e Isolamento de atributos
	Conhecimento do desempenho; Conhecimento da resposta correta; Elaborado
	De violação de condição e de meta
Dica	Informação transmitida; Apontar para e Linha direta de raciocínio

Fonte: Adaptado de Ascari et al. (2021).

De acordo com Ascari et al. (2021), as principais subtipos levantadas para *Scaffolding* são: **Conceitual** que orienta o estudante a concentrar em conceitos que apresentam várias interpretações; **Processual** que orienta o estudante no entendimento das funções de um sistema ou de uma ferramentas; **Estratégico** que avisa que outras alternativas podem ser úteis e **Metacognitivo** que ajuda o estudante a pensar sobre um determinado problema.

As principais para *feedbacks* são: **De confirmação** que mostra se a resposta está correta ou não; **Corretivo** que apresenta informações a mais sobre a resposta incorreta; **Explicativo** que exhibe motivos da resposta estar errada; **Diagnóstico** que identifica falhas comparando erros básicos com o erro do estudante; **Elaborativo** que fornece informações a mais para complementar o conhecimento presentes na atividade; **De conhecimento da resposta** que mostra se a resposta está certa ou errada; **Até que resposta seja correta** que pede para o estudante tentar novamente até que a resposta esteja certa; **De conhecimento da resposta correta** que informa qual é a resposta certa; **De tópico contingente** que verifica a resposta do estudante e elabora o *feedback*; **De resposta contingente** que mostra explicações sobre a resposta do estudante; **bug relacionado** que apresenta quais são foram os erros comuns cometidos pelo estudante; **De isolamento de atributos** que identifica os atributos centrais do conceito de acordo com sua resposta. **De conhecimento do desempenho** que apresenta informações sobre sua atividade; **De conhecimento do resultado** que mostra informações sobre a resposta do estudante; **De conhecimento da resposta correta** que apresenta a resolução da tarefa; **Elaborado** que apresenta informações conhecimento acerca da resposta correta. **Mínimo** que fornece informações básicas sobre a resposta do estudante; **e violação de condição** que informa qual a próxima etapa ao estudante; **De meta** que fornece um estímulo para o que o estudante faça o caminho que precisa seguir para encontrar a resposta certa;

As principais para **dicas** são: **De informação transmitida** que consiste em perguntas que transmitem informações explícitas ao estudante na forma de uma explicação ou um resumo; **Apontar para** inclui enunciados que fazem menção à informação que se pressupõe estar disponível para o estudante; **De Linha direta de raciocínio** oferece uma sucessão de perguntas, ou sugestões, que fazem com que o estudante tenha que pensar sobre cada uma das etapas até chegar em uma solução.

### 3 TRABALHOS CORRELATOS

Este capítulo faz um levantamento dos trabalhos que guiaram a pesquisa desta tes e contribuíram de forma significativa para o desenvolvimento teórico e prático. Os temas abordados apresentados neste capítulo são trabalhos de estados afetivos na aprendizagem, feedbacks na aprendizagem, sistemas tutores afetivos e coleta de EEG com OpenBCI.

#### 3.1 ESTADOS AFETIVOS NA APRENDIZAGEM

A aprendizagem em níveis mais profundos de compreensão, resolução de problemas e testes de alto risco são afetados pela emoção (Calvo e D’Mello, 2011). Emoções negativas (como irritação, frustração e raiva) podem trazer experiências como o fracasso, comete-se erros e problemas maiores acontecem. Por outro lado, desafios são vencidos, ideias são reveladas e grandes descobertas são feitas. Essas trajetórias de estados afetivos positivos e negativos levam a diferentes resultados de aprendizagem. Estados afetivos como engajamento geralmente refletem em aprendizado, enquanto frustração, tédio e falta de autoconfiança inibem o aprendizado (Calvo e D’Mello, 2011).

O trabalho de Gottardo e Ricardo Pimentel (2018) apresenta uma abordagem gráfica baseada em quadrantes que representa uma distribuição de estados afetivos. Esta abordagem pode ser vista na Figura 3.1.

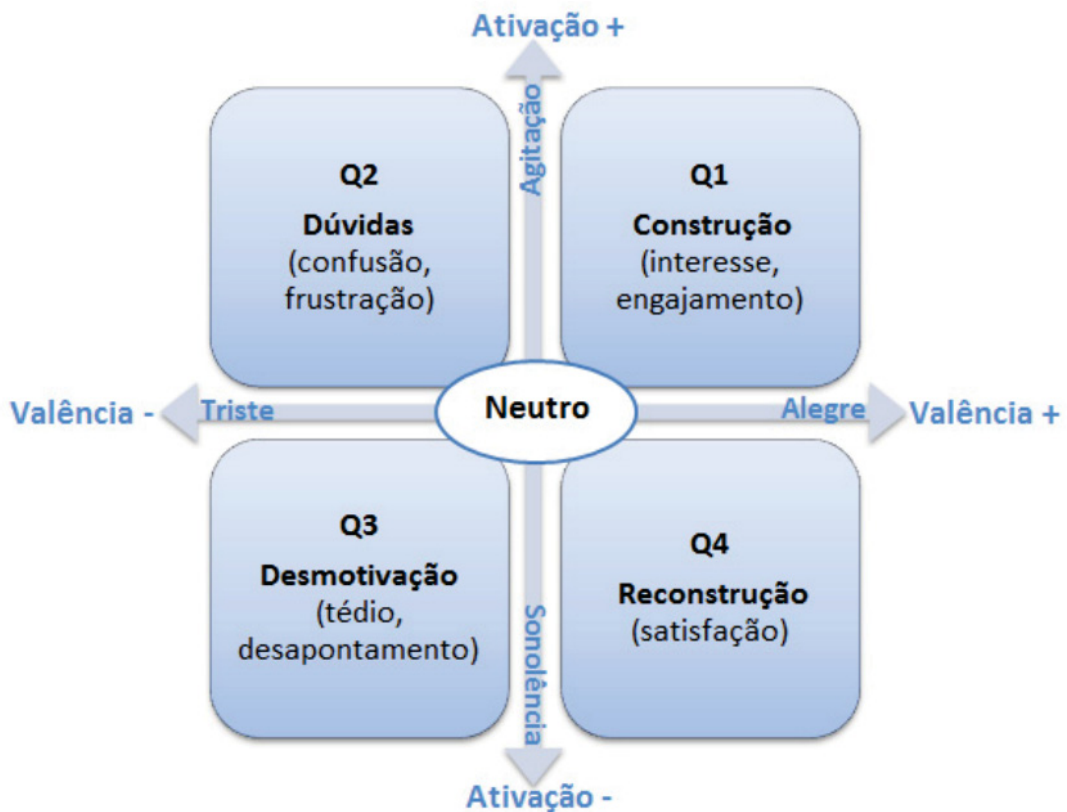


Figura 3.1: Modelo de representação das emoções em quadrantes.  
Fonte: Adaptado de Gottardo e Ricardo Pimentel (2018).

Esta abordagem trabalha com quatro quadrantes, onde o quadrante 1 contém a alegria e surpresa, no quadrante 2, o medo, desgosto, raiva, surpresa e desprezo, no quadrante 3, tristeza, no quadrante 4, alegria, e no quadrante do meio o neutro. Os quadrantes 1 e 2 com *arousal* positivo formam a classe chamada agitação, e os quadrantes 3 e 4 com *arousal* negativo formam a classe chamada sonolência. Em relação à dimensão de *valence*, os quadrantes Q1 e Q4 formam a classe chamada positivo, enquanto os quadrantes 2 e 3 formam a classe chamada negativo. O quadrante neutro nas duas dimensões permanece como uma classe chamada de neutro. Esta representação em quadrantes possibilita ver a ocorrência de estados afetivos do tal como o engajamento.

Para identificar qual estado afetivo, Gottardo e Ricardo Pimentel (2018) apresentam uma abordagem híbrida que combina dados físicos e cognitivos do estudante que se assemelha ao processo natural de inferência de emoções, pois trabalha com a identificação de expressões faciais em conjunto com as reações positivas ou negativas frente a eventos, agentes e objetos, e após a fusão entre essas duas formas de identificação de estado afetivo, o estudo da variação entre quadrantes pode ser realizado.

A presente tese trabalha com a ideia de quadrantes sugerida por Gottardo e Ricardo Pimentel (2018) para analisar as mudanças de estados afetivos, porém, utilizará dados físicos (imagens de expressões faciais) e também com a atividade neural via EEG com *feedbacks* dados em processo.

Em ambientes de educação, várias atividades de aprendizagem e avaliação são oferecidas aos estudantes, que podem encontrar dificuldades como travamento, bloqueios ou falta de motivação (Kouahla et al., 2022). Soluções pedagógicas e/ou psicológicas podem melhorar o estado afetivo dos estudantes, como aumentar a motivação e desbloquear situações difíceis. Kouahla et al. (2022) realizar em seu trabalho o reconhecimento do estado afetivo das faces e vozes de estudantes, propõe um algoritmo de recomendação solução pedagógicas ou solução psicológicas para motivar o aluno com base nos resultados de reconhecimento de estado afetivo da face e voz. O trabalho de Kouahla et al. (2022) ajudou esta presente tese na decisão de coletar os dados que também vêm de face face, porém não há análise de voz, mas há análise de EEG enquanto o estudante está avaliando atividades.

### 3.2 FEEDBACKS NA APRENDIZAGEM

Yamamoto et al. (2021) explica que o fornecimento de *feedback* é uma das questões mais importantes para realizar a aprendizagem adaptativa. Também faz uma separação entre dois tipos de *feedbacks* que podem ser apresentados ao estudante. Os que são apresentados **depois da resposta** da atividade, é chamado de "*feedback* pós-processo", o segundo tipo de *feedback* é o que é exibido ao estudante **durante** a atividade, ou seja, **antes da resposta**, é chamado de "*feedback* em processo". Este último tipo de intervenção foi pouco explorado em comparação ao "pós-processo" por exigir de uma análise constante, sendo uma linha de pesquisa desafiadora. O trabalho de Yamamoto et al. (2021) fornece informações importantes para ser abordado em um contexto de STI. O trabalho Yamamoto et al. (2021) identifica o estado afetivo do estudante através da atividade neural via EEG para decidir o momento de exibição do *feedback* em processo e a estimativa do estado de conhecimento com base na estrutura de conhecimento para o conteúdo do *feedback*. A detecção de um "travamento" com base em dados de EEG usando um BCI simples é considerada bastante prática.

Esta tese tem como objetivo exibir *feedbacks* em processo, ou seja, antes do estudante fornecer sua resposta, o que complementa trabalhos que estudam *feedbacks* pós-processo. Também tem como diferencial elaborar uma abordagem modular, ou seja, as formas de inferência

de estados afetivos podem ser modificadas, adaptadas ou trocadas, assim como a estratégia de escolha do *feedback* que será exibido, que podem ser utilizado por qualquer AVA. Para isso, um módulo afetivo para STI com análise emocional utilizando dados da face do estudante além do EEG para que sejam apresentados *feedbacks* em processo em forma de notificações em um AVA que é acessado via web.

No trabalho de Mohanan et al. (2017) é apresentada uma tabela que relaciona *feedbacks* fornecidos por um tutores humanos e por um sistema, que pode ser vista na Figura 3.2, exibindo o estado afetivo, a resposta do tutor humano e a resposta do sistema.

Emoção identificada pelo sistema de reconhecimento de padrões (FEARS)	Pontos CEM do e-estudante	Modelo de papel afetivo do agente de software			Resposta do Tutor Humano	Resposta do Sistema Tutor Inteligente Emocional (EITS)
		Papel	Ação	Característica		
Neutro	Em branco	Promotor	Promoção	Amigável, Elaborado, esperançoso, acolhedor	Refaça a pergunta	Tenha 2-3 versões de perguntas. Divida a pergunta em elementos que levaria à questão principal.
Feliz	Motivado	Pais	Estimulação	Incentivadora, desejada, aproximando-se	Celebrar isso. Dar um mimo. Use reforço verbal. "Você entendeu!"	Dê mensagens como "Parabéns"" Mostrar fogos de artifício.
Excitação	Curioso	Pedagogo	Lição/Ensinar	Informativo, pedagogia, amoroso educado, calmo, racional	Forneça mais informações e material adicional	Forneça mais informações através de um botão. Link para vídeo ou outras páginas da web.
Medo	Hesitante	Orientador/conselheiro	Motivação	Torcedor, confiante, entusiasmado, cuidando	Aumente a confiança. Permitir estudantes a discutir com pares. "Eu sei que você pode fazer isso". "Sua opinião importa"	Dê uma mensagem como "Você pode fazer isso!". Isso pode motivar o estudante a encontrar a resposta. Reproduza o arquivo de áudio de música suave.
Triste	Decepcionado	Companheiro	Apoiar	Amigável, Cordial, Inspirador, otimista, Aprovando, Agradável	Incentive (mantenha o tom positivo). Diga a eles que não há problema em fazer algo errado algumas vezes. "Converse sobre isso"	Mostre-lhes exemplos ou vídeos. Mostre Interações do passado de forma positiva. Deixe-os tentar novamente ou tente uma versão diferente de uma pergunta. "Digite" - deixe-os digitar seus sentimentos e pensamentos e submetê-los ao EITS.
Raiva, vergonha, Embaraço	Fracassado	Animador Companheiro	Inspirar	Energético, habilidoso, ágil, útil, expressivo	Re-ensine os conceitos. inspira-os a tentar novamente. Dê exemplos diferentes. "Vamos! Está bem."	Avisos extras, lembretes. Forneça uma opção para revisar e tentar novamente. Forneça dicas, exemplos e Vídeos.
Medo, Desprezo	Ansioso	Coordenador	Explicação	Eloquente, habilidoso, ágil, útil, expressivo	Acalme-os. Mencione todas as coisas que eles fizeram corretamente.	Exia uma mensagem encorajadora positiva. Mostre-lhes uma caixa de listagem das últimas interações positivas.
Desprezo, tristeza, raiva	Contestado	Admirador	Elogio	Animado, orgulhoso, Feliz, sugestivo, satisfeito	"Você vai descobrir"	Mensagem de tom de forma positiva. Botão de exibição para "Precisa de uma dica?" e dê uma

Figura 3.2: STIE e suas respostas e respostas de tutores humanos de acordo com cada estado afetivo identificado.

Fonte: Adaptado e traduzido de (Mohanan et al., 2017).

Foi observado em Mohanan et al. (2017) que uma emoção negativa dificulta a aprendizagem. O sistema pode detectar estados afetivos negativos (medo, tristeza ou raiva) e com isso escolher um *feedbacks* apropriados que pode manter o estudante motivado. Por exemplo, se o estudante estiver com medo, o sistema proposto pode dar uma mensagem do tipo "você pode fazer isso!", motivando-o a encontrar a resposta, enquanto que um tutor humano iria sugerir o aumento da confiança e pedido para discutirem em pares depois de uma mensagem do tipo "eu sei que você pode fazer isso".

O trabalho de Mohanan et al. (2017) foi uma base para esta tese pois através da tabela fornecida, pode-se elaborar listas de *feedbacks* que serão apresentados para o estudante no experimento. O principal diferencial desta tese com o trabalho citado é a utilização de EEG além da face, e também da implementação e a aplicação do experimento em um AVA, realizando um estudo de efetividade desse tipo de *feedback*, onde comparou-se um grupo de controle, que não vê a intervenção, e experimental, que vê a intervenção, e também a criação de um *ranking* dos melhores *feedbacks* de acordo com o experimento.

O trabalho de Ascari et al. (2021) apresenta um modelo que permite a apresentação automática de intervenções com base na identificação do tipo de erro matemático cometido pelo estudante, além de inferir seu estado afetivo, que foi aplicado em experimentos em ambiente real de aprendizagem, utilizando o modelo proposto implementado em um jogo de frações. Seus resultados apresentados indicam que as intervenções tutoriais personalizadas favorecem maior engajamento e motivação dos aprendizes e melhora nos resultados de aprendizagem. Este trabalho teve bastante influência teórica no trabalho de Ascari et al. (2021) pela revisão sistemática realizada na área de intervenções estudantis, e por exibir tais intervenções de acordo com a resposta do estudante identificando o estado afetivo de acordo com sua expressão facial após receber tal intervenção, o chamado *feedback* pós-processo.

A diferença da abordagem de Ascari et al. (2021) para a proposta desta tese é o fato do uso de *feedbacks* em processo, ou seja, antes da resposta do estudante, e a análise afetiva será realizada, além da face, de acordo com a atividade neural via EEG, fazendo assim uma complementação à abordagem do trabalho citado.

Duarte Leite. et al. (2013) trabalha com *feedbacks* pós-processo e cita que a correção de erros presente em STI visa proporcionar aos estudantes o *feedback* mais adequado que pode estar atrelado ao perfil do estudante ou ao caminho que ele está seguindo, interferindo antes mesmo que o estudante cometa um erro. Este trabalho foi tido como base por proporcionar um conhecimento teórica acerca de STI para exibição de *feedbacks* para remediação de erros do estudante. O principal diferencial desta tese com o trabalho de Duarte Leite. et al. (2013) está no fato da tese ter como proposta trabalhar com análises afetivas e com *feedbacks* em processo.

O trabalho de Tiam-Lee e Sumi (2018) apresenta um sistema para a prática de programação que fornece *feedback* adaptativo com base na presença de confusão no estudante, que solicita através do clique de um botão. Em Silva et al. (2019) há uma descrição de uma abordagem para ajudar os estudantes envolvidos em um sistema de tutoria de programação, fornecendo *feedback* durante o código de atividades de solução de problemas, também de forma manual.

O objetivo desta tese é semelhante aos trabalhos mencionados acima, no entanto, os *feedbacks* textuais serão exibidos automaticamente através notificação no AVA, permanecendo alguns segundos e depois apagando, semelhante à notificações em mídias sociais utilizando dados da face e de eeg, enquanto que nos trabalhos citados, o pedido de dicas e *feedbacks* são solicitados manualmente através de um botão e não usam análise de face nem de EEG.

### 3.3 SISTEMAS TUTORES AFETIVOS

Heraz e Frasson (2011) propõem um sistema multiagentes chamado NORA que identifica atributos emocionais através da atividade neural via EEG de estudante dentro de um STI. Segundo os autores, a medição da atividade neural durante a aprendizagem tem um papel importante para ajudar os estudantes a alcançar as melhores condições de aprendizagem. Segundo os autores, aprender a controlar conscientemente os estados de ondas cerebrais pode ajudar no aumento da capacidade de concentração e consequente diminuição do estresse. A Figura 3.3 exhibe a arquitetura proposta no trabalho citado.

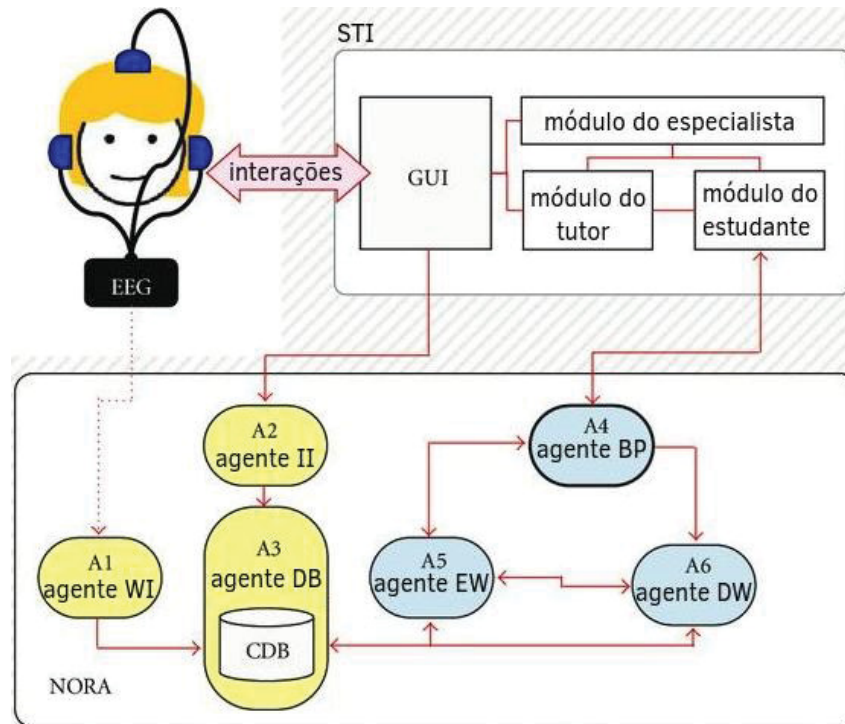


Figura 3.3: Arquitetura NORA, formada por coleta de dados (agentes A1, A2 e A3) e inferência do estado afetivo (agentes A4, A5 e A6)

Fonte: Adaptado de Heraz e Frasson (2011).

Segundo Heraz e Frasson (2011), o estudante usa BCI contendo três sensores, Cz, A1 e A2, enquanto interage com o ITS por meio de uma GUI e inclui seis agentes principais distribuídos em dois grupos.

- Grupo 1: Coleta de Dados.
  - O agente A1 *Wave Input (WI)* recebe dados de EEG enquanto o agente A2 *Interact Input (II)* recebe informações sobre a interação do estudante com o ITS;
  - O Agente A3 *Data Base (DB)* armazena essas duas categorias de entrada em um *Central Data Base (CDB)* após uma filtragem de algumas variáveis.
- Grupo 2: Inferência do estado afetivo;
  - O agente A5 *Esmo Wave (EW)* solicita dados do CDB e infere o estado afetivo e cognitivo do estudante a partir de suas ondas cerebrais e é capaz de prever esses estados usando técnicas de aprendizado de máquina aplicadas nos dados do CDB e enviar essas informações a pedido do agente A4 *Brain Profile (BP)*;

- O agente *A6 Demo Wave (DW)* solicita dados da *CDB* sobre o estado afetivo e cognitivo do estudante para selecionar um método de indução de ondas cerebrais capaz de melhorar o aprendizado. *DW* envia ao agente *BP* uma lista de estímulos auditivos e visuais a serem aplicados para induzir ondas cerebrais específicas úteis para o aprendizado;
- O Agente *BP* desempenha o papel de agente supervisor; ele solicita informações dos agentes *EW* e *DW* para determinar o perfil cerebral do estudante, atualizar o módulo do aluno (no STI) e selecionar uma estratégia pedagógica a ser aplicada para melhorar o aprendizado.

O principal diferencial entre a proposta desta tese e o trabalho de Heraz e Frasson (2011) está no fato de a inferência de estados afetivos usar expressões faciais via *webcam* e na questão do EEG, são utilizados seis eletrodos, F3, F4, AF3, AF4, A1 e A2, e não apenas três do trabalho citado, Cz, A1 e A2, utilizando-se o FEA, uma técnica muito utilizada na neurociência (Palmiero e Piccardi, 2017; Pomer-Escher et al., 2014; Coan e Allen, 2004; Allen et al., 2004; Davidson, 2004). E também, a abordagem proposta na tese é modular, possibilitando a mudança de algoritmos de detecção de emoções via face, EEG e estratégia de tutor e AVA. Porém, o trabalho de Heraz e Frasson (2011) teve bastante influência neste trabalho para o desenvolvimento da abordagem proposta na tese, além de ser uma possível continuação deste trabalho.

Kanjilal (2014) propõe um sistema capaz de avaliar as capacidades, os estados cognitivos e o estado afetivo do estudante, através dos dados de expressões faciais processamento de síntese de voz. Este sistema é capaz de avaliar com as emoções dos estudantes e alterar o conteúdo do STI de acordo com as necessidades baseados nesta avaliação afetiva. A Figura 3.4 mostra o diagrama em blocos do STIE.

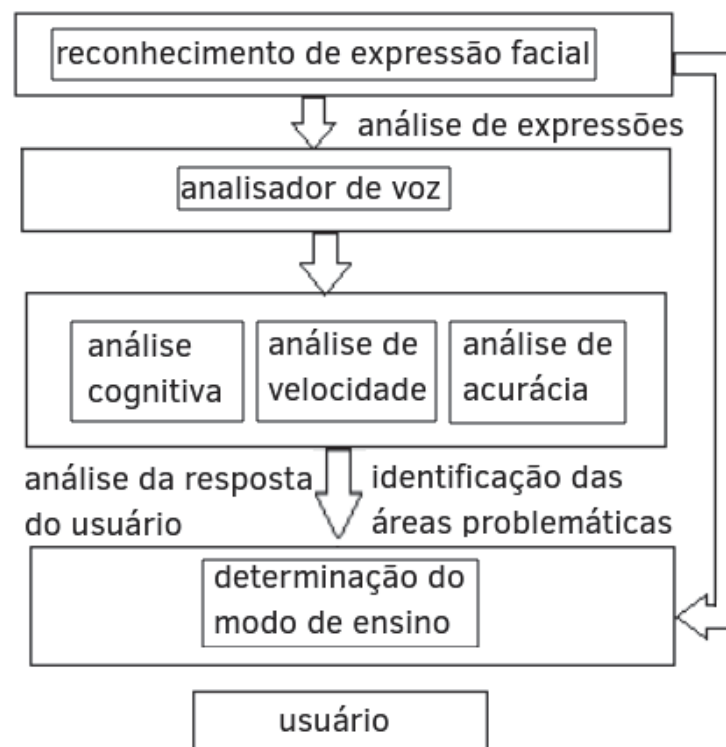


Figura 3.4: Diagrama de blocos do STIE.  
Fonte: Adaptado de Kanjilal (2014).



A expectativa é que este STIE melhore a experiência de aprendizagem, reduzindo o número de desistências de cursos online com a possibilidade de diminuição de tédio dos estudantes, fornecendo material de forma adaptada de acordo com os estados afetivos, cognitivos e capacidades (Kanjilal, 2014).

O principal diferencial da proposta da tese com o trabalho de Kanjilal (2014) é o fato de usar EEG juntamente com análise de faces, e também ser uma abordagem modular que trabalha com *feedbacks* textuais, pois o trabalho citado não fornece intervenções estudiantis textuais, mas altera a forma de interação do estudante com o ambiente.

O trabalho de Mangaroska et al. (2022) aborda o estudo de estudantes enquanto realizam a resolução de problemas de programação em uma IDE (do inglês, *Integrated Development Environment*, onde a análise de dados é realizada de forma multimodal, verificando a dimensões cognitiva, metacognitiva e afetiva da aprendizagem. O objetivo foi analisar dados de câmera para análise da face, um rastreador ocular para saber o caminho que o olho realiza enquanto olha para a IDE e dados de atividade cerebral via EEG utilizando um BCI para que verifique uma possível associação entre as dimensões cognitiva e afetiva da aprendizagem com o desempenho do estudante e também em comparação ao seu conhecimento prévio.

O experimento foi realizado com quarenta estudantes de ciência da computação. E para estudar os processos cognitivos associados ao aprendizado, utilizaram a teoria da carga cognitiva e no modelo de processamento de informações humanas. A Figura 3.5 exibe a configuração do experimento proposto, a configuração dos eletrodos para EEG utilizados e a área de interesse estudado.

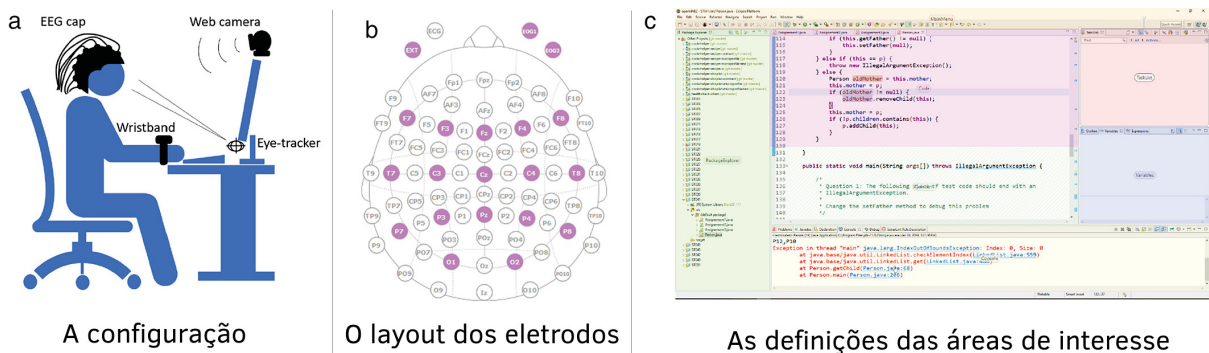


Figura 3.5: Projeto do experimento. (a) A configuração, (b) o layout do eletrodos EEG (c) as áreas de interesse definidas no Eclipse.

Fonte: Adaptado de Mangaroska et al. (2022).

Concluí-se que a atenção, pensamento convergente e frustração foram positivamente correlacionados com a programação bem-sucedida (desempenho) dos estudantes. Carga cognitiva, carga de memória e tédio foram negativamente correlacionados com o desempenho dos alunos e normalmente manifestados por participantes de baixo desempenho (Mangaroska et al., 2022).

Mesmo que o trabalho de Mangaroska et al. (2022) utilize EEG e *webcam* para identificação de estados afetivos, esta tese difere do trabalho citado pelo fato de não usar *feedbacks* em processo e não estar relacionado com um ambiente web. A proposta da tese é realizar um estudo que usa *feedbacks* para verificar mudanças de estados afetivos, onde no final, um *ranking* de melhores intervenções pode ser elaborado.

### 3.4 COLETA DE EEG COM OPENBCI

O trabalho de Xu et al. (2018b) cita que existem muitas tentativas de estudo entre BCI e STI. No entanto, ainda existem muitos desafios neste domínio de pesquisa que são:

- Desafios da perspectiva da análise de dados do EEG: Em comparação com o eletrocardiograma (ECG), os dados do EEG são muito mais fracos e facilmente perturbados por fatores externos, como o movimento dos sujeitos e o ruído ambiente. A aquisição de dados de EEG se torna o primeiro desafio, relacionado a como melhorar a qualidade dos dados e remover artefatos. Do ponto de vista da aplicação de ensino, os dados do EEG devem ser gravados um longo período de aprendizagem para a detecção de emoções. Os métodos tradicionais de análise de dados são usados para medir a resposta do cérebro que é o resultado direto do evento curto. Encontrar um método de análise de dados apropriado para o período de aprendizagem é outro desafio.
- Desafios do "do laboratório para a aplicação educacional": O *headset* BCI para coleta de EEG é um dispositivo específico e caro, que era comumente aplicado apenas na área da saúde na área de saúde. O mais simples geralmente custa várias centenas de dólares e sua precisão de teste não alcança os requisitos de reconhecimento de emoções. Se os headsets de EEG esperam ser amplamente utilizados no BCI para STI, há dois desafios: como reduzir o custo e como melhorar a precisão do teste.

As BCIs são dispositivos de comunicação promissores entre humanos e máquinas (Frey, 2016). As baseadas em técnicas não invasivas de neuroimagem, como o EEG, têm muitas aplicações, porém a disseminação da tecnologia é limitada, em parte por causa do preço do hardware. Frey (2016) comparou dois amplificadores EEG, o grau de consumo OpenBCI e o nível clínico g.tec g.USBamp. Para isso, empregou-se uma montagem original, baseada na gravação simultânea do mesmo conjunto de eletrodos. Dois conjuntos de gravações foram realizados. Durante o primeiro experimento, foi utilizado um adaptador simples com conexão direta entre os amplificadores e os eletrodos. Então, em um segundo experimento, tentou-se descartar qualquer interferência possível que um amplificador poderia causar ao outro adicionando diodos "ideais" ao adaptador. Os resultados sugerem que a placa OpenBCI - ou uma solução semelhante baseada no chip ADS1299 - pode ser uma alternativa eficaz aos dispositivos clínicos de EEG, onde mesmo que supere o OpenBCI, este último fornece leituras de EEG muito próximas, resultando na prática de uma precisão de classificação que pode ser adequada para popularizar os usos da BCI.

Rashid et al. (2018) também realizou um estudo de desempenho do ADS1299 em relação a um sistema baseado em laboratório de alta qualidade. Duas tarefas motoras de membro inferior individualizadas foram realizadas por vinte e dois participantes saudáveis. A energia registrada nas bandas EEG *delta*, *theta*, *alpha* e *beta*, a taxa de potência entre as tarefas motoras, o ruído pré-movimento e a relação sinal-ruído foram obtidas para avaliação. A amplitude e o tempo do pico negativo nos potenciais corticais relacionados ao movimento extraídos dos dados do EEG também foram obtidos. Usando modelos mistos lineares, não foram encontradas diferenças estatisticamente significativas ( $p > 0,05$ ) em nenhuma dessas medidas entre os dois sistemas. Essas descobertas foram apoiadas pela avaliação da similaridade de cosseno, diferenças de forma de onda e mapas topográficos. Houve diferenças estatisticamente significativas ao longo das tarefas motoras em ambos os sistemas. Concluí-se que o desempenho do ADS1299 é análogo ao de um sistema baseado em laboratório em um registro de EEG de baixa frequência (<40 Hz).

Os trabalhos de Frey (2016) e Rashid et al. (2018) foram duas bases para a decisão de trabalhar com EEG utilizando o OpenBCI na tese, em conjunto com as expressões faciais.

### 3.5 TRABALHOS CORRELATOS E A TESE

Todos os trabalhos citados neste capítulo contribuíram para a decisão de trabalhar nesta tese com a elaboração de uma abordagem que analise os estados afetivos, utilizando o plano baseado em quadrantes *valence* e *arousal*, pra que seja exibido *feedbacks* em processo, ou seja, antes da resposta, utilizando dados da ativação neural via EEG através do OpenBCI, que serão processados com FEA (que utiliza seis eletrodos, F3, F4, AF3, AF4, A1 (terra) e A2 (terra), e faces com dados processados via *deep learning*. Esta abordagem será apresentada no próximo capítulo é necessária para a realização do estudo experimental para análise dos *feedbacks*, comparando com dados do grupo controle, que não vêm o *feedback* e experimental, que vêm o *feedback*, e também para verificar quais foram as intervenções que melhor ajudaram o estudante.

## 4 METODOLOGIA DA ABORDAGEM NEURAFFEED

Este capítulo apresenta a visão geral da abordagem **NeurAFFeed** para a realização do estudo proposto. Como acontece a coleta e análise de dados de EEG e face, como funciona o módulo afetivo para STI *feedbacks* e como o AVA os exibe para o estudante durante as atividades propostas.

### 4.1 VISÃO GERAL

Antes de mostrar a visão geral, faz-se necessário um apanhado sobre o que pretende-se fazer de modo geral. Segundo Yamamoto et al. (2021), fornecer *feedback* às atividades de aprendizagem é uma das questões mais importantes para realizar a aprendizagem adaptativa. O *feedback* apresentado ao estudante **depois da resposta** da atividade, chama-se "*feedback* pós-processo", e o *feedback* apresentado ao estudante **durante** a atividade, ou seja, **antes da resposta**, chama-se de "*feedback* em processo". Este último tipo de intervenção foi pouco explorado em comparação ao "pós-processo", abrindo grandes possibilidades de pesquisa. Quando um estudante fica frustrado durante algum estágio da atividade, o *feedback* em processo se torna uma importante via.

O objetivo deste trabalho é realizar um estudo para análise de *feedbacks* em processo, e para isso, se faz necessário elaborar e implementar uma abordagem chamada **NeurAFFeed** que possibilita tais estudos. A visão geral desta abordagem é apresentada na Figura 4.1, onde cada etapa é identificada por um número que serão explicados a seguir.

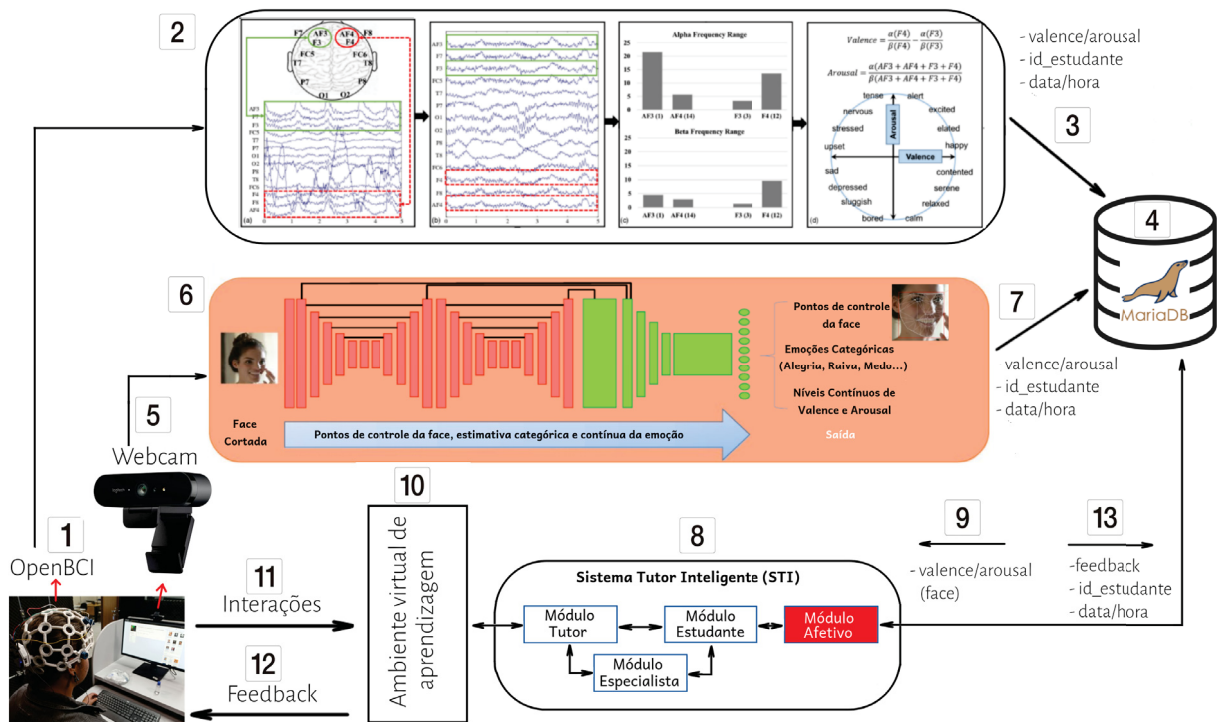


Figura 4.1: Visão Geral da abordagem **NeurAFFeed**, utilizada para a realização do estudo proposto. Fonte: Própria, exceto etapa 2 (adaptado de Hwang et al. (2018)) e etapa 6 (adaptado de Toisoul et al. (2021)).

A **NeurAFFeed** é uma abordagem modular que trabalha com a coleta, análise e armazenamento de atividade neural via EEG e de imagens de faces para identificação de estados afetivos *valence* e *arousal* para que um módulo afetivo para STI realize a estratégia de escolha de *feedback* em processo (antes da resposta, durante a atividade) de acordo com tais valores emocionais e apresente ao estudante na forma de notificações em um AVA. Seu nome vem da união das palavras **neural**, **affective states** (estados afetivos em inglês), **face** e **feedback**. A abordagem é modular pela possibilidade de trocar a análise de EEG, de Face, o AVA e o SGBD.

A abordagem **NeurAFFeed** é formada por três partes:

- Ferramentas e algoritmos para Coleta e análise de atividade neural via EEG e face (1, 2, 3, 4, 5, 6 e 7);
- Módulo afetivo para STI encarregado de verificar o estado afetivo do estudante e assim exibir ou não o *feedback* de acordo com uma estratégia (8 e 9);
- AVA com objetivo de exibir questões de linguagem de programação e possui um *plugin* que recebe o *feedback* vindo do STI e exibe ao estudante. (10, 11, 12, 13).

#### 4.2 COLETA E ANÁLISE DE ATIVIDADE NEURAL VIA EEG E FACE

Para realizar a extração de dados de EEG, foi utilizado o OpenBCI, com placa Cyton e com a impressão dos arquivos STL do Ultracortex, que foram baixadas da internet (Ultracortex, 2022). As ferramentas utilizadas para o fatiamento (técnica de corte em várias camadas) foram o RepetierHost e o Slic3r. As imagens da Figura 4.2 ilustram estes processos. A etapa de montagem pode ser vista com detalhes no Apêndice A.

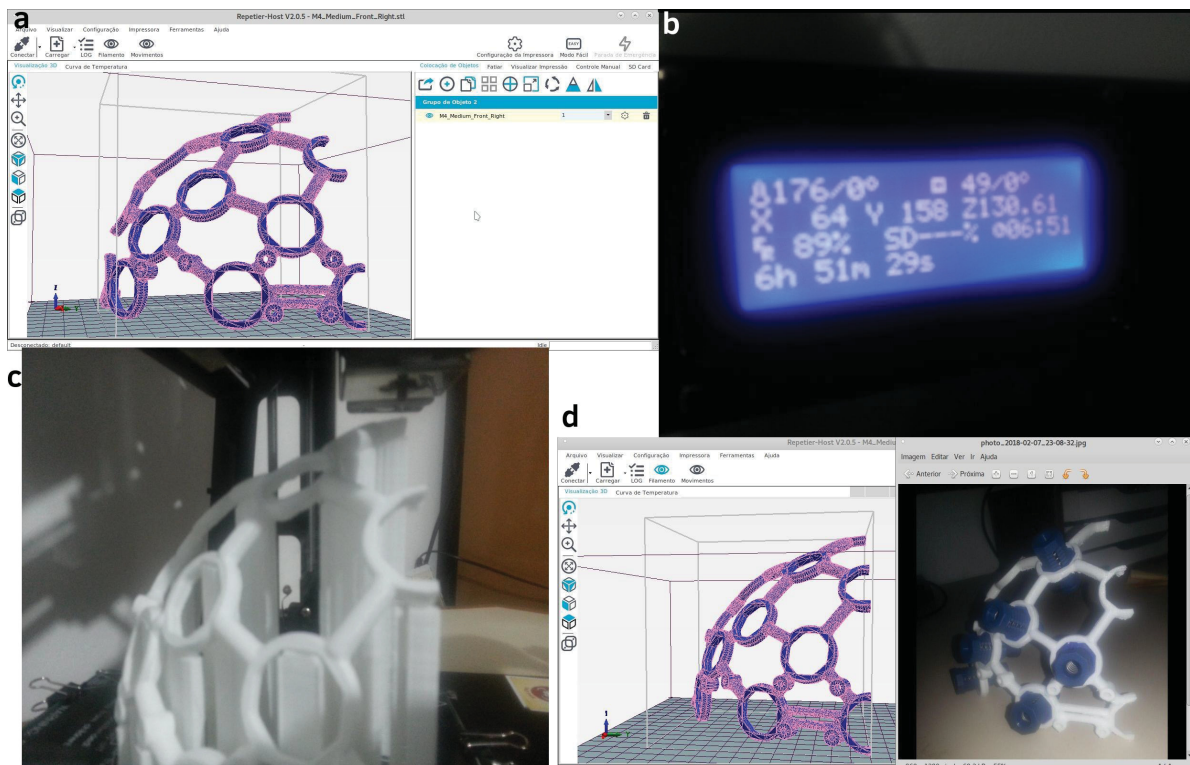


Figura 4.2: Etapas da impressão do headset: **a.** Carregamento dos arquivos STL no RepetierHost; **b.** Configuração da impressora 3D; **c.** impressão do headset; **d.** comparação do modelo com impressão.

Fonte: Própria.

Na parte eletrônica, foi utilizada a placa Cyton com oito canais, sem a necessidade da utilização da placa Daisy (16 canais), pois foi necessário apenas quatro canais, F3, F4, AF3 e AF4. Para alimentação do Cyton, foi utilizado uma bateria de Lipo de 3.7V e 450mAh e um carregador via USB. Quatro fios foram utilizados para levar cada eletrodo ao seu respectivo canal no na placa OpenBCI e **eles não se tocam em momento algum**, evitando assim problemas de ruído, sendo que o próprio OpenBCI resolve este problema de ruídos através de fios terras ligados aos lóbulos da orelha dos estudantes. O *dongle bluetooth* para recepção de dados EEG no computador estava há trinta centímetros do OpenBCI para não haver perdas de pacotes, testes foram realizados via *Brainflow* e constatou-se que não havia perda de pacotes.

O estudante irá vestir o OpenBCI (**etapa 1** da Figura 4.1), e seus sinais elétricos cerebrais serão coletados para análise (**etapa 2**), que consiste na utilização das técnicas do FEA (Lewis et al., 2007; Blaiech et al., 2013), que usam quatro canais na área do lobo frontal, os eletrodos F3 e F4 no lobo frontal e os eletrodos AF3 e AF4 na área anterior-frontal, conforme Figura 4.3.




Figura 4.3: Localização dos eletrodos F3, F4, AF3 e AF4 (em vermelho) segundo o sistema internacional 10-20  
Fonte: Adaptado de OpenBCI (2022a).

Após isso, foram calculados os valores médios do PSD das faixas de frequência alfa e beta para estes sinais. O PSD mede a distribuição média de energia em função da frequência de um sinal. O PSD médio é expresso como um valor logarítmico (decibel), que pode ter valor positivo ou negativo. Em seguida, as dimensões *valence* e *arousal* são calculadas usando os indicadores PSD médios e FEA, com base nas Equações 4.1 e 4.2.

$$Valence = \frac{\alpha(F4)}{\beta(F4)} - \frac{\alpha(F3)}{\beta(F3)} \quad (4.1)$$

$$Arousal = \frac{\alpha(AF3 + AF4 + F3 + F4)}{\beta(AF3 + AF4 + F3 + F4)} \quad (4.2)$$

onde  $\alpha(i)$  e  $\beta(i)$  = PSD da faixa de frequência alfa e beta obtidos a partir do  $i$ -ésimo canal do sinal EEG.

Especificamente, uma *valence* positiva está associada a uma ativação relativamente maior da área frontal esquerda, enquanto uma *valence* negativa está mais relacionada a uma ativação relativamente maior da área frontal direita. A Equação 4.1 indica uma diferença relativa de ativações entre duas áreas para mostrar o nível de *valence*. Embora não exista um intervalo predefinido de níveis de *valence*, um valor mais positivo significa emoção mais agradável com mais ativação da área esquerda do que da direita. Por outro lado, a Equação 4.2 indica o nível de *arousal* calculando a razão alfa e beta (Lewis et al., 2007; Blaiech et al., 2013). Da mesma forma, um maior valor de *arousal* indica o estado emocional mais ativo do indivíduo. Estes valores serão armazenados (**etapa 3**) nas tabelas do banco de dados do SGBD MariaDB (**etapa 4**).

Para o reconhecimento de *valence* e *arousal* da face, foi utilizado uma *webcam* para aquisição de dados (**etapa 5**). Para a análise, foi utilizada a biblioteca AffectNet (Mollahosseini et al., 2019). Para sua aquisição, foi necessária a solicitação via site do projeto (Mahoor, 2022), onde foi disponibilizado um *link* para download de 120GB de conteúdo. A classificação utilizada foi utilizado o treinamento de uma arquitetura de rede neural profunda, utilizando o EmoNet como base para treinamento (Toisoul et al., 2022) para analisar o efeito facial em condições naturalistas com alto nível de precisão descrita em (Toisoul et al., 2021). Essa proposta reconhece a face, recortando-a e então é realizado a integração do alinhamento de faces, utilizando *landmarks*, que são os pontos de controle da expressão facial, e estima conjuntamente emoções categóricas e contínuas em uma única passagem (**etapa 6**), tornando-a adequada para esta tese por sempre estar trabalhando para fornecer o *feedback* "em processo". Após o retorno da *deep learning* EmoNet com os valores de *valence* e *arousal* de acordo com os *landmarks* da face do estudante, estes dados são armazenados (**etapa 7**) nas tabelas do banco de dados do MariaDB (**etapa 4**).

### 4.3 MÓDULO AFETIVO PARA STI

Como visto no capítulo 2, um STI clássico é formado por módulo do estudante, responsável pela representação do conhecimento do aluno de acordo com os erros cometidos, módulo do tutor, responsável pelas estratégias de ensino, e do módulo do especialista, que armazena as informações e conteúdos que serão exibidas ao estudante (Nwana, 1990). Os STI clássicos não possuem módulos afetivos que possibilitam um entendimento maior do estudante e assim, tendem a não entender a emoção do estudante.

Neste trabalho foi desenvolvido um módulo afetivo para STI (**etapa 8**) e tem como objetivo analisar os registros de *valence* e *arousal* de EEG e face (**etapa 9**), e de acordo com estes dados, ele seleciona um *feedback* para ser exibido ao estudante.

Os *feedbacks* foram elaborados de acordo com a experiências em sala-de-aula, fornecendo dicas de acordo com as atividades, e também baseado no artigo (Mohanani et al., 2017), onde realizou-se um estudo indicado qual tipo de *feedback* poderia ser fornecido ao estudante de acordo com o quadrante em que se encontra, que resume-se em: se a emoção identificada pelo sistema de reconhecimento de padrões for *valence* baixa: dê uma mensagem como "você pode fazer isso!", isso pode motivar o estudante encontrar a resposta, ou "forneça informações (dicas) para o estudante". O tema escolhido foi a disciplina de linguagem de programação por ser um tema comum entre os estudantes de informática, que foi o público convidado a participar do experimento.

Cada questão possui uma dica e um *feedback* afetivo para motivação. Foi feito desta forma para realizar o estudo de verificação de qual tipo de *feedback* melhor ajudou o estudante. No total, foram cinco questões do assunto de linguagem de programação e para cada questão há dois *feedbacks*, um motivacional e uma dica sobre a questão. As questões e *feedbacks* são enumeradas abaixo:

1. Como podemos definir um Algoritmo?
  - *feedback 1*: Você sabia que um algoritmo é tipo uma receita de bolo?
  - *feedback 2*: Vamos lá, sei que você manja de algoritmos.
  
2. Como funciona um laço while?
  - *feedback 1*: Laços de repetições são bem importantes, pra deixar a máquina fazendo coisas repetitivas pra você. Você vai se sair bem nessa.
  - *feedback 2*: While é o enquanto algo não for falso, continue
  
3. Precisamos criar um vetor (array unidimensional) para armazenar 15 valores numéricos relativos aos salários de funcionários de uma empresa. Qual das seguintes instruções deve ser empregada para esse fim em um algoritmo?
  - *feedback 1*: Vetor é bem chato de entender, mas é bem útil, principalmente quando você entende que o primeiro elemento não é como todos esperam. Entender seu funcionamento ajuda bastante.
  - *feedback 2*: Real é o dinheiro brasileiro =)
  
4. Qual dos seguintes é um operador de concatenação de strings válido?
  - *feedback 1*: Concatenar é uma palavra chique da programação que significa "colocar junto"
  - *feedback 2*: Vamos lá, sei que você consegue, qual operador desses que da pra juntar coisas?
  
5. Qual a diferença entre os operadores lógicos E (AND) e OU (OR)?
  - *feedback 1*: Lógica é algo que nos faz humanos. Você como humano já manja de lógica naturalmente
  - *feedback 2*: uma dica legal é que na matemática OR é tipo MAIS (+) e AND é tipo vezes (x)

As mesmas questões serão apresentadas para todos os vinte participantes, tanto para o GC quanto para o GE. Porém, os *feedbacks* serão apresentadas apenas para o GE.

Assim que o valor afetivo chegar ao módulo afetivo, será chamado o módulo do estudante que armazenará este dado e enviará ao módulo do tutor que faz a estratégia para escolha do *feedback* para aquela atividade de acordo com o estado afetivo recebido.

O fluxograma (Figura 4.4) inicialmente verifica qual o estado afetivo do estudante de forma automática, utilizando os valores de *valence* e *arousal* identificados no módulo de inferência de estados afetivos (na linguagem python), oriundos do OpenBCI e da *webcam*. Após isso, há uma condicional que verifica se o estado afetivo identificado é negativo ou não, se não, ele finaliza o algoritmo, se sim, ele seleciona o primeiro *feedback* da questão atual que o estudante está analisando. Há mais uma condicional que verifica se o *feedback* selecionado já foi exibido ao estudante ou não, se sim, ele volta ao passo anterior e seleciona o segundo *feedback* da questão em análise, e verifica novamente se já foi exibido ao estudante, se não, ele exhibe ao estudante e finaliza o algoritmo.



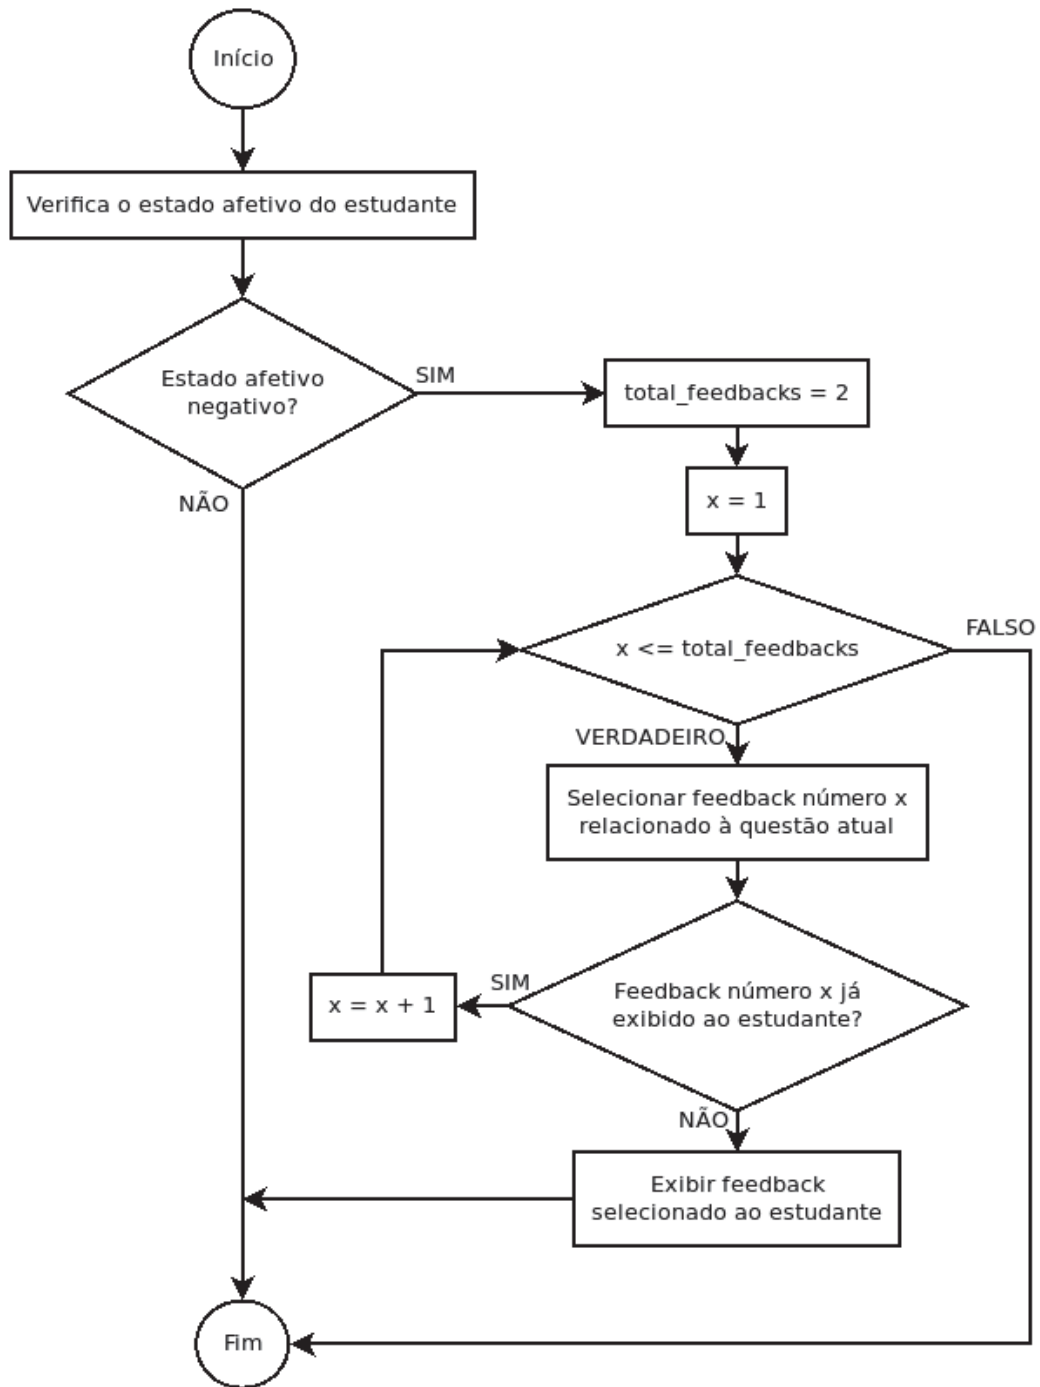


Figura 4.4: Fluxograma da escolha dos *feedbacks* pelo Módulo Tutor

No trabalho de Tiam-Lee e Sumi (2018), foi desenvolvido um sistema para a prática de programação que fornece *feedback* adaptativo com base na presença de confusão no estudante. Em Silva et al. (2019) há uma descrição de uma abordagem para ajudar os estudantes envolvidos em um sistema de tutoria de programação, fornecendo *feedback* durante o código de atividades de solução de problemas. O objetivo deste trabalho é semelhante aos trabalhos mencionados acima, no entanto, os *feedbacks* são exibidos automaticamente através de textos em uma notificação no AVA, permanecendo alguns segundos e depois apagando (semelhante à notificações em mídias sociais).

#### 4.4 AVA, EXIBIÇÃO DAS ATIVIDADES E APRESENTAÇÃO DE *FEEDBACKS*

Todo o processo da abordagem **NeurAFFeed** tem como objetivo a interação do estudante com as atividades e *feedbacks* que serão apresentados a ele. Para que isso aconteça, foi necessária a utilização de um ambiente que exiba as questões elaboradas para análise e resposta do estudante, e que também possibilite exibir as intervenções textuais em formato de notificações. Neste trabalho, optou-se por utilizar um ambiente *web* pela facilidade no acesso.

O AVA utilizado se chama Sisto (de Oliveira e Pinheiro, 2010) (**etapa 10**), que consiste em uma ferramenta web com estilo de mídia social com características de AVA, similar ao Moodle (Moodle, 2022). Este ambiente é dividido em três partes: lado esquerdo, centro e lado direito. À esquerda, contém o perfil do estudante e alguns links de navegação para recados, álbum de fotos e vídeos. Ao centro, tem o ambiente de interação. E do lado superior direito, tem os colegas fictícios que representa os outros estudantes que fazem conexão com você, e do inferior direito, as disciplinas cadastradas (Figura 4.5).

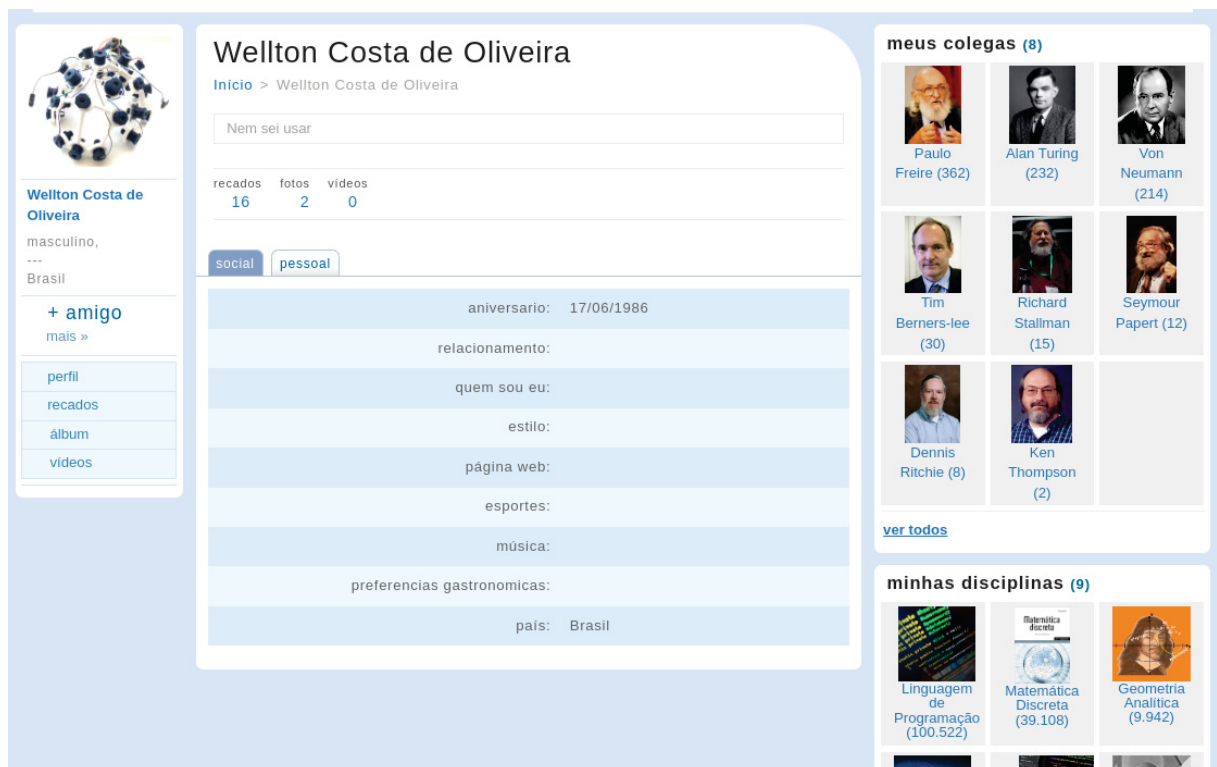


Figura 4.5: AVA web utilizado para apresentação das atividades e *feedbacks*.

Fonte: Própria.

A interface gráfica e a usabilidade deste ambiente são similares aos de uma mídia social. O estudante interage (**etapa 11**) se cadastrando e acessando uma das disciplinas disponíveis. As disciplinas existentes aparecem no lado direito inferior, como por exemplo, a disciplina de linguagem de programação, que simula um ambiente de uma sala-de-aula com atividades, colegas cadastrados, histórico de exercícios, fóruns, enquetes, documentos entre outras funcionalidades. Isso possibilita o estudante a interagir e participar das atividades propostas pelo professor de forma mais interativa.

Neste trabalho, o estudante clica em um botão chamado "responder atividades" e então aparecerá a primeira questão de cinco no total para a resposta, e no final, será apresentada a nota e o gabarito do estudante, mostrando qual questão ele acertou ou errou. Este etapa do ambiente pode ser visto na Figura 4.6.

[Início](#) | [Perfil](#) | [Página de recados](#) | [Amigos](#) | [Comunidades](#)
caetano.biss@hotmail.com | [Sair](#)

## Atividades de linguagem de programação

[Início](#) > [Atividades de linguagem de programação](#)

### 1 - Como podemos definir um Algoritmo?

a) Sequência de comandos ordenados, infinitos e ambíguos que são empregados para executar uma tarefa.

b) Sequência de instruções ordenadas, infinitas e não-ambíguas que são empregadas para executar uma tarefa.

c) Sequência de instruções ordenadas, finitas e não-ambíguas que são empregadas para executar uma tarefa.

d) Sequência de comandos ordenados, infinitos e não-ambíguas que são empregados para executar uma tarefa.

e) nda

#### Estudantes desta disciplina(8)

 Paulo Freire (362)	 Alan Turing (232)	 Von Neumann (214)
 Tim Berners-lee (30)	 Richard Stallman (15)	 Seymour Papert (12)
 Dennis Ritchie (8)	 Ken Thompson (2)	

[ver todos](#)

#### minhas disciplinas (9)

 Linguagem de Programação (100.522)	 Matemática Discreta (39.108)	 Geometria Analítica (9.942)
 Inteligência Artificial (9.290)	 Programação Web (6)	 Multimídia (3.403)

Figura 4.6: Ambiente Virtual de Aprendizagem exibindo uma questão da disciplina de Linguagem de Programação.  
Fonte: Própria.

Para exibir os *feedbacks* dentro do AVA (**etapa 12**), foi elaborado um *plugin* na linguagem javascript que manipula notificações em páginas web de acordo com as estratégias do tutor. Foi implementado utilizando as bibliotecas jQuery (2022) e Toastr (2022). Este *plugin* realiza requisições assíncronas via ajax através da função chamarTutor() ao módulo afetivo do STI, utilizando o arquivo "feedbacks.php" que faz uma análise dos dados de face e de EEG localizados nas tabelas correspondentes do MariaDB de acordo com a data e hora do registro, e com isso, faz uma contagem de quantas vezes o valor de *valence* aparece negativo, caso apareça oito vezes negativo em seguida, busca-se no banco um *feedback* correspondente daquela atividade e assim é exibido na forma de notificação de acordo com o tempo configurado no *plugin*.

O *feedback* fica em exibição para o estudante na tela do AVA por dez segundos depois desaparece, mas há a possibilidade de estender este tempo caso o estudante coloque o ponteiro do mouse em cima da notificação, desaparecendo no momento da retirada do ponteiro. Uma das contribuições muito relevantes deste *plugin* é sua possibilidade de sua portabilidade para outros AVA's que sejam feitas para funcionar na web. Para isso, é necessário inserir o código-fonte exibido abaixo dentro da página responsável por exibir as atividades, e claro, é preciso ter o servidor de análise de face e EEG, bastando alterar o endereço 127.0.0.1 pelo ip desejado. A possibilidade de se utilizar este *plugin* para comunicar, de forma minimalista, qualquer página web com o servidor que infere estados afetivos de acordo com a face e ativação neural via EEG de um estudante é uma das contribuições desta tese.

```
1 <link href="toastr.css" rel="stylesheet">
2 <script src="toastr.min.js"></script>
3 <script src="jquery-3.6.0.min.js"></script>
4
5 <script>
6   function chamarTutor(){
7
8     $.ajax({
9       method: "GET",
10      url: "http://127.0.0.1/sti/feedback.php",
11      success: function(text){
12
13        //Caso o retorno informe um texto...
14        if(text!=""){
15
16          //Trava o ajax e prepara para exibir Feedback
17          $(document).ready( function() {
18
19            //Exibe feedback. Pode ser do tipo:
20            //success (verde), info (azul),
21            //warning (amarelo), error (vermelho)
22            toastr.info(text, "", {
23
24              //Quando a notificação desaparecer,
25              //apaga o feedback do banco e chama função ajax
26              onHide: function() {
27
28                $.ajax({
29                  method: "GET",
30                  url: "http://127.0.0.1/sti/feedback.php?limpar=ok",
31                })
32
33                //Chamada da função
34                chamarTutor();
35              }
36            });
37          });
38        } else {
39          //Caso não tenha retorno do ajax, solicita feedback
40          setTimeout(function() { chamarTutor(); }, 1000);
41        }
42      }
43    });
44  }
45  ajax();
46  //Configurações da notificação
47  toastr.options = {
48    "closeButton": true,
49    "progressBar": true,
50    "positionClass": "toast-bottom-left",
51    "timeOut": "10000",
52    "showDuration": "2000",
53    "hideDuration": "2000",
54    "extendedTimeOut": "2000",
55  }
56 </script>
```

Este *plugin* executa a função `ajax()` a cada segundo, chamando o arquivo `Federico.php` que faz uma consulta na tabela tutor que verifica quantas vezes o valor de *valence* da face aparece com valor negativo. Para definir um número de vezes em que o estudante precisa ficar com *valence* negativo para que apareça o *feedback*, foi usado o artigo de Bradbury (2016), em que comenta que o tempo de atenção de oito segundos para humanos reflete o tempo médio que uma pessoa gasta em uma página da web antes de procurar em outro lugar, e como neste estudo, cada valor de *valence* e *arousal* para face e EEG é registrado em um segundo.

Optou-se por utilizar oito registros negativos para que o *feedback* seja exibido ao estudante no AVA em forma de notificação por dez segundos, com possibilidade do estudante colocar o ponteiro do mouse em cima para pausar o tempo de dez segundos, desaparecendo assim que o ponteiro for retirado de cima. O tempo de dez segundos também reflete ao artigo de Bradbury (2016) com um acréscimo de dois segundos. Caso o estudante continue com *valence* da face negativo, o *plugin* exibirá o segundo *feedback* (afetivo). A Figura 4.7 exibe o *feedback* no canto inferior esquerdo.

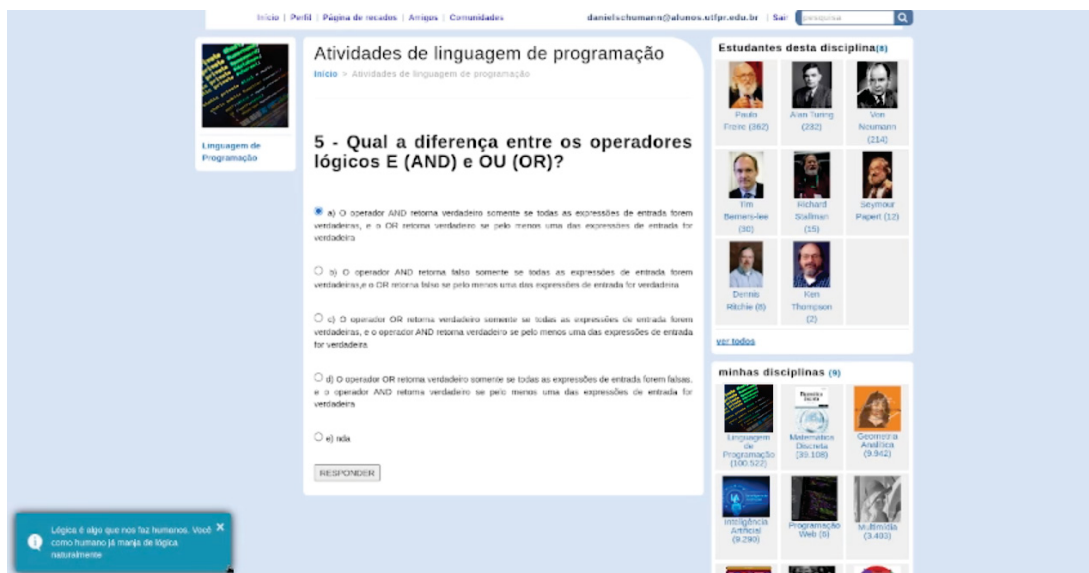


Figura 4.7: Exemplo de *feedback* exibido  
Fonte: Própria.

No momento em que aparece, o *feedback* é armazenado juntamente com o código de identificação do estudante e com a data, hora, minuto e segundo são armazenados na tabela tutor dentro do banco gerenciado pelo MariaDB (**etapa 13**).

Com isso, apresenta-se uma maneira de exibir *feedbacks* de acordo com os estados afetivos do estudante, processados através da atividade neural via EEG e da face para que o estudo proposto nesta tese possa ser realizados com uma análise de mudança de estados afetivos. O experimento da aplicação da abordagem **NeurAFFeed** será apresentado no próximo capítulo.

## 5 REALIZAÇÃO DO EXPERIMENTO

Neste capítulo é apresentada a metodologia científica utilizada, os participantes, os ambientes utilizados e a metodologia do experimento que utiliza a abordagem **NeurAFFeed** e os dados coletados.

### 5.1 METODOLOGIA CIENTÍFICA EXPERIMENTAL

Esta pesquisa segue a metodologia de pesquisa experimental. Para Gil et al. (2007), a pesquisa experimental consiste em determinar qual será o objeto de estudo, definir quais variáveis seriam capazes de influenciar os participantes do experimento, definir quais serão as formas de controle e de experimentação das consequências que as variáveis definidas produzem no objeto de estudo. Deve-se desenvolver a forma que será realizada a coleta de dados e submetida a testes para verificar a eficácia em mensurar os objetivos que a pesquisa se propõe (Gerhardt e Silveira, 2009). Já segundo Fonseca (2002):

A pesquisa experimental seleciona grupos de assuntos coincidentes, submete-os a tratamentos diferentes, verificando as variáveis estranhas e checando se as diferenças observadas nas respostas são estatística mente significantes. Os efeitos observados são relacionados com as variações nos estímulos, pois o propósito da pesquisa experimental é apreender as relações de causa e efeito ao eliminar explicações conflitantes das descobertas realizadas.

De acordo com essa definição, este trabalho selecionou os grupos para controle e para experimentação, e aplicou-se as variáveis estabelecidas que utilizam a abordagem **NeurAFFeed**, que consistem em resolver questões, exibindo *feedbacks* apenas ao GE, enquanto os estados afetivos extraídos dos dados de EEG e da face são armazenados, para que posteriormente sejam analisados estatisticamente para verificação se há diferença significativa entre GC e GE e as mudanças de estados afetivos que ocorreram antes e depois dos *feedbacks* exibidos, verificando também tais variações foram benéficas ou não.

### 5.2 ESTUDANTES VOLUNTÁRIOS PARTICIPANTES

Um total de vinte estudantes de graduação da UTFPR Francisco Beltrão, foram convidados e participaram do experimento, onde foram divididos em dois grupos:

1. Grupo Controle, que será chamado durante o trabalho de GC, com dez participantes que terão seus sinais EEG coletados pelo OpenBCI e de sua face por uma *webcam*. Este grupo não verá nenhum *feedback* em momento algum;
2. Grupo Experimental, que será chamado durante o trabalho de GE, com dez participantes que terão seus sinais EEG coletados pelo OpenBCI e de sua face por uma *webcam*. Este grupo será exposto aos *feedbacks* que aparecerão caso os registros de *valence* do estudante sejam muitas vezes negativos.

Para realizar deste experimento, foi necessária a aprovação de um projeto pelo Comitê de Ética da Universidade Tecnológica Federal do Paraná via Plataforma Brasil (PlataformaBrasil, 2022). O projeto foi aprovado sob o número *CAAE: 38246820.5.0000.5547*. Com isso, os estudante foram convidado a ler e assinar (caso aceite) o Termo de consentimento livre e esclarecido, permitindo o uso, análise e divulgação de seus dados coletados de forma anônima.

### 5.3 AMBIENTES PARA REALIZAÇÃO DO EXPERIMENTO

O ambiente utilizado para os experimentos foi a sala Q203, o estúdio de para gravação de multimídia e para estudos de Educação a distância (EAD) da UTFPR Campus Francisco Beltrão. Os ambientes foram divididos em três partes:

- Ambiente 1: Sala de extração de dados;
- Ambiente 2: Sala de monitoramento;
- Ambiente 3: Sala de espera.

Essas salas foram organizadas assim pois houve a necessidade de ter um ambiente agradável e confortável para o estudante, de se ter um lugar para monitorar e gravar a atividade do estudante no computador, mas sem estar no mesmo local para dar uma liberdade maior, e também pelo fato de alguns estudantes aguardarem até serem chamados. Nas próximas seções, estes ambientes são apresentados.

#### 5.3.1 Ambiente 1: Sala de extração de dados

Foi utilizado o estúdio para a extração de dados dos estudantes voluntários pois possui uma parede acústica que diminui consideravelmente sons externos que possam atrapalhar a concentração de quem estiver participando do experimento. Neste ambiente, uma mesa de estudo onde foi instalada contendo um monitor de 29 polegadas com uma webcam *Logitech brio c1000e 4K*, um teclado, um mouse e o OpenBCI para ser levado à cabeça do estudante pelo pesquisador. Ao lado desta mesa, há uma menor onde foi colocado um gabinete de computador *desktop* contendo a seguinte configuração:

- Modelo Computador: HP ProDesk 600 G5 SFF;
- CPU: Intel i5-9400F (6) @ 4.100GHz;
- GPU: AMD ATI Radeon HD 7450;
- Memória principal: 15853 MiB (16 GB);
- Sistema Operacional: Debian GNU/Linux bookworm x86\_64;
- Kernel: Linux versão 5.19.0-2-amd64;
- Interface Gráfica: GNOME 41;
- *Dongle bluetooth* USB para recepção dos dados dos sensores do OpenBCI.

Esta máquina possui duas funções, funciona como **cliente**, onde o estudante acessa o AVA, responde as atividades e verifica no final sua nota, erros e acertos, e funciona como **servidor**, onde há os algoritmos de análise dos dados da face e de EEG para identificação de seus respectivos valores de *valence* e *arousal*, que são armazenados em tabelas de um banco de dados gerenciado pelo MariaDB, que será acessado pelo módulo afetivo para que o tutor faça sua estratégia de escolha e exibição do *feedback* no AVA.

Uma câmera da marca Sony foi instalada para gravação do ambiente durante a participação do estudante. Também há quatro refletores instalados no teto utilizados para aumentar a luminosidade do ambiente. A Figura 5.1 mostra a sala.




Figura 5.1: Ambiente 1: sala para extração de dados  
Fonte: Própria.

Por conta dos refletores, que ficaram ligados durante todo o experimento, a visibilidade da face dos participantes foi bastante clara, ajudando assim o algoritmo de identificação de estado afetivo. Todo o experimento foi gravado pela câmera ambiente para uma análise posterior ao experimento.

### 5.3.2 Ambiente 2: Sala de Monitoramento

O ambiente 2 consiste na sala de monitoramento que fica à frente da sala de extração, separadas por um vidro transparente, que possibilita o estudante ver sinais feitos pelo pesquisador que é a instrução para o começo do experimento (Figura 5.2).



Figura 5.2: Ambiente 2: Sala de monitoramento  
Fonte: Própria.



Nesta sala há um monitor que está ligado ao mesmo computador que está na sala de extração, servindo para fazer o seu monitoramento. Foi usado para visualizar a captura feita pelo software *OBS Studio* (OBS, 2022) da tela que está dividida em três partes:

1. O navegador web com o AVA aberto sendo utilizado pelo estudante;
2. O terminal dividido em duas partes mostrando, os valores de *valence* e *arousal* identificados através dos dados extraídos pelos eletrodos F3, F4, AF3 e AF4 via OpenBCI de forma *online* e os valores de *valence* e *arousal* identificados através da face identificada pela *webcam*, também de forma *online*;
3. A imagem da *webcam* do estudante com sua face identificada com os *landmarks*, que são os pontos de controle conectadas com linhas brancas. A Figura 5.3 exibe o *OBS Studio* gravando a tela de um participante exibido no monitor da sala de monitoramento.

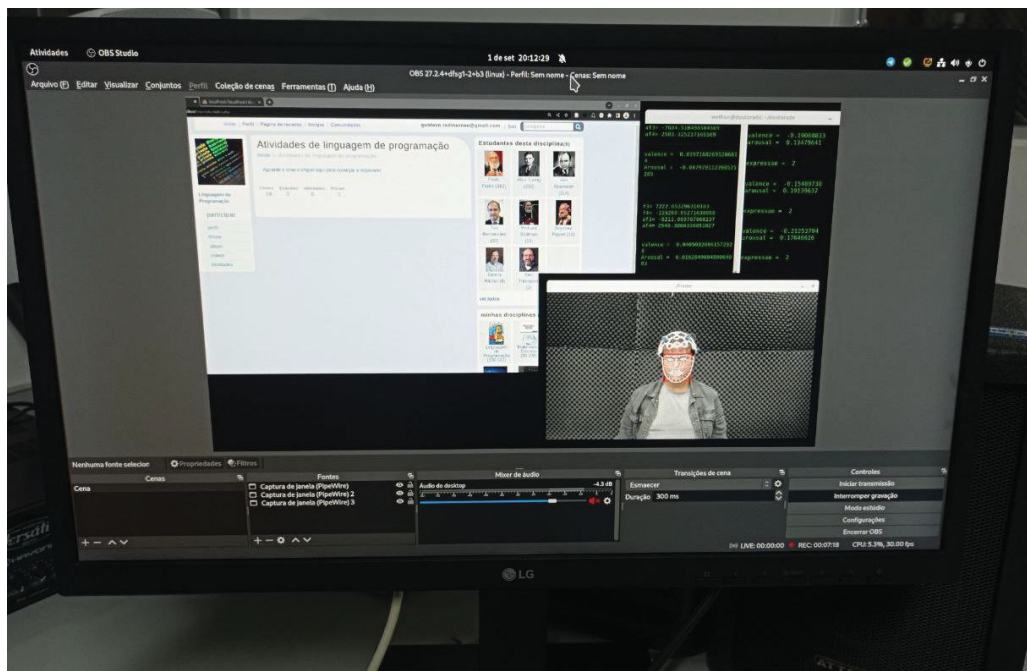


Figura 5.3: Software OBS Studio capturando a tela do estudante  
Fonte: Própria.

Com isso, foi possível registrar toda a atividade dos estudantes durante seus experimentos para uma análise posterior individual. Porém, vale ressaltar que o sigilo exigido pelo comitê de ética foi respeitado e estes dados são exclusivamente para uso nesta pesquisa.

### 5.3.3 Ambiente 3: Sala de Espera

O ambiente 3 consiste na sala de espera localizada ao lado externo do estúdio, com cadeiras e mesas para que os estudantes voluntários possam esperar sua participação no experimento.

Alguns procedimentos foram tomados para quem ficasse no experimento, tal como a explicação de como o experimento iria ocorrer para possíveis dúvidas serem respondidas, solicitação para preenchimento do Termo de Consentimento Livre e Esclarecido e para Uso de Imagem e Som de Voz exigido pelo comitê de ética e o pedido de silêncio para que não interferisse no experimento (Figura 5.4)



Figura 5.4: Sala de Espera  
Fonte: Própria.

Com esta sala, foi possível ter um ambiente de recepção e acomodação dos estudantes antes da participação de seu experimento. E vale sempre ressaltar que haviam máscaras, álcool em gel e panos para que os participantes ficassem seguros e protegidos contra doenças infectocontagiosas.

#### 5.4 METODOLOGIA DO EXPERIMENTO

Cada participante foi convidado a entrar na sala, sentar-se na cadeira e preencher um formulário no AVA contendo nome, email, cpf e gênero. Após isso, foi explicado que o navegador contendo o AVA, sua imagem da *webcam* e os valores de coleta de dados de face e EEG seriam registrados. Também foi informado que todo o ambiente da sala seria gravado, tanto áudio quanto vídeo. Em seguida foi solicitado a permissão do estudante para que o pesquisador colocasse o OpenBCI, com os quatro eletrodos F3, F4, AF3 e AF4 em sua cabeça, pedindo para que qualquer dor sentida fosse relatada.

Após isso, foram iniciados os programas escritos em python que coletam e analisam os dados da face chamado "face.py", e o que coleta e analisa dados de EEG chamado "eeg.py". As saídas do processamento são os valores de *valence* e *arousal* da face e do EEG, e são armazenados pelos mesmos programas nas tabelas *face\_experimento* e *eeg\_experimento* no banco de dados gerenciado pelo MariaDB.

Após o cadastro, o estudante acessará sua página inicial. Ao total, ele precisa responder a cinco questões de linguagem de programação e para cada uma há dois *feedbacks*. Essas questões foram apresentadas para todos os vinte participantes, tanto para o GC quanto para o GE, porém, os *feedbacks* foram apresentados apenas para o GE. Quando o estudante inicia uma questão, um contador de *valence* negativo da face é iniciado começando de zero, caso este contador chegue ao número de oito emoções negativas, é apresentado um *feedback* para o estudante. Caso uma emoção seja positiva, o contador é zerado e é iniciado novamente. Conforme já explicado no capítulo 4, este valor de oito emoções negativas está relacionado com o tempo de atenção em páginas web comentado em Bradbury (2016).

A Figura 5.5 mostra uma participante do GE sendo monitorada antes da exibição de um *feedback*.

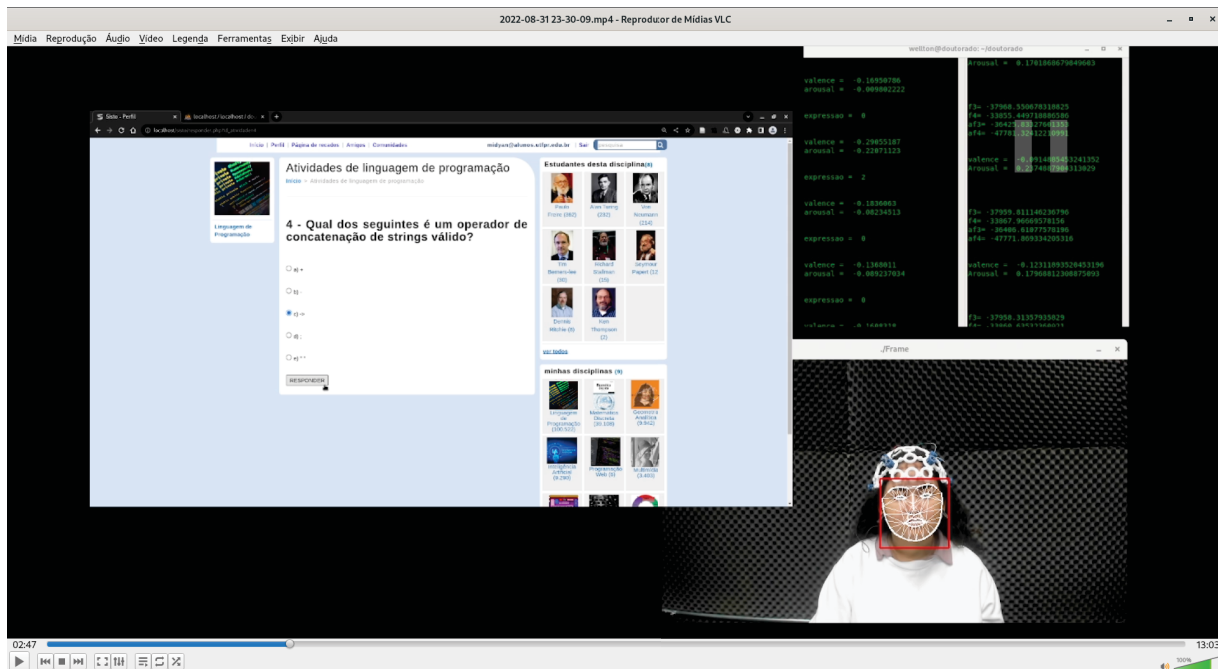


Figura 5.5: Estudante do GE antes de exibir o *feedback*

Fonte: Própria.

A Figura 5.6 mostra um *feedback* sendo exibido do lado inferior esquerdo. Isso ocorre quando o número de emoções negativas chega a oito, conforme explicado no capítulo 4. Após a exibição, o contador é zerado novamente.

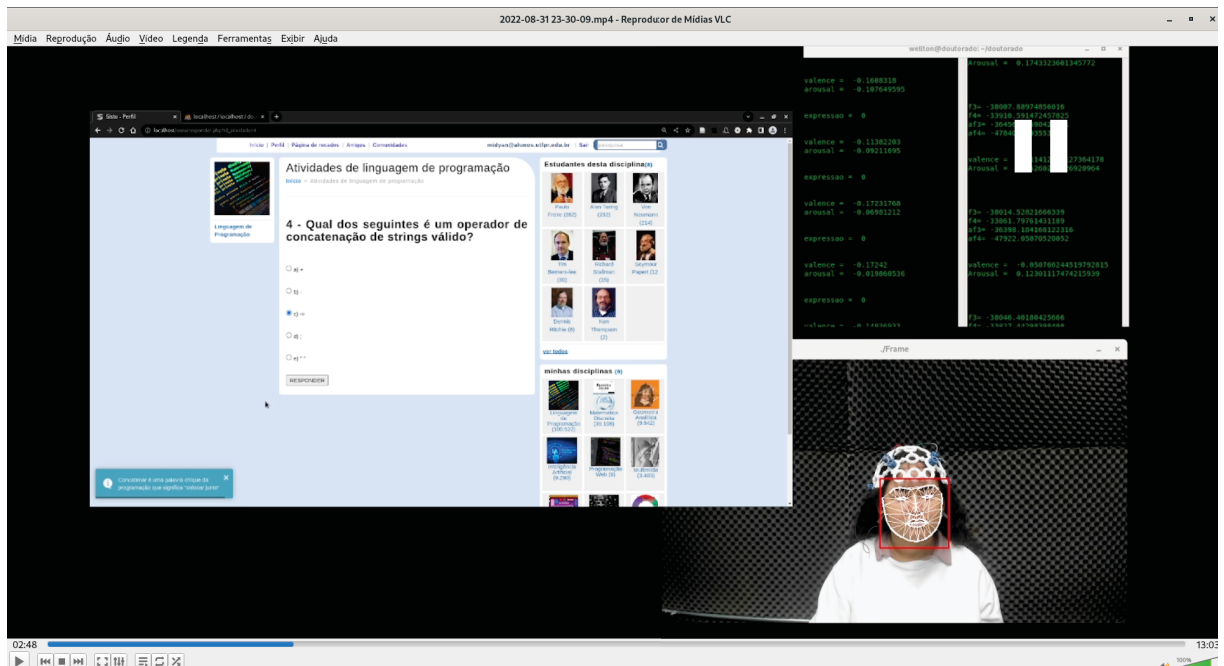


Figura 5.6: Estudante do GE enquanto exibe o *feedback*

Fonte: Própria.

## 5.5 DADOS COLETADOS

Os dados coletados foram armazenados nas tabelas do MariaDB chamadas *face\_experimento* e *eeg\_experimento*. Após os experimentos realizados, foram coletados dados de *valence* e *arousal* do EEG e da Face de dez alunos do GC (variando o id um ao id dez), e de dez estudantes do GE (variando do id onze ao id vinte), juntamente com a data, hora, minuto e segundo exato da coleta. Também foi armazenado os dados dos *feedbacks* exibidos aos estudantes do GE.

### 5.5.1 Coleta de dados do GC

O GC começa do estudante 1 ao estudante 10. Para os dados de EEG, foram coletados 64.575 dados de *valence* e *arousal*. Para os dados de Faces, foram coletados 64.967 dados de *valence* e *arousal*. A Figura 5.7 exibe um trecho das tabelas *face\_experimento* e *eeg\_experimento* com a coleta do último estudante do GC (10).

id	id_usuario	valence	arousal	horario
64951	10	-0.024417225271463394	0.07512792944908142	2022-08-31 21:03:09
64952	10	-0.037306610494852066	0.12558403611183167	2022-08-31 21:03:09
64953	10	-0.10553699731826782	0.2192467600107193	2022-08-31 21:03:21
64954	10	-0.061710793524980545	0.2065588805675507	2022-08-31 21:03:26
64955	10	-0.0568838492035866	0.20231585204601288	2022-08-31 21:03:26
64956	10	-0.07865285873413086	0.21597623825073242	2022-08-31 21:03:26
64957	10	0.07411569356918335	0.1354392021894455	2022-08-31 21:03:54
64958	10	0.02832871302962303	0.1315016895532608	2022-08-31 21:03:54
64959	10	-0.10736590623855591	0.20684103667736053	2022-08-31 21:03:55
64960	10	-0.08042256534099579	0.18028709292411804	2022-08-31 21:03:55
64961	10	0.07967069745063782	0.22698535025119781	2022-08-31 21:03:56
64962	10	0.041650231927633286	0.21708494424819946	2022-08-31 21:03:56
64963	10	0.17020899057388306	0.18036144971847534	2022-08-31 21:03:56
64964	10	-0.12131765484809875	0.2131544053554535	2022-08-31 21:03:57
64965	10	-0.10391664505004883	0.18551483750343323	2022-08-31 21:03:57
64966	10	-0.07642462849617004	0.18549668788909912	2022-08-31 21:03:57
64967	10	-0.06601439416408539	0.18080303072929382	2022-08-31 21:03:58
64968	11	-0.002897340804338455	0.05635729432106018	2022-08-31 21:08:40
64969	11	0.05963699147105217	0.10806173086166382	2022-08-31 21:08:40
64970	11	0.07545232772827148	0.08874765038490295	2022-08-31 21:08:40
64971	11	0.05527856573462486	0.06911695003509521	2022-08-31 21:08:40

Figura 5.7: Trecho dos dados de Face EEG coletados do GC

Fonte: Própria.

### 5.5.2 Coleta de dados do GE

O GE começou do estudante 11 e termina no estudante 20. Para os dados de EEG, foram coletados 32.550 dados de *valence* e *arousal*. Para os dados de Faces, foram coletados 33.100 dados de *valence* e *arousal*. Vale ressaltar que o calculo feito para saber o valor dos dados coletados do GE foi: Para os dados de EEG, a diferença entre 97125 e 64575 dá 32550. Para dados de Face foi a diferença de 98075 e 64975 é 33100. A Figura 5.8 exibe um trecho das tabelas *face\_experimento* e *eeg\_experimento*, onde o GE com a coleta do primeiro estudante (11) ao último estudante do GC (id número 20).

Banco de dados: doutorado » Tabela: face_experimento					Banco de dados: doutorado » Tabela: eeg_experimento				
id	id_usuario	valence	arousal	horario	id	id_usuario	valence	arousal	horario
98052	20	-0.18071869015693665	0.20271360874176025	2022-09-01 20:17:47	97103	20	0.24152045495826524	0.7037825671831188	2022-09-01 20:16:31
98053	20	-0.20082488656044006	0.1999296247959137	2022-09-01 20:17:47	97104	20	0.2913224584871067	0.71776763879722	2022-09-01 20:16:32
98054	20	-0.14270658791065216	0.21476179361343384	2022-09-01 20:17:47	97105	20	0.2585293213968075	0.681489615544804	2022-09-01 20:16:32
98055	20	-0.10547272861003876	0.1341034173965454	2022-09-01 20:17:48	97106	20	0.2927448894322161	0.6790026523992944	2022-09-01 20:16:32
98056	20	-0.19325633347034454	0.1491306573152542	2022-09-01 20:17:48	97107	20	0.3302869060271325	0.6963947382132715	2022-09-01 20:16:33
98057	20	-0.20481352508068085	0.22863325476646423	2022-09-01 20:17:48	97108	20	0.2792732614475165	0.6595180570663716	2022-09-01 20:16:33
98058	20	-0.20214515924453735	0.20445236563682556	2022-09-01 20:17:48	97109	20	0.3100791595378933	0.675201640304176	2022-09-01 20:16:33
98059	20	-0.18800020217895508	0.2121829390525818	2022-09-01 20:17:49	97110	20	0.3094885362703101	0.7124806750474421	2022-09-01 20:16:33
98060	20	-0.19469532370567322	0.2997277081012726	2022-09-01 20:17:49	97111	20	0.3057659146623415	0.7177851247753653	2022-09-01 20:16:34
98061	20	-0.21049371361732483	0.23478589951992035	2022-09-01 20:17:49	97112	20	0.32836869477432773	0.7137401217000997	2022-09-01 20:16:34
98062	20	-0.21104305982589722	0.22181329131126404	2022-09-01 20:17:50	97113	20	0.19785819956182635	0.7214793891470221	2022-09-01 20:16:34
98063	20	-0.22605153918266296	0.25111323595046997	2022-09-01 20:17:50	97114	20	0.226973790903736	0.711336347832136	2022-09-01 20:16:35
98064	20	-0.1712778956980133	0.2202797532081604	2022-09-01 20:17:50	97115	20	0.2301485579759266	0.7116503311872049	2022-09-01 20:16:35
98065	20	-0.19062526524066925	0.18767130374908447	2022-09-01 20:17:51	97116	20	0.23872355249311514	0.6884204422778761	2022-09-01 20:16:35
98066	20	-0.19759908318519592	0.1351451873779297	2022-09-01 20:17:51	97117	20	0.1862299917760037	0.7161456347445899	2022-09-01 20:16:36
98067	20	-0.20630379021167755	0.1907806694507599	2022-09-01 20:17:51	97118	20	0.2801659409419502	0.6756122661531639	2022-09-01 20:16:36
98068	20	-0.16005659103393555	0.16249053180217743	2022-09-01 20:17:52	97119	20	0.2939572819188891	0.7042087080464063	2022-09-01 20:16:36
98069	20	-0.19847244024276733	0.11814141273498535	2022-09-01 20:17:52	97120	20	0.22881304039217715	0.6549987580328918	2022-09-01 20:16:37
98070	20	-0.15526968240737915	0.16600100696086884	2022-09-01 20:17:52	97121	20	0.2546787737954114	0.6481906385481039	2022-09-01 20:16:37
98071	20	-0.14354410767555237	0.13326770067214966	2022-09-01 20:17:52	97122	20	0.21906713581502668	0.6321439934701603	2022-09-01 20:16:37

Figura 5.8: Trecho dos dados de Face e EEG coletados do GE  
Fonte: Própria.

### 5.5.3 Coleta de dados *feedbacks* apresentados ao estudante

No total foram 113 *feedbacks* apresentados aos estudantes do GE e foram coletados e armazenados na tabela tutor. Com isso, pode-se identificar exatamente como estava o valor de *valence* e *arousal* antes e depois do *feedback* para poder verificar se há diferença significativa entre os dois e se para o positivo ou negativo.

Banco de dados: doutorado » Tabela: tutor					
id	id_usuario	id_pergunta	feedback	valence_eeg	arousal_eeg
4186	14	4	Concatenar é uma palavra chique da programação que...	0.078830141367912	-0.11290061454
4503	17	4	Concatenar é uma palavra chique da programação que...	-0.006928123989471402	-0.18970600454
3291	11	4	Concatenar é uma palavra chique da	0.020494015015215618	-0.13360196471

Figura 5.9: Trecho da tabela tutor com *feedbacks* apresentados ao estudante do GE.  
Fonte: Própria.

Após a realização do experimento e com os dados nas suas respectivas tabelas, realizou-se a análise dos dados para responder às duas hipóteses que serão apresentadas no próximo capítulo.

## 6 ANÁLISE DOS RESULTADOS

Este capítulo apresenta a análise dos dados coletados no capítulo anterior, apresentando as hipóteses para análise, os resultados obtidos, a discussão realizada e as ameaças à análise do experimento.

### 6.1 HIPÓTESES PARA ANÁLISE

O objetivo deste trabalho é elaborar uma abordagem chamada **NeurAFFeed** que possibilite realizar um estudo no uso de *feedbacks*, fornecidos por um módulo para sistema tutor inteligente, para análise das mudanças de estados afetivos (variação de *valence* e *arousal*) do estudante utilizando dados de face através de uma *webcam*, e ativação neural via EEG, oriundos de uma BCI não invasiva e não-clínico chamado OpenBCI, enquanto realiza atividades em um AVA.

Com o intuito de satisfazer este objetivo, faz-se necessário a realização do estudo estatístico dos dados coletados no experimento descrito na seção anterior de acordo com a abordagem **NeurAFFeed** explicada no capítulo 4. Para isso foi criada duas hipóteses para a análise dos dados. As hipóteses formuladas para os experimentos são:

1. A primeira hipótese verifica se as mudanças afetivas acontecidas no GC e no GE (tanto nos dados de Face quanto de EEG) são iguais ou não, ou seja, se rejeita-se a hipótese nula ou não. Caso estejam em distribuições diferentes, verificar se estas mudanças foram para quadrantes preferíveis (quadrantes 1 e 4) ou foram para quadrantes não preferíveis (quadrantes 2 e 3), de acordo com Gottardo e Ricardo Pimentel (2018).
2. A segunda hipótese verifica quais são os *feedbacks*, apresentados aos estudantes do GE, que ocasionaram maior mudança afetiva para quadrantes preferíveis.

Tanto a primeira hipótese quanto a segunda hipótese serão analisadas realizando quatro estudos (dois para cada) com dados da face e outro estudo com dados de EEG, e são apresentados nas próximas seções.

### 6.2 ANÁLISE DA HIPÓTESE 1

A hipótese 1 indaga se o GC e o GE (tanto nos dado de Face e quanto nos dado de EEG) são iguais ou diferentes. Para isso, foi utilizado o teste de Shapiro-Wilk para verificar a normalidade dos dados de mudanças de estados afetivos tanto do GC quanto para o GE.

Para isso, inicialmente, foi necessário realizar a extração das mudanças afetivas dos dados gravados em banco. O estudo divide-se em duas partes: estudo com dados da face e estudo com dados de EEG.

#### 6.2.1 Estudo com dados da face

Foi realizada uma contagem de todas as mudanças afetivas acontecidas no GC e no GE dos dados de Face. O gráfico da Figura 6.1 exibe todas as mudanças afetivas ocorridas com os dados de Face no GC.




Figura 6.1: Mudanças afetivas ocorridas nos dados da face do GC

Fonte: Própria.

Para verificar a normalidade dos dados, foi realizada a normalização dos dados utilizando o algoritmo Min-Max. Após isso, foi aplicado o teste de Shapiro-Wilk para verificar a normalidade ou não da distribuição. Para os dados do GC, o valor estatístico foi de 0,49 e o valor p foi de  $2,03 \cdot 10^{-6}$  (ou 0,00000203). Como p é maior que 5% (nível de significância adotado na pesquisa  $\alpha = 0,05$ ), ou seja, como  $p < 0,05$ , então confirma-se a não-normalidade dos dados.

Agora para os dados do GE, o gráfico da Figura 6.2 exibe todos os dados de mudanças afetivas acontecidos com os dados de Face.




Figura 6.2: Mudanças afetivas ocorridas nos dados da face do GE

Fonte: Própria.

Para verificar a normalidade dos dados, foi realizada a normalização dos dados utilizando o algoritmo Min-Max. Após isso, foi aplicado o teste de Shapiro-Wilk para verificar a normalidade ou não da distribuição. Para os dados do grupo **experimental**, o valor estatístico foi de 0,55 e o valor p foi de  $6,11 \cdot 10^{-6}$  (ou 0,00000611). Como p é maior que 5% (nível de significância adotado na pesquisa  $\alpha = 0,05$ ), ou seja, como  $p < 0,05$ , então confirma-se a não-normalidade dos dados.

Na sequência foi aplicado o teste de Wilcoxon, para testar a hipótese nula já que as distribuições tanto do GC quanto do GE não são normais. Os resultados sinalizaram positivamente, com um grau de confiança de 95%, com valor  $p = 0,0309$  e teste wilcoxon=22, ou seja, os dados revelaram que existe diferença significativa (já que  $p < \alpha = 0,05$ ) em termos de mudanças afetivas entre os estudantes do GC e o GE. Assim, como  $p < \alpha$ , há evidências para dizer que essa diferença se deve aos *feedbacks* apresentados para o GE, restando saber se essa diferença é positiva ou negativa em se tratando de mudanças para quadrantes preferíveis (1 e 4) ou para quadrantes não preferíveis (2 e 3).

Para responder a esta questão, foi gerado o número total de mudanças de estados afetivos para o GC, com total de 7504, onde 2440 mudanças foram para quadrantes preferíveis (1 e 4) e

5064 foram para quadrantes não-preferíveis (2 e 3). O gráfico da Figura 6.3 exibe os valores totais de mudanças para quadrantes preferíveis (1 e 4) e para não-preferíveis (2 e 3) em porcentagem de forma **proporcional**.




Figura 6.3: valores totais de mudanças para quadrantes preferíveis (1 e 4) e para não-preferíveis (2 e 3) para os dados de faces do GC

Fonte: Própria.

Foi gerado também o número total de mudanças de estados afetivos para o GE, com total de 7504, onde 2440 mudanças foram para quadrantes preferíveis (1 e 4) e 5064 foram para quadrantes não-preferíveis (2 e 3). O gráfico da Figura 6.4 exibe os valores totais de mudanças para quadrantes preferíveis (1 e 4) e para não-preferíveis (2 e 3) em porcentagem de forma **proporcional**. Vale ressaltar que no GE foram exibidos os *feedbacks* aos estudantes de acordo com sua *valence* muitas vezes negativo.




Figura 6.4: Valores da porcentagem proporcional de mudanças para quadrantes preferíveis (1 e 4) e para não-preferíveis (2 e 3) para dados de faces do GE. Em comparação com o gráfico anterior, ocorreu um ganho de **14,9%**.

Fonte: Própria.

A partir destes dados, podemos concluir que o GE tem um **14,9%**, evidenciando que, estatisticamente falando, o GC e GE são diferentes onde o segundo teve mais incidências para os quadrantes preferíveis. Ou seja, há evidências de que tal ganho tem relação como os *feedbacks* apresentados ao GE.



## 6.2.2 Estudo com dados da EEG

Foi realizada uma contagem de todas as mudanças afetivas acontecidas no GC e no GE dos dados de EEG. O gráfico da Figura 6.5 exibe todas as mudanças afetivas ocorridas com os dados de EEG no GC.




Figura 6.5: Mudanças afetivas ocorridas nos dados de EEG do GC

Fonte: Própria.

Para verificar a normalidade dos dados, foi realizada a normalização dos dados utilizando o algoritmo Min-Max. Após isso, foi aplicado o teste de Shapiro-Wilk para verificar a normalidade ou não da distribuição. Para os dados do GC, o valor estatístico foi de 0,62 e o valor p foi de  $3.147 \cdot 10^{-5}$  (ou 0,00003147). Como p é maior que 5% (nível de significância adotado na pesquisa  $\alpha = 0,05$ ), ou seja, como  $p < 0,05$ , então confirma-se a não-normalidade dos dados.

Agora para os dados do GE, o gráfico da Figura 6.6 exibe todos os dados de mudanças afetivas acontecidos com os dados de EEG.




Figura 6.6: Mudanças afetivas ocorridas nos dados de EEG do GE

Fonte: Própria.

Para verificar a normalidade dos dados, foi realizada a normalização dos dados utilizando o algoritmo Min-Max. Após isso, foi aplicado o teste de Shapiro-Wilk para verificar a normalidade ou não da distribuição. Para os dados do grupo **experimental**, o valor estatístico foi de 0,64 e o valor p foi de  $4,29 \cdot 10^{-5}$  (ou 0,0000429). Como p é maior que 5% (nível de significância adotado na pesquisa  $\alpha = 0,05$ ), ou seja, como  $p < 0,05$ , então confirma-se a não-normalidade dos dados.

Na sequência foi aplicado o teste de Wilcoxon, para testar a hipótese nula já que as distribuições tanto do GC quanto do GE não são normais. Os resultados sinalizaram positivamente, com um grau de confiança de 95%, com valor  $p = 0,0230$  e teste wilcoxon = 20, ou seja, os dados revelaram que existe diferença significativa (já que  $p < \alpha = 0,05$ ) em termos de mudanças afetivas entre os estudantes do GC e o GE. Assim, como  $p < \alpha$ , há evidências para dizer que essa diferença se deve aos *feedbacks* apresentados para o GE, restando saber se essa diferença é positiva ou negativa em se tratando de mudanças para quadrantes preferíveis (1 e 4) ou para quadrantes não preferíveis (2 e 3).

Para responder a esta questão, foi gerado o número total de mudanças de estados afetivos para o GC, com total de 6349, onde 3095 mudanças foram para quadrantes preferíveis (1 e 4) e 3254 foram para quadrantes não-preferíveis (2 e 3). O gráfico da Figura 6.7 exibe os valores totais de mudanças para quadrantes preferíveis (1 e 4) e para não-preferíveis (2 e 3) em porcentagem de forma **proporcional**.




Figura 6.7: valores totais de mudanças para quadrantes preferíveis (1 e 4) e para não-preferíveis (2 e 3) para os dados de EEG do GC.

Fonte: Própria.

Foi gerado também o número total de mudanças de estados afetivos para o GE, com total de 7906, onde 4838 mudanças foram para quadrantes preferíveis (1 e 4) e 3068 foram para quadrantes não-preferíveis (2 e 3). O gráfico da Figura 6.8 exibe os valores totais de mudanças para quadrantes preferíveis (1 e 4) e para não-preferíveis (2 e 3) em porcentagem de forma **proporcional**. Vale ressaltar que no GE foram exibidos os *feedbacks* aos estudantes de acordo com sua *valence* muitas vezes negativo.

A partir destes dados, pode-se concluir que o GE tem um **12,5%**, evidenciando que, estatisticamente falando, o GC e GE são diferentes onde o segundo teve mais incidências para os quadrantes preferíveis.




Figura 6.8: valores de mudanças para quadrantes preferíveis (1 e 4) e para não-preferíveis (2 e 3), com dados de EEG do GE. Em comparação com o gráfico anterior, ocorreu um ganho de **12,5%**.

Fonte: Própria.

### 6.3 ANÁLISE DA HIPÓTESE 2

A hipótese 2 verifica quais são os *feedbacks*, apresentados aos estudantes do GE, que melhor ajudam na mudança afetiva para quadrantes preferíveis (1 e 4).

Procedimentos para este estudo: O tutor gravou em disco todos os *feedbacks* exibido para para os estudante, junto com a data/hora, id do feedback, id do estudante e id da atividade. Então, inicialmente foi identificado a hora exata da exibição do *feedback* para o estudante para assim criar uma janela de tempo entre o início da atividade e o horário da exibição, conseguindo assim identificar quais foram os valores de *valence* e *arousal* antes do *feedback*. Analisou-se se há um segundo *feedback*, caso sim, o horário desta segunda intervenção é usado na criação de nova janela entre o *feedback* anterior e o novo, identificando assim os valores afetivos para análise **antes** E **depois**. Caso não tenha uma segunda intervenção ou se já foi a segunda, uma última janela é criada entre o último *feedback* exibido até o fim da atividade, quando o estudante responde a pergunta. Com as janelas identificadas, é identificado o número de quadrantes preferíveis (1 e 4) e o número de quadrantes não-preferíveis (2 e 3) nesse intervalo de tempo, possibilitando o cálculo da porcentagem de quadrantes preferíveis **antes** do *feedback* e a porcentagem de quadrantes preferíveis **depois** do *feedback*. Isso é feito para cada *feedback* exibido e no fim, é feito uma diferença entre a porcentagem de quadrantes preferíveis **antes** e **depois** do *feedback*, retornando assim o ranking de qual intervenção ajudou o estudante a mudar seu estado afetivo para quadrantes preferíveis. Nas seções a seguir, o estudo é apresentado, inicialmente com os dados de expressões faciais e posteriormente, com dados de EEG.

### 6.3.1 Análise do *ranking* do melhores *feedbacks* de acordo com a face

Esta análise consiste em utilizar os dados da face para gerar um *ranking* dos melhores *feedbacks* sugeridos nesta tese para cada atividade em que o estudante irá analisar. Para isso, um estudo de análise dos dados da face **antes** e **depois** de um *feedback* foi realizado, onde realiza-se uma porcentagem proporcional de quantidade de vezes em que ocorreram registros de quadrantes preferíveis antes do *feedback* e a porcentagem proporcional de registros de quadrantes preferíveis depois do *feedback*.

Dessa forma, foi feita uma revisão de quais *feedbacks* foram usados como exemplo nesta tese, fazendo uma associação entre cada intervenção com seus respectivos valores de porcentagem preferível antes, possibilitando assim uma melhor visualização dos valores.

A visualização destes dados podem ser acompanhadas na Tabela 6.1, onde exhibe os *feedbacks* utilizados neste trabalho com suas respectivas porcentagens proporcionais de ocorrências em quadrantes preferíveis **antes** e **depois** da exibição do mesmo *feedback* de acordo com os dados da face.

Tabela 6.1: Tabela de *feedbacks* com suas respectivas porcentagens de ocorrências em quadrantes preferíveis **antes** e **depois** de acordo com a face.

<i>Feedbacks</i>	% preferíveis <b>antes</b> <i>feedback</i>	% preferíveis <b>depois</b> <i>feedback</i>
<i>Feedback 1</i> : Você sabia que um algoritmo é tipo uma receita de bolo?	66,73%	62,86%
<i>Feedback 2</i> : vamos lá, sei que você manja de algoritmos	70,75%	69,0%
<i>Feedback 3</i> : Laços de repetições são bem importantes, pra deixar a maquina fazendo coisas repetitivas pra você. Você vai se sair bem nessa	34%	40,83%
<i>Feedback 4</i> : While é o 'enquanto algo não for falso, continue	(não foi exibido)	
<i>Feedback 5</i> : Vetor é bem chato de entender, mas é bem útil, principalmente quando você entende que o primeiro elemento não é como todos esperam. Entender seu funcionamento ajuda bastante.	36,88%	35,11%
<i>Feedback 6</i> : Real é o dinheiro brasileiro =)	44,4%	43,2%
<i>Feedback 7</i> : Concatenar é uma palavra chique da programação que significa "colocar junto"	25,42%	26,85%
<i>Feedback 8</i> : Vamos lá, sei que você consegue, qual operador desses que da pra juntar coisas?	25,0%	25,0%
<i>Feedback 9</i> : Lógica é algo que nos faz humanos. Você como humano já manja de lógica naturalmente	14,0%	13,0%
<i>Feedback 10</i> : uma dica legal é que na matemática OR é tipo MAIS (+) e AND é tipo vezes (x)	0,66%	0,66%

Fonte: Própria.

Ao analisar a tabela acima, percebe-se que houveram aumento na porcentagem que representam as variações para os quadrantes preferíveis, como foi o caso dos *feedbacks* 3 e 7.

Para listar os melhores *feedbacks* de acordo com estes valores, realiza-se a diferença entre a porcentagem de quadrantes preferíveis **antes** com os quadrantes preferíveis **depois** da intervenção. Os valores negativos significam que os quadrantes preferíveis **depois** do *feedback* são menores que os quadrantes preferíveis **antes** do *feedback*, resultando em um *feedback* não tão bom segundo o experimento. Esta lista ordenada pode é exibida na Tabela 6.2.

Tabela 6.2: Tabela de diferenças entre a porcentagem dos quadrantes preferíveis antes e depois dos *feedbacks* com dados da face.

Número do <i>feedback</i>	Diferença entre <b>antes</b> e <b>depois</b>
Diferença entre <b>antes</b> e <b>depois</b> do <i>feedback</i> 1	-3,86
Diferença entre <b>antes</b> e <b>depois</b> do <i>feedback</i> 2	-1,75
Diferença entre <b>antes</b> e <b>depois</b> do <i>feedback</i> 3	6,83
Diferença entre <b>antes</b> e <b>depois</b> do <i>feedback</i> 4	(não foi exibido)
Diferença entre <b>antes</b> e <b>depois</b> do <i>feedback</i> 5	-1,77
Diferença entre <b>antes</b> e <b>depois</b> do <i>feedback</i> 6	-1,19
Diferença entre <b>antes</b> e <b>depois</b> do <i>feedback</i> 7	1,42
Diferença entre <b>antes</b> e <b>depois</b> do <i>feedback</i> 8	0 (sem mudança)
Diferença entre <b>antes</b> e <b>depois</b> do <i>feedback</i> 9	-1
Diferença entre <b>antes</b> e <b>depois</b> do <i>feedback</i> 10	0 (sem mudança)

Fonte: Própria.

Desta forma, conclui-se a possibilidade de realizar estudos de identificação de melhores *feedbacks* de acordo com a porcentagem proporcional dos dados da face **antes** e **depois** do *feedback*. Assim, é possível criar um *ranking* com as intervenções que pode ser vista abaixo.

1º) *feedback* 3 com 6,83; 2º) *feedback* 7 com 1,42; 3º) *feedback* 8 e *feedback* 10 com 0; 4º) *feedback* 9 com -1; 5º) *feedback* 6 com -1,19; 6º) *feedback* 2 com -1,75; 7º) *feedback* 5 com -1,77; 8º) *feedback* 1 com -3,86; O *feedback* 4 não foi exibido.

### 6.3.2 Análise do *ranking* do melhores *feedbacks* de acordo com o EEG

Da mesma forma que foi realizada análise com os dados da face, esta análise consiste em utilizar os dados de EEG para gerar um *ranking* dos melhores *feedbacks*. Para isso, um estudo de análise dos dados da face **antes** e **depois** de um *feedback* foi realizado, onde realiza-se uma porcentagem proporcional de quantidade de vezes em que ocorreram registros de quadrantes preferíveis antes do *feedback* e a porcentagem proporcional de registros de quadrantes preferíveis depois do *feedback*.

A Tabela 6.3 exibe os *feedbacks* utilizados neste trabalho com suas respectivas porcentagens de ocorrências em quadrantes preferíveis **antes** e **depois** da exibição do mesmo *feedback*, com dados de EEG.

Tabela 6.3: Tabela de *feedbacks* com suas respectivas porcentagens de ocorrências em quadrantes preferíveis **antes** e **depois** com dados de EEG

<i>Feedbacks</i> do estudo	% preferíveis <b>antes</b> <i>feedback</i>	% preferíveis <b>depois</b> <i>feedback</i>
<i>Feedback 1</i> : Você sabia que um algoritmo é tipo uma receita de bolo?	66,71%	62,86%
<i>Feedback 2</i> : vamos lá, sei que você manja de algoritmos	59,25%	62%
<i>Feedback 3</i> : Laços de repetições são bem importantes, pra deixar a maquina fazendo coisas repetitivas pra você. Você vai se sair bem nessa	87,16%	71,5%
<i>Feedback 4</i> : While é o 'enquanto algo não for falso, continue	(não foi exibido)	
<i>Feedback 5</i> : Vetor é bem chato de entender, mas é bem útil, principalmente quando você entende que o primeiro elemento não é como todos esperam. Entender seu funcionamento ajuda bastante.	69,11%	64,77%
<i>Feedback 6</i> : Real é o dinheiro brasileiro =)	80,2%	80,8%
<i>Feedback 7</i> : Concatenar é uma palavra chique da programação que significa "colocar junto"	57,28%	56,85%
<i>Feedback 8</i> : Vamos lá, sei que você consegue, qual operador desses que da pra juntar coisas?	62,75%	62,5%
<i>Feedback 9</i> : Lógica é algo que nos faz humanos. Você como humano já manja de lógica naturalmente	47,0%	49,75%
<i>Feedback 10</i> : uma dica legal é que na matemática OR é tipo MAIS (+) e AND é tipo vezes (x)	48,33%	51%

Fonte: Própria.

Ao analisar a Tabela acima, também pode-se perceber que houveram variações para os quadrantes preferíveis, como foi o caso do *feedback* 2, 6, 9 e 10.

Agora para elencar os melhores *feedbacks*, realiza-se a diferença entre a porcentagem proporcional de quadrantes preferíveis **antes** com os quadrantes preferíveis **depois**. O resultado já ordenado pode ser visto na Tabela 6.4.

Tabela 6.4: Tabela de diferenças entre a porcentagem proporcional do número de registros que estiveram nos quadrantes preferíveis (1 e 4) **antes** e **depois** dos *feedbacks* com dados de EEG, de acordo com a Tabela 6.3.

Número do <i>feedback</i>	Diferença entre <b>antes</b> e <b>depois</b>
Diferença entre <b>antes</b> e <b>depois</b> do <i>feedback</i> 1	-3,18
Diferença entre <b>antes</b> e <b>depois</b> do <i>feedback</i> 2	2,75
Diferença entre <b>antes</b> e <b>depois</b> do <i>feedback</i> 3	-15,66
Diferença entre <b>antes</b> e <b>depois</b> do <i>feedback</i> 4	(não foi exibido)
Diferença entre <b>antes</b> e <b>depois</b> do <i>feedback</i> 5	-4,33
Diferença entre <b>antes</b> e <b>depois</b> do <i>feedback</i> 6	0,59
Diferença entre <b>antes</b> e <b>depois</b> do <i>feedback</i> 7	-0,42
Diferença entre <b>antes</b> e <b>depois</b> do <i>feedback</i> 8	-0,25
Diferença entre <b>antes</b> e <b>depois</b> do <i>feedback</i> 9	2,75
Diferença entre <b>antes</b> e <b>depois</b> do <i>feedback</i> 10	2,66

Fonte: Própria.

Desta forma, conclui-se a possibilidade da realização de estudos de identificação de melhores *feedbacks* de acordo com a porcentagem proporcional dos dados de EEG capturadas via *OpenBCI* **antes** e **depois** do *feedback*. Assim, é possível criar um *ranking* com as intervenções que pode ser visto abaixo.

1º) *feedback* 9 e *feedback* 2 com 2,75; 2º) *feedback* 10 com 2,66; 3º) *feedback* 6 com 0,59; 4º) *feedback* 8 com -0,25; 5º) *feedback* 7 com -0,42; 6º) *feedback* 1 com -3,18; 7º) *feedback* 5 com -4,33; 8º) *feedback* 3 com -15,66;

Assim, verifica-se que a hipótese 2 foi atendida positivamente pois foi possível identificar quais são os *feedbacks* que melhor ajudam na mudança afetiva para quadrantes preferíveis (1 e 4), pois tanto para os dados da face, quanto para os dados de EEG, foi possível criar *rankings* com as melhores intervenções usadas neste estudo, utilizando a diferença de porcentagem proporcional de vezes em que houveram registros em quadrantes preferíveis (1 e 4) **antes** e **depois** do *feedback*.

## 6.4 DISCUSSÃO DOS RESULTADOS

Este trabalho objetiva realizar um estudo que usa *feedbacks* para analisar mudanças afetivas do estudante, utilizando expressões faciais e EEG. Para isso, foi elaborada uma abordagem chamada **NeuraFeed** que analisa tais mudanças enquanto o estudante está analisando as atividades antes da resposta. Segundo Yamamoto et al. (2021), o *feedback* que se dá ao resultado da atividade é chamado de "*feedback* pós-processo", uma das áreas mais importantes quando se trata de intervenção estudantil. No entanto, o *feedback* fornecido ao estudante durante a atividade, chama-se de "*feedback* em processo", e segundo o autor, foi pouco implementado e abordado e é uma área que vem complementar o *feedback* pré-processo. Este trabalho tem o objetivo de trabalhar com *feedback* em processo, com o diferencial de analisar automaticamente expressão facial e atividade neural via EEG com a possibilidade de ser utilizada em qualquer AVA web por conta do *plugin* apresentado que exibe o *feedback* de acordo com tal análise de face, e por ter realizado o experimento em ambiente real com estudantes de graduação brasileiros de uma universidade federal.

As análises realizadas na seção anterior visam responder se 1) existe diferença significativa entre os dados de GC e GE, usando dados de face e EEG, e 2) se é possível listar os *feedbacks* apresentados ao GE que possibilitaram mudanças afetivas para quadrantes preferíveis.

Para responder a hipótese 1, foram identificadas mudanças afetivas ocorridas no GC e no GE para face e EEG. Estes dados foram submetidos ao algoritmo Shapiro-Wilk que indicou uma distribuição não-normal, utilizando assim o teste de comparação wilcoxon e, como resultado, rejeitou-se a hipótese nula, ou seja, os dois grupos (GC e GE) estão em distribuições diferentes, tanto para os dados de face quanto para os dados de EEG. Ou seja, existem evidências estatísticas de que esta diferença possivelmente seja pela exibição dos *feedbacks* ao GE. Após isso, foi verificado se esta diferença foi algo bom ou ruim. Para isso, realizou-se um estudo de comparação de porcentagens proporcionais de número de vezes em que um estado afetivo ficou em quadrantes preferíveis (1 e 4) em comparação com as vezes em que ficou em quadrantes não-preferíveis (2 e 3). Dessa forma, constatou-se que para dados de Face, houve um aumento de **14,9%** de vezes em que o estado afetivo esteve em quadrantes preferíveis e nos dados de EEG, houve um aumento de **12,5%**. Desta forma, a abordagem **NeurAFFeed** foi elaborada possibilitando a criação de estudos que usam *feedbacks* para analisar mudanças afetivas usando dados de face e de EEG de forma satisfatória, atingindo o objetivo deste trabalho.

Para responder a hipótese 2, foram verificados quais *feedbacks* ocasionaram maior mudança afetiva para quadrantes preferíveis (nos dados de face e EEG). Para isso, foram identificadas janelas de análise, que iniciam quando o estudante começa seu experimento até a notificação do primeiro *feedback*, e assim pode calcular uma porcentagem dos quadrantes preferíveis e não-preferíveis. Essa etapa foi chamada de porcentagem de preferíveis **antes** do *feedback*, em que foi comparado com a janela feita pós-intervenção, que foi chamado de porcentagem de preferíveis **depois** do *feedback*. Com isso, foram criadas tabelas com a diferença entre o **antes** e **depois**, onde a diferença é o valor de mudança afetiva acontecida após a intervenção e assim, criou-se um *ranking* com todos os *feedbacks* apresentadas este trabalho. Com isso, constatou-se novamente uma grande possibilidade de formas de utilizar esta pesquisa para trabalhos futuros tais como criar uma lista de intervenções que forem mais bem avaliadas pelo sistema de acordo com as mudanças de estados afetivos para quadrantes preferíveis.

Mesmo que os valores de face e EEG atribuídos para os *feedbacks* sejam diferentes e elencaram diferentes *rankings*, uma indagação faz-se para provocar um debate para trabalhos futuros: *valence* e *arousal* de EEG precisam se parecer com as expressões faciais? Muito se fala em pessoas que sentem algo em sua mente mas que demonstram na expressão facial outro estado



afetivo que não aquele que de fato está acontecendo. Esta tese não teve como objetivo responder estas perguntas, o objeto da tese foi criar uma abordagem chamada **NeurAFFeed** que permita realizar um estudo no uso de *feedbacks* para mudanças afetivas utilizando atividade neural via EEG e face, mas tais perguntas ficam para futuros pesquisadores, de forma multidisciplinar, realizar estudos nessa linha, e talvez, usando a **NeurAFFeed** e estudo apresentada nesta tese para ajudar nisso. Com isso, existe a possibilidade de criar atividades e criar seus respectivos *feedbacks*, que serão exibidos enquanto o estudante realiza tais atividades, e no final, criar um *ranking* de *feedbacks* melhor ajudaram na mudança afetiva do estudante, positivamente ou negativamente, tanto para dados da face quanto para dados de EEG.

Um diferencial importante que vale ser ressaltado é a forma de aquisição de EEG utilizado neste trabalho, que foi o OpenBCI, um aparelho *open source*, não-clínico, de baixo custo (comparado com versões clínicas), que possibilita customização e com uma API de boa integração com linguagens de programação chamada *Brainflow*. Vislumbra-se um possível futuro em que a educação seja uma simbiose entre sensores bioquímicos (tal como EEG) e estudantes, onde cada um possuiria um *headset* de interface cérebro-computador, já que com o barateamento de aparelhos como OpenBCI, adaptáveis por serem de *software* e *hardware* livre, e podem serem integrados em bonés, toucas, tiaras, capuzes, etc. com sua estrutura impressa em impressoras 3D (onde em um futuro não tão longe, cada escola tenha um FabLab ou laboratório com esses aparelhos).

Para finalizar, faz-se necessário observar as preocupações referentes à privacidade dos dados dos estudante, principalmente quando se trabalha com coleta de atividade neural via EEG utilizando BCI (Haselager et al., 2009; Nijboer et al., 2013). Esta tese promove seu código como software livre, possibilitando cada escola possuir seus próprios computadores servidores para análise de dados de forma local, e não armazenados e centralizados em uma empresa específica fora da escola ou mesmo fora do país. Dados dos estudantes são sempre sigilosos e precisam estar amparados por um forte termo de uso que beneficie sua privacidade, com criptografia ponto-a-ponto, em que os únicos que terão acesso é o próprio estudante e o sistema de análise de dados apresentada nesta tese.

## 6.5 AMEAÇAS À ANÁLISE DO EXPERIMENTO

Uma das ameaças é o fato do estudante participante do experimento não ver o *feedback* ou simplesmente ignorá-lo. Isso impede o estudo acontecer de forma satisfatória no GE. Isso aconteceu com os dois primeiros participantes do experimento, após isso, foi conversado antes com a pessoa explicando que uma notificação aparecerá na tela no canto inferior esquerdo e pedido para que o participante desse uma atenção ao *feedback*. Alguns estudantes não analisaram as atividades com calma e respondiam sem se preocupar com os *feedbacks* que estavam sendo apresentados, e acabaram chutaram a resposta e não tentaram responder e nem utilizar a intervenção como auxílio.

Percebeu-se posteriormente que alguns eletrodos do OpenBCI perderam o contato com a pele do couro cabeludo do estudante no meio do experimento e isso possibilita uma ameaça aos dados coletados. Isso ocorre por vários fatores, como por exemplo um cabelo muito volumoso empurra o *headset* do OpenBCI e aos poucos o contato vai se desfazendo. Alguns estudantes fazem um movimento um pouco brusco ou fazem algo corporal, ocasionando também a falta de contato com a pele. Esses problemas ocasionam um problema no funcionamento algoritmo FEA para o reconhecimento valores de *valence* e *arousal* e esse equívoco pode ter ameaçado os dados desta análise. Porém, foram poucos estudantes com quem aconteceu essa situação, foram três estudantes.

## 7 CONSIDERAÇÕES FINAIS

Os estados afetivos desempenham um papel fundamental no processo de ensino/aprendizagem. Existem dificuldades para inseri-los no contexto educacional atual, por vários fatores, tal como a dificuldade em inferir um estado afetivo de um estudante, o fato de geralmente se ter muitos estudantes para que aconteça um ensino direcionado à afetividade e quais retornos os professores forneceriam para os estudantes de acordo com aquele estado afetivo identificado. Porém, pesquisas recentes indicam a possibilidade de adaptar um Sistema Tutor Inteligente como suporte a um ensino direcionado de acordo com a inferência de estados afetivos do estudante. Também houve o barateamento de aparelhos que podem ser utilizados para inferência de estados afetivos, como interfaces cérebro-computador que capturam sinais de eletroencefalograma do estudante e câmeras digitais (tais como *webcams*). Tais estados afetivos podem ser coletados e modelados utilizando-se a teoria bidimensional do afeto, que usa o valor de agradabilidade *valence* e *arousal*. Este trabalho teve como objetivo fazer um estudo no uso de *feedbacks* para mudanças de estados afetivos do estudante através da identificação de dados de *valence* e *arousal* utilizando dados de sinais elétricos cerebrais (eletroencefalograma - EEG) através de uma interface cérebro-computador não-invasivo de baixo-custo e código-aberto, e dados de expressões faciais através de uma *webcam*. A abordagem **NeurAFFeed** foi elaborada para ser utilizada em um experimento de um estudo que usa *feedbacks* para análise de mudanças dos estados afetivos de um estudante ao realizar atividades em um AVA, e assim, elencar quais intervenções foram melhores em mudar o estado afetivo para melhor. A **NeurAFFeed** foi utilizada em 20 estudantes de graduação, sendo 10 no GC (são os que não vêm o *feedback*) e 10 no GE (são os que vêm o *feedback*). Os dados foram coletados e analisados através de duas hipóteses: 1) Existe diferença significativa entre os dados do GC e do GE tanto nos dados de expressão facial e de EEG? e 2) quais são os *feedbacks*, apresentados aos estudantes do GE, que ocasionaram maior mudança afetiva para quadrantes preferíveis?

Para a primeira hipótese, foi usado o teste de wilcoxon (já que as distribuições de GC e GE deste trabalho foram não-normais) e como resultado, rejeitou-se a hipótese nula, ou seja, os dois grupos, GC e GE, estão em distribuições diferentes quando se analisa todos os dados de mudanças afetivas, evidenciando que as intervenções fornecidas ao estudante possivelmente teve impacto de alguma forma nos estudantes participantes do estudo, já que a única diferença entre o GC e o GE é que este apresenta *feedbacks* em forma de notificações. Outros estudos também foram realizados, onde comparou-se apenas os quadrantes preferíveis, que é como foi definido neste trabalho os quadrantes 1 e 4, que possuem *valence* positivo, do GC com o GE e também apenas os quadrantes não-preferíveis, como foi chamado neste trabalho os quadrantes 2 e 3 por terem *valence* negativo, do grupo GC com o GE. Todavia, este estudo não rejeitou a hipótese nula, ou seja, ambos grupos se encontram na mesma distribuição, sem diferença significativa. Para o primeiro estudo que deu diferença significativa, foi realizado um novo estudo de comparação de porcentagens de número de vezes que o estado afetivo do estudante ficou em quadrantes preferíveis em comparação com as vezes que ficou em quadrantes não-preferíveis e constatou-se que para Face, houve um aumento de 14,9% e nos dados de EEG, foi de 12,5%. Para responder a segunda hipótese, foi realizado um estudo de análise de antes e depois do *feedback* em que através e porcentagens proporcional de vezes do estado afetivo em quadrantes preferíveis, verificou-se a diferença entre estas porcentagens de antes e de depois da intervenção e com isso criou-se um *ranking* com todos os *feedbacks* apresentadas e trabalhadas neste trabalho.

A abordagem **NeurAFFeed** foi elaborada e foi utilizada em um experimento para realizar um estudo que analisa emoções de estudantes, conforme o objetivo desta tese descreveu e constatou-se que pode-se criar estudos que usam *feedbacks* textuais para análise de estados afetivos usando dados de atividade neural e face. O **NeurAFFeed** possibilita uma gama de formas de realizar tais estudos. Existe uma grande possibilidade de se utilizar esta pesquisa para trabalhos futuros tais como criar uma lista de intervenções que forem mais bem avaliadas pelo sistema de acordo com as mudanças de estados afetivos para quadrantes preferíveis.

## 7.1 TRABALHOS FUTUROS

Para trabalhos futuros, sugere-se a utilização do OpenBCI de maneira mais efetiva na coleta de dados de estudantes, criando uma nova base de dados, juntamente com a aquisição de expressões faciais usando *webcam* de alta qualidade. Para o estímulo emocional, sugere-se usar o banco de dados IAPS.

Uma vez que o sistema para melhoria de *feedbacks* está em processo de melhorias e testes, uma sugestão é realizar experimentos com análises nas mudanças afetivas que acontecem com o estudante quando um *feedback* textual é apresentado em meio à um objeto de aprendizagem. Com isso, possibilitará a criação de um banco de dados com os *feedbacks* e quais variações afetivas ela provoca, usando Expressões Faciais e EEG.

Durante o experimento, observou-se que o contato entre os eletrodos e o couro-cabeludo influencia na coleta dos dados, ou seja, não se satisfaz uma boa coleta apenas tocando o eletrodo na pele, mas deve estar em um contato bem estabelecido. Sugere-se fazer um novo estudo comparando diferenças de contato dos eletrodos com a pele e desenvolver uma técnica mais eficaz para isso.

Sugere-se fazer estudos mais aprofundados utilizando outras configurações de eletrodos, e também utilizando outras técnicas de reconhecimento de *valence* e *arousal* além do *Frontal EEG Asymmetry* (FEA) utilizado neste trabalho. Tais abordagem usam outras fórmulas provenientes também da neurociência e até usam *deep learning* para analisar atividade neural via EEG coletados por um OpenBCI, porém, tal biblioteca ainda não existe na literatura, e por este motivo, sugere-se como trabalho futuro iniciar um projeto de construção de uma biblioteca de EEG via OpenBCI, com todos os 16 eletrodos.

Refazer o experimento desta tese, aumentar o número de amostra, evitando as ameaças à análise dos resultados, conforme capítulo anterior. Esta pesquisa vai corroborar com os dados analisados até aqui ou indicar outros valores. Realizar estudos de remoção de artefatos de EEG tal como piscadas de olho ou movimentos.

Realizar pesquisas com EMG, que é tensão muscular, usando hardware do projeto BackyardBrains (BackyardBrains, 2022), pois é importante realizar estudos com vários biossensores para análise de dados.

Sugere-se também adicionar intervenções além do textual, tal como músicas relaxantes e vídeos sobre exercícios como dicas e até alterar de cor. Talvez assim o *feedback* seja mais efetivo.

Sugere-se também inserir um formulário ao final de cada pergunta para ter um retorno do estudante sobre a pesquisa. Uma pergunta tal como: "Qual *feedback* ajudou mais?". isso vai ajudar na análise dos resultados para comparar com os dados inferidos.

## 7.2 PUBLICAÇÃO

de Oliveira, W.C., Gottardo, E., Pimentel, A.R. (2020). Changes of Affective States in Intelligent Tutoring System to Improve Feedbacks Through Low-Cost and Open Electroencephalogram and Facial Expression. In: Kumar, V., Troussas, C. (eds) Intelligent Tutoring Systems. ITS 2020. Lecture Notes in Computer Science(), vol 12149. Springer, Cham. [https://doi.org/10.1007/978-3-030-49663-0\\_8](https://doi.org/10.1007/978-3-030-49663-0_8)

## REFERÊNCIAS

- Abril, M. J. d. e Peixoto, F. (2012). Emoções na sala de aula: Estudo das relações entre emoções, autoconceito e percepção do clima de sala de aula em alunos do 3º ciclo. *Educação, aprendizagem e desenvolvimento: Olhares contemporâneos através da investigação e da prática—Actas do 12º Colóquio Internacional de Psicologia e Educação*, páginas 880–892.
- Adolph, D. e Alpers, G. W. (2010). Valence and arousal: a comparison of two sets of emotional facial expressions. *The American Journal of Psychology*, 123(2):209–219.
- ADS1299 (2022). Especificação do ads1299. <http://www.ti.com/lit/ds/symlink/ads1299.pdf>. Acessado em novembro de 2022.
- Ahuja, N. J. e Sille, R. (2013). A critical review of development of intelligent tutoring systems: Retrospect, present and prospect. *International Journal of Computer Science Issues*, 10(4):39–48.
- Alam, M. G. R., Abedin, S. F., Moon, S. I., Talukder, A. e Hong, C. S. (2019). Healthcare iot-based affective state mining using a deep convolutional neural network. *IEEE Access*, 7:75189–75202.
- Alarcão, S. M. e Fonseca, M. J. (2019). Emotions recognition using eeg signals: A survey. *IEEE Transactions on Affective Computing*, 10(3):374–393.
- Albawardi, H., Almoaibed, A., Abbas, N. A., Alsayed, S., Almaghlouth, T. e Alzahrani, S. (2021). Design of low-cost steady state visually evoked potential-based brain computer interface using openbci and neuromore. Em *2021 4th International Conference on Bio-Engineering for Smart Technologies (BioSMART)*, páginas 1–4.
- Aldhafeeri, F. M., Mackenzie, I., Kay, T., Alghamdi, J. e Sluming, V. (2012). Regional brain responses to pleasant and unpleasant iaps pictures: Different networks. *Neuroscience Letters*, 512(2):94–98.
- Aldridge, A., Barnes, E., Bethel, C. L., Carruth, D. W., Kocturova, M., Pleva, M. e Juhar, J. (2019). Accessible electroencephalograms (eegs): A comparative review with openbci’s ultracortex mark iv headset. Em *2019 29th International Conference Radioelektronika*, páginas 1–6.
- Allen, J. J., Coan, J. A. e Nazarian, M. (2004). Issues and assumptions on the road from raw signals to metrics of frontal eeg asymmetry in emotion. *Biological Psychology*, 67(1):183–218. Frontal EEG Asymmetry, Emotion, and Psychopathology.
- Alqahtani, F., Katsigiannis, S. e Ramzan, N. (2021). Using wearable physiological sensors for affect-aware intelligent tutoring systems. *IEEE Sensors Journal*, 21(3):3366–3378.
- Anohina-Naumeca, A. e Grundspenkis, J. (2010). Evaluating students’ concept maps in the concept map based intelligent knowledge assessment system. Em *Proceedings of the 13th East European Conference on Advances in Databases and Information Systems, ADBIS’09*, páginas 8–15, Berlin, Heidelberg. Springer-Verlag.

- Arumugam, D. e Dr. S. Purushothaman B.E, M. (2011). Emotion classification using facial expression. *International Journal of Advanced Computer Science and Applications*, 2(7).
- Ascari, S. R., Pimentel, A. R. e Gottardo, E. (2021). Tutorial intervention's affective model based on learner's error identification in intelligent tutoring systems. Em Cristea, A. I. e Troussas, C., editores, *Intelligent Tutoring Systems*, páginas 453–465, Cham. Springer International Publishing.
- BackyardBrains (2022). Site do projeto backyardbrains. <https://backyardbrains.com/products/heartAndBrainSpikerBox>. Acessado em novembro de 2022.
- Barrón-Estrada, M. L., Zatarain-Cabada, R., Oramas-Bustillos, R. e Alor-Hernández, G. (2016). How an Affective Learning Environment for Learning Java Impacts the Student's Learning Results. Em *2016 IEEE 16th International Conference on Advanced Learning Technologies (ICALT)*, páginas 363–365.
- Bear, M., Connors, B. e Paradiso, M. A. (2020). *Neuroscience: Exploring the Brain, Enhanced Edition: Exploring the Brain*. Jones & Bartlett Learning.
- Ben Ammar, M., Neji, M., Alimi, A. M. e Gouardères, G. (2010). The affective tutoring system. *Expert Systems with Applications*, 37(4):3013–3023.
- Blaiech, H., Neji, M., Wali, A. e Alimi, A. M. (2013). Emotion recognition by analysis of eeg signals. Em *13th International Conference on Hybrid Intelligent Systems (HIS 2013)*, páginas 312–318.
- Blinowska, K. e Durka, P. (2006). Electroencephalography (eeg). *Wiley encyclopedia of biomedical engineering*.
- Bo, K., Yin, S., Liu, Y., Jenkins, J., Keil, A. e Ding, M. (2019). Eeg and fmri decoding of emotional states: Temporal dynamics and neural substrate. *Journal of Vision*, 19(10):285–285.
- Bosch, N., Chen, Y. e D'Mello, S. (2014). It's written on your face: Detecting affective states from facial expressions while learning computer programming. Em Trausan-Matu, S., Boyer, K. E., Crosby, M. e Panourgia, K., editores, *Intelligent Tutoring Systems*, páginas 39–44, Cham. Springer International Publishing.
- Botelho, A. F., Baker, R. S. e Heffernan, N. T. (2017). Improving sensor-free affect detection using deep learning. Em André, E., Baker, R., Hu, X., Rodrigo, M. M. T. e du Boulay, B., editores, *Artificial Intelligence in Education*, páginas 40–51, Cham. Springer International Publishing.
- Bouzakraoui, M. S., Sadiq, A. e Enneya, N. (2017). A customer emotion recognition through facial expression using poem descriptor and svm classifier. Em *Proceedings of the 2Nd International Conference on Big Data, Cloud and Applications, BDCA'17*, páginas 80:1–80:6, New York, NY, USA. ACM.
- Bradbury, N. A. (2016). Attention span during lectures: 8 seconds, 10 minutes, or more? *Advances in Physiology Education*, 40(4):509–513. PMID: 28145268.
- Bradley, M. e Lang, P. (2000). Measuring emotion: Behavior, feeling and physiology. Em Lane, R. e Nadel, L., editores, *Cognitive neuroscience of emotion*, páginas 242 – 276. New York: Oxford University Press.

- Bradley, M., Sabatinelli, D., Lang, P., Fitzsimmons, J., King, W. e Desai, P. (2003). Activation of the visual cortex in motivated attention. *Behavioral neuroscience*, 117:369–80.
- Bradley, M. M. e 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.
- Bradley, M. M. e Lang, P. J. (2022). Iaps message and request. <https://csea.php.ufl.edu/media/iapsmessage.html>. Acessado em novembro de 2022.
- Brainflow (2022). Brainflow, how biosensors work. <https://brainflow.org/>. Acessado em novembro de 2022.
- Broekens, J. e Degroot, D. (2004). Emotional agents need formal models of emotion.
- Brookhart, S. M. (2012). *Teacher Feedback in Formative Classroom Assessment*, páginas 225–239. Springer Netherlands, Dordrecht.
- Bruggeman-Everts, F. (2010). *The neural correlates of symptom relief after interventions in anxiety disorders*. Tese de doutorado, Utrecht University.
- Busso, C., Deng, Z., Yildirim, S., Bulut, M., Lee, C. M., Kazemzadeh, A., Lee, S., Neumann, U. e Narayanan, S. (2004). Analysis of emotion recognition using facial expressions, speech and multimodal information. Em *Proceedings of the 6th International Conference on Multimodal Interfaces, ICMI '04*, páginas 205–211, New York, NY, USA. ACM.
- Calvo, R. A. e D'Mello, S. K. (2011). *New perspectives on affect and learning technologies*, volume 3. Springer Science & Business Media.
- Camacho-Morles, J., Slemp, G. R., Pekrun, R., Loderer, K., Hou, H. e Oades, L. G. (2021). Activity achievement emotions and academic performance: A meta-analysis. *Educational Psychology Review*, 33(3):1051–1095.
- Chen, M., Han, J., Guo, L., Wang, J. e Patras, I. (2015). Identifying valence and arousal levels via connectivity between eeg channels. Em *2015 International Conference on Affective Computing and Intelligent Interaction (ACII)*, páginas 63–69.
- Chen, Y.-J., Hsu, L. e wei Lu, S. (2022). How does emoji feedback affect the learning effectiveness of efl learners? neuroscientific insights for call research. *Computer Assisted Language Learning*, 0(0):1–24.
- Coan, J. A. e Allen, J. J. (2004). Frontal eeg asymmetry as a moderator and mediator of emotion. *Biological Psychology*, 67(1):7–50. Frontal EEG Asymmetry, Emotion, and Psychopathology.
- Conati, C. (2011). *Combining Cognitive Appraisal and Sensors for Affect Detection in a Framework for Modeling User Affect*, páginas 71–84. Springer New York, New York, NY.
- Cosenza, R. M. e Guerra, L. B. (2011). *Neurociência e educação: como o cérebro aprende*. Artmed.
- Courchesne, E., Mouton, P. R., Calhoun, M. E., Semendeferi, K., Ahrens-Barbeau, C., Hallet, M. J., Barnes, C. C. e Pierce, K. (2011). Neuron Number and Size in Prefrontal Cortex of Children With Autism. *JAMA*, 306(18):2001–2010.
- Damasio, A. (2008). *Descartes' Error: Emotion, Reason and the Human Brain*. Random House.

- Damásio, A. (2015). *O mistério da consciência: do corpo e das emoções ao conhecimento de si*. Editora Companhia das Letras.
- Davidson, R. J. (2004). What does the prefrontal cortex “do” in affect: perspectives on frontal eeg asymmetry research. *Biological Psychology*, 67(1):219–234. Frontal EEG Asymmetry, Emotion, and Psychopathology.
- de Oliveira, W. C. e Pinheiro, C. D. (2010). *Sisto-Um Sistema Web Para a Interação Aluno-Professor-Disciplina: Unindo Redes Sociais e Ambientes Virtuais de Aprendizagem*. Tese de doutorado, Universidade Federal do Pará.
- Duarte Leite., M., Marczal., D. e Ricardo Pimentel., A. (2013). Multiple external representations in remediation of math errors. Em *Proceedings of the 15th International Conference on Enterprise Information Systems - Volume 3: ICEIS*,, páginas 519–523. INSTICC, SciTePress.
- Duffy, F. H., Iyer, V. G. e Surwillo, W. W. (1989). *Brain Electrical Activity: An Introduction to EEG Recording*, páginas 1–10. Springer New York, New York, NY.
- Dāboliņš, J. e Grundspenķis, J. (2013). The role of feedback in intelligent tutoring system. *Applied Computer Systems*, 14(1):88 – 93.
- D’Mello, S. e Graesser, A. (2012). Dynamics of affective states during complex learning. *Learning and Instruction*, 22(2):145–157.
- Ekman, P., Friesen, W., Ellsworth, P., Goldstein, A. e Krasner, L. (2013). *Emotion in the Human Face: Guidelines for Research and an Integration of Findings*. Pergamon general psychology series. Elsevier Science.
- Ekman, P., Friesen, W. V., O’Sullivan, M., Chan, A., Diacoyanni-Tarlatzis, I., Heider, K., Krause, R., LeCompte, W. A., Pitcairn, T., Ricci-Bitti, P. E., Scherer, K. e Tomita, M. (1987). Universals and cultural differences in the judgments of facial expressions of emotion. *Journal of personality and social psychology*, 53(4):712–7.
- Ellis, R. e Calvo, R. (2007). Minimum indicators to assure quality of lms-supported blended learning. *Educational Technology & Society*, 10:60–70.
- Elnicki, D. M. (2010). Learning With Emotion: Which Emotions and Learning What? *Academic Medicine*, 85(7).
- Esperidião-Antonio, V., Majeski-Colombo, M., Toledo-Monteverde, D., Moraes-Martins, G., Fernandes, J. J., Assis, M. B. d. e Siqueira-Batista, R. (2008). Neurobiologia das emoções. *Archives of Clinical Psychiatry (São Paulo)*, 35:55–65.
- Fattahi, P., Yang, G., Kim, G. e Abidian, M. R. (2014). A review of organic and inorganic biomaterials for neural interfaces. *Advanced Materials*, 26(12):1846–1885.
- Ferreira, A. L. S., de Miranda, L. C., de Miranda, E. E. C. e Sakamoto, S. G. (2013). A survey of interactive systems based on brain-computer interfaces. *Journal on Interactive Systems*, 4(1).
- Ferrero, R., Ferrero, A. R. e A., R. L. (1995). *Análisis computado del EEG*. Fundacion Argentina de Estudio Del Cerebro.
- Fonseca, J. (2002). Metodologia da pesquisa científica. fortaleza: Uec, 2002. *F. P. A pesquisa científica.*, 2:31–42.



- Fossati, D. (2008). The role of positive feedback in intelligent tutoring systems. Em *In: ACL 2008, The 46th Annual Meeting of the Association for Computational Linguistics, Student Research Workshop*.
- Frey, J. (2016). Comparison of an open-hardware electroencephalography amplifier with medical grade device in brain-computer interface applications. *CoRR*, abs/1606.02438.
- Friesen, P. E. . W. (1975). *Unmasking the face*. Prentice Hall.
- Frijo, M. e Johnson, S. (1998). Fftw: an adaptive software architecture for the fft. Em *Proceedings of the 1998 IEEE International Conference on Acoustics, Speech and Signal Processing, ICASSP '98 (Cat. No.98CH36181)*, volume 3, páginas 1381–1384 vol.3.
- Frijda, N. H. (2007). Klaus scherer’s article on “what are emotions?” comments. *Social Science Information*, 46(3):381–383.
- Fwa, H. L. (2018). An architectural design and evaluation of an affective tutoring system for novice programmers. *International Journal of Educational Technology in Higher Education*, 15:1–19.
- Gavidia, J. J. Z. e Andrade, L. C. V. d. (2003). Sistemas tutores inteligentes. *Rio de Janeiro–RJ: UFRJ*.
- Gerhardt, T. E. e Silveira, D. T. (2009). *Métodos de pesquisa*. Plageder.
- Gil, A. C. et al. (2007). *Como elaborar projetos de pesquisa*, volume 4. Atlas São Paulo.
- Gottardo, E. e Ricardo Pimentel, A. (2018). Improving inference of learning related emotion by combining cognitive and physical information. Em Nkambou, R., Azevedo, R. e Vassileva, J., editores, *Intelligent Tutoring Systems*, páginas 313–318, Cham. Springer International Publishing.
- Gouli, E., Gogoulou, A., Tsakostas, C. e Grigoriadou, M. (2006). How compass supports multi-feedback forms and components adapted to learner’s characteristics. Em *In A. Cañas, & J. Novak (Eds.), Concept Maps: Theory, Methodology, Technology, Proceedings of the Second International Conference on Concept Mapping*, páginas 255–262.
- Graimann, B., Allison, B. Z. e Pfurtscheller, G. (2010). *Brain-computer interfaces: Revolutionizing human-computer interaction*. Springer Science & Business Media.
- Gunawardane, H., Silva, C. e Chiao, M. (2019). An oculomotor sensing technique for saccade isolation of eye movements using openbci. Em *IEEE Sensors*, página 4.
- Guo, L., Wang, D., Gu, F., Li, Y., Wang, Y. e Zhou, R. (2021). Evolution and trends in intelligent tutoring systems research: a multidisciplinary and scientometric view. *Asia Pacific Education Review*, 22(3):441–461.
- Hartling, C., Metz, S., Pehrs, C., Scheidegger, M., Gruzman, R., Keicher, C., Wunder, A., Weigand, A. e Grimm, S. (2021). Comparison of four fmri paradigms probing emotion processing. *Brain Sciences*, 11(5).
- Hasan, M. A., Noor, N. F. M., Rahman, S. S. B. A. e Rahman, M. M. (2020). The Transition From Intelligent to Affective Tutoring System: A Review and Open Issues. *IEEE Access*, 8:204612–204638.

- Haselager, P., Vlek, R., Hill, J. e Nijboer, F. (2009). A note on ethical aspects of bci. *Neural Networks*, 22(9):1352–1357. Brain-Machine Interface.
- Hattie, J. e Timperley, H. (2007). The power of feedback. *Review of Educational Research*, 77(1):81–112.
- He, Y., Hui, S. C. e Quan, T. T. (2009). Automatic summary assessment for intelligent tutoring systems. *Computers & Education*, 53(3):890 – 899.
- Henry, J. C. (2006). Electroencephalography: Basic principles, clinical applications, and related fields, fifth edition. *Neurology*, 67(11):2092–2092–a.
- Heraz, A. e Frasson, C. (2011). Towards a Brain-sensitive Intelligent Tutoring System: Detecting Emotions from Brainwaves. *Adv. in Artif. Intell.*, 2011:1:1–1:13.
- Horovitz, T. e Mayer, R. E. (2021). Learning with human and virtual instructors who display happy or bored emotions in video lectures. *Computers in Human Behavior*, 119:106724.
- Hubel, D. H. (1988). Eye, brain and vision, volume 22 of scientific american library. *Scientific American Press, New York*.
- Hwang, S., Jebelli, H., Choi, B., Choi, M. e Lee, S. (2018). Measuring workers emotional state during construction tasks using wearable eeg. *Journal of Construction Engineering and Management*, 144(7):04018050.
- Ienca, M. (2019). Democratizing cognitive technology: a proactive approach. *Ethics and Information Technology*, 21(4):267–280.
- Immordino-Yang, M. H. (2015). *Emotions, Learning and the Brain: Exploring the Educational Implication of Affective Neuroscience*. W. W. Norton & Company, New York, 1 edition edition.
- Ioannou, S. V., Raouzaïou, A. T., Tzouvaras, V. A., Mailis, T. P., Karpouzis, K. C. e Kollias, S. D. (2005). Emotion recognition through facial expression analysis based on a neurofuzzy network. *Neural Networks*, 18(4):423 – 435. Emotion and Brain.
- Jaques, N., Conati, C., Harley, J. M. e Azevedo, R. (2014). Predicting affect from gaze data during interaction with an intelligent tutoring system. Em Trausan-Matu, S., Boyer, K. E., Crosby, M. e Panourgia, K., editores, *Intelligent Tutoring Systems*, páginas 29–38, Cham. Springer International Publishing.
- Jaques, P. A. e Vicari, R. M. (2005). Estado da arte em ambientes inteligentes de aprendizagem que consideram a afetividade do aluno. *Informática na educação, UFRGS: Porto Alegre*, 8(1):15–38.
- Jasper, H. H. (1958). Report of the committee on methods of clinical examination in electroencephalography: 1957. *Electroencephalography and Clinical Neurophysiology*, 10(2):370 – 375.
- Jiménez, S., Juárez-Ramírez, R., Castillo, V. H. e Tapia Armenta, J. J. (2018). *Feedback and Affectivity in Intelligent Tutoring Systems*, páginas 5–25. Springer International Publishing, Cham.

- Jimnez, S., Jurez-Ramrez, R., Castillo, V. H. e Armenta, J. J. T. (2018). *Affective Feedback in Intelligent Tutoring Systems: A Practical Approach*. Springer Publishing Company, Incorporated, 1st edition.
- jQuery (2022). jquery. <https://jquery.com>. Acessado em novembro de 2022.
- Junior, H. H. e Visconti, M. A. (2014). Organização geral do sistema nervoso. [https://midia.atp.usp.br/plc/plc0029/impresos/plc0029\\_top02.pdf](https://midia.atp.usp.br/plc/plc0029/impresos/plc0029_top02.pdf). Acessado em novembro de 2022.
- Kandel, E., Schwartz, J., Jessell, T., Siegelbaum, S. e Hudspeth, A. (2014). *Princípios de neurociências-5*. AMGH Editora.
- Kanjilal, D. (2014). Study buddy: An emotionally intelligent tutoring system. *International Journal of Computer Applications*, 99(9):20–23. Full text available.
- Kasim, N. e Khalid, F. (2016). Choosing the right learning management system (lms) for the higher education institution context: A systematic review. *International Journal of Emerging Technologies in Learning (iJET)*, 11:55.
- Katsigiannis, S. e Ramzan, N. (2018). Dreamer: A database for emotion recognition through eeg and ecg signals from wireless low-cost off-the-shelf devices. *IEEE Journal of Biomedical and Health Informatics*, 22(1):98–107.
- Kawala-Sterniuk, A., Browarska, N., Al-Bakri, A., Pelc, M., Zygarlicki, J., Sidikova, M., Martinek, R. e Gorzelanczyk, E. J. (2021). Summary of over fifty years with brain-computer interfaces—a review. *Brain Sciences*, 11(1).
- Kawde, P. e Verma, G. K. (2017). Deep belief network based affect recognition from physiological signals. Em *2017 4th IEEE Uttar Pradesh Section International Conference on Electrical, Computer and Electronics (UPCON)*, páginas 587–592.
- Keizer, A. W. (2018). qeeg-pro manual. [https://qeeg.pro/wp-content/uploads/2018/02/qEEG-pro-Manual\\_v1\\_5.pdf](https://qeeg.pro/wp-content/uploads/2018/02/qEEG-pro-Manual_v1_5.pdf). Acessado em novembro de 2022.
- Kochhann, A. e ROCHA, V. (2015). A afetividade no processo ensino-aprendizagem na perspectiva de piaget, vygotsky e wallon. *Simpósio de Pesquisa e Extensão (SIMPEX)*, 1.
- Koelstra, S., Muhl, C., Soleymani, M., Lee, J., Yazdani, A., Ebrahimi, T., Pun, T., Nijholt, A. e Patras, I. (2012). Deap: A database for emotion analysis ;using physiological signals. *IEEE Transactions on Affective Computing*, 3(1):18–31.
- Kollias, D., Tzirakis, P., Nicolaou, M. A., Papaioannou, A., Zhao, G., Schuller, B., Kotsia, I. e Zafeiriou, S. (2019). Deep affect prediction in-the-wild: Aff-wild database and challenge, deep architectures, and beyond. *International Journal of Computer Vision*, 127(6-7):907–929.
- Kouahla, M. N., Boughida, A., Chebata, I., Mehenaoui, Z. e Lafifi, Y. (2022). Emorec: a new approach for detecting and improving the emotional state of learners in an e-learning environment. *Interactive Learning Environments*, 0(0):1–19.
- Lang, P. e Bradley, M. M. (2007). The international affective picture system (iaps) in the study of emotion and attention. *Handbook of emotion elicitation and assessment*, 29.

- Lang, P. J. (1980). Behavioral treatment and bio-behavioral assessment: computer applications. Em Sidowski, J. B., Johnson, J. H. e Williams, T. A., editores, *Technology in the health care delivery system*, páginas 119—137. Ablex, Norwood, NJ.
- Lang, P. J., Bradley, M. M. e Cuthbert, B. N. (2005). International affective picture system (iaps): Affective ratings of pictures and instruction manual. Relatório Técnico A-6, University of Florida, Gainesville.
- Lang, P. J., Bradley, M. M., Fitzsimmons, J. R., Cuthbert, B. N., Scott, J. D., Moulder, B. e Nangia, V. (1998). Emotional arousal and activation of the visual cortex: An fmri analysis. *Psychophysiology*, 35(2):199–210.
- Latham, A., Crockett, K., McLean, D. e Edmonds, B. (2012). A conversational intelligent tutoring system to automatically predict learning styles. *Computers & Education*, 59(1):95 – 109. CAL 2011.
- LeDoux, J. (1994). Emotion, memory and the brain. *Scientific American*, 270(6):50–57.
- LeDoux, J. (1996). *Cérebro Emocional*, o. Editora Objetiva.
- Lee, D. H. e Brusilovsky, P. (2009). Reinforcing recommendation using implicit negative feedback. Em Houben, G.-J., McCalla, G., Pianesi, F. e Zancanaro, M., editores, *User Modeling, Adaptation, and Personalization*, páginas 422–427, Berlin, Heidelberg. Springer Berlin Heidelberg.
- Lent, R., Azevedo, F. A. C., Andrade-Moraes, C. H. e Pinto, A. V. O. (2012). How many neurons do you have? some dogmas of quantitative neuroscience under revision. *European Journal of Neuroscience*, 35(1):1–9.
- Lewis, R. S., Weekes, N. Y. e Wang, T. H. (2007). The effect of a naturalistic stressor on frontal eeg asymmetry, stress, and health. *Biological Psychology*, 75(3):239 – 247.
- Lindsley, D. B. (1951). Emotion. Em *Handbook of experimental psychology*., páginas 473–516. Wiley.
- Longhi, M. T., Bercht, M. e Behar, P. A. (2007). Reconhecimento de estados afetivos do aluno em ambientes virtuais de aprendizagem. *RENOTE: revista novas tecnologias na educação [recurso eletrônico]*. Porto Alegre, RS.
- Mahoor, M. H. (2022). Affectnet. <http://mohammadmahoor.com/affectnet/>. Acessado em novembro de 2022.
- Mangaroska, K., Sharma, K., Gašević, D. e Giannakos, M. (2022). Exploring students' cognitive and affective states during problem solving through multimodal data: Lessons learned from a programming activity. *Journal of Computer Assisted Learning*, 38(1):40–59.
- Matlab (2022). Power spectral density estimates using fft. <https://www.mathworks.com/help/signal/ug/power-spectral-density-estimates-using-fft.html>. Acessado em novembro de 2022.
- Medina-Medina, N., Molina-Ortiz, F., García-Cabrera, L. e Parets-Llorca, J. (2003). Personalized guided routes in an adaptive evolutionary hypermedia system. Em Moreno-Díaz, R. e Pichler, F., editores, *Computer Aided Systems Theory - EUROCAST 2003*, páginas 196–207, Berlin, Heidelberg. Springer Berlin Heidelberg.

- Mehrabian, A. e Russel, A. J. (1974). *An Approach to Environmental Psychology*. MIT Press.
- Miller, K. J., Hermes, D. e Staff, N. P. (2020). The current state of electrocorticography-based brain–computer interfaces. *Neurosurgical focus*, 49(1):E2.
- Mills, K. R. (2005). The basics of electromyography. *Journal of Neurology, Neurosurgery & Psychiatry*, 76(suppl 2):ii32–ii35.
- Mirvis, D. M. e Goldberger, A. L. (2001). Electrocardiography. *Heart disease*, 1:82–128.
- Mohanran, R., Stringfellow, C. e Gupta, D. (2017). An emotionally intelligent tutoring system. Em *2017 Computing Conference*, páginas 1099–1107.
- Mollahosseini, A., Hasani, B. e Mahoor, M. H. (2019). Affectnet: A database for facial expression, valence, and arousal computing in the wild. *IEEE Transactions on Affective Computing*, 10(1):18–31.
- Mollahosseini, A., Hassani, B. e Mahoor, M. H. (2017). Affectnet: A database for facial expression, valence, and arousal computing in the wild. *CoRR*, abs/1708.03985.
- Moodle (2022). Site do projeto moodle. <https://moodle.org>. Acessado em novembro de 2022.
- Muhardi, M., Gunawan, S. I., Irawan, Y. e Devis, Y. (2020). Design of web based lms (learning management system) in sman 1 kampar kiri hilir. *Journal of Applied Engineering and Technological Science (JAETS)*, 1(2):70–76.
- Munezero, M., Montero, C. S., Sutinen, E. e Pajunen, J. (2014). Are they different? affect, feeling, emotion, sentiment, and opinion detection in text. *IEEE Transactions on Affective Computing*, 5(2):101–111.
- Nicolas-Alonso, L. F. e Gomez-Gil, J. (2012). Brain computer interfaces, a review. *Sensors*, 12(2):1211–1279.
- Nijboer, F., Clausen, J., Allison, B. e Haselager, P. (2013). The asilomar survey: Stakeholders' opinions on ethical issues related to brain-computer interfacing. *Neuroethics*, 6:1–38.
- Nogueira, K. (2018). Estudo de respostas emocionais às cores no contexto de cartazes de cinema. *Design e Tecnologia*, 8:1.
- Norton, A. (2013). Synapse. <https://www.flickr.com/photos/123689703@N04/14792084041/in/album-72157646065956112/>. Acessado em novembro de 2022.
- Nowack, W. J. (1995). Neocortical dynamics and human eeg rhythms.
- Nwana, H. S. (1990). Intelligent tutoring systems: an overview. *Artificial Intelligence Review*, 4(4):251–277.
- OBS (2022). Site do projeto obs studio. <https://obsproject.com/>. Acessado em novembro de 2022.
- Oliveira, W. C., Cantieri, Á. R., Borba, G. B. e Gamba, H. R. (2010). Avaliação do instrumento sam para a etiquetagem colaborativa em ambiente web de imagens segundo critérios afetivos. Em *Anais Estendidos do XVI Simpósio Brasileiro de Sistemas Multimídia e Web*, páginas 75–78. SBC.

- OpenBCI (2022a). Site do projeto openbci. <https://www.openbci.com>. Acessado em Novembro de 2022.
- OpenBCI, L. A. (2022b). Citations: Research is at the heart of what we do. <https://openbci.com/citations>. Acessado em novembro de 2022.
- Pakkenberg, B. e Gundersen, H. J. G. (1997). Neocortical neuron number in humans: Effect of sex and age. *Journal of Comparative Neurology*, 384(2):312–320.
- Palmiero, M. e Piccardi, L. (2017). Frontal eeg asymmetry of mood: A mini-review. *Frontiers in Behavioral Neuroscience*, 11.
- Pandey, P., Tripathi, R. e Miyapuram, K. (2021). Classifying oscillatory brain activity associated with indian rasas using network metrics. *Brain Informatics*.
- Paquette, L., Baker, R. S. J. D., Sao Pedro, M. A., Gobert, J. D., Rossi, L., Nakama, A. e Kauffman-Rogoff, Z. (2014). Sensor-free affect detection for a simulation-based science inquiry learning environment. Em Trausan-Matu, S., Boyer, K. E., Crosby, M. e Panourgia, K., editores, *Intelligent Tutoring Systems*, páginas 1–10, Cham. Springer International Publishing.
- Pekrun, R. (1992). The impact of emotions on learning and achievement: Towards a theory of cognitive/motivational mediators. *Applied Psychology*, 41(4):359–376.
- Pekrun, R., Goetz, T., Titz, W. e Perry, R. P. (2002). Academic Emotions in Students' Self-Regulated Learning and Achievement: A Program of Qualitative and Quantitative Research. *Educational Psychologist*, 37(2):91–105.
- Peska, L. (2012). User feedback and preferences mining. Em Masthoff, J., Mobasher, B., Desmarais, M. C. e Nkambou, R., editores, *User Modeling, Adaptation, and Personalization*, páginas 382–386, Berlin, Heidelberg. Springer Berlin Heidelberg.
- Petrovica, S. (2014). Design of the pedagogical module for an emotionally intelligent tutoring system. *Mokslas - Lietuvos ateitis*, 6:138–146.
- Pfaff, L., Lamy, J., Noblet, V., Gounot, D., Chanson, J.-B., de Seze, J. e Blanc, F. (2019). Emotional disturbances in multiple sclerosis: A neuropsychological and fmri study. *Cortex*, 117:205–216.
- Phobun, P. e Vicheanpanya, J. (2010). Adaptive intelligent tutoring systems for e-learning systems. *Procedia - Social and Behavioral Sciences*, 2(2):4064 – 4069. Innovation and Creativity in Education.
- Picard, R. W. (2000). *Affective computing*. MIT press.
- PlataformaBrasil (2022). Site da plataforma brasil. <https://plataformabrasil.saude.gov.br>. Acessado em novembro de 2022.
- Pomer-Escher, A. G., de Souza, M. D. P. e Filho, T. F. B. (2014). Methodology for analysis of stress level based on asymmetry patterns of alpha rhythms in eeg signals. Em *5th ISSNIP-IEEE Biosignals and Biorobotics Conference (2014): Biosignals and Robotics for Better and Safer Living (BRC)*, páginas 1–5.

- Prutchi, D. e Norris, M. (2005). *Design and development of medical electronic instrumentation: a practical perspective of the design, construction, and test of medical devices*. John Wiley & Sons.
- Rahma, R. e Nurhadi, J. (2017). Measurement of concentration duration on reading activity: Eeg analysis with openbci ganglion board. *SSRN Electronic Journal*.
- Ramele, R., Julia, V. e Santos, J. (2018). Eeg waveform analysis of p300 erp with applications to brain computer interfaces. *Brain Sciences*, 8:199.
- Rashid, U., Niazi, I. K., Signal, N. e Taylor, D. (2018). An eeg experimental study evaluating the performance of texas instruments ads1299. *Sensors*, 18(11).
- rfd22301 (2022). Especificação do módulo bluetooth rfd22301. [https://www.mouser.com/ds/2/470/rfd22301.data.sheet.11.24.13\\_11.38pm-272240.pdf](https://www.mouser.com/ds/2/470/rfd22301.data.sheet.11.24.13_11.38pm-272240.pdf). Acessado em novembro de 2022.
- Roll, I., Aleven, V., McLaren, B. M. e Koedinger, K. R. (2011). Improving students' help-seeking skills using metacognitive feedback in an intelligent tutoring system. *Learning and Instruction*, 21(2):267 – 280. Special Section I: Solving information-based problems: Evaluating sources and information Special Section II: Stretching the limits in help-seeking research: Theoretical, methodological, and technological advances.
- Ruiz, L. Z., Alomia, R. P. V., Dantis, A. D. Q., San Diego, M. J. S., Tindugan, C. F. e Serrano, K. K. D. (2017). Human emotion detection through facial expressions for commercial analysis. *2017IEEE 9th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment and Management (HNICEM)*, páginas 1–6.
- Russell, J. A. (1980). A circumplex model of affect. *Journal of personality and social psychology*, 39(6):1161.
- Russell, J. A. e Mehrabian, A. (1977). Evidence for a three-factor theory of emotions. *Journal of Research in Personality*, 11(3):273 – 294.
- Sabatinelli, D., Bradley, M. M., Fitzsimmons, J. R. e Lang, P. J. (2005). Parallel amygdala and inferotemporal activation reflect emotional intensity and fear relevance. *NeuroImage*, 24(4):1265–1270.
- Sabatinelli, D., Bradley, M. M., Lang, P. J., Costa, V. D. e Versace, F. (2007). Pleasure rather than salience activates human nucleus accumbens and medial prefrontal cortex. *Journal of Neurophysiology*, 98(3):1374–1379. PMID: 17596422.
- Sabatinelli, D., Lang, P. J., Keil, A. e Bradley, M. M. (2006). Emotional Perception: Correlation of Functional MRI and Event-Related Potentials. *Cerebral Cortex*, 17(5):1085–1091.
- Sadoughi, M. e Hejazi, S. Y. (2021). Teacher support and academic engagement among efl learners: The role of positive academic emotions. *Studies in Educational Evaluation*, 70:101060.
- Samson, V. R. R., Praveen Kitti, B., Pradeep Kumar, S., Suresh Babu, D. e Monica, C. (2018). Electroencephalogram-based openbci devices for disabled people. Em Satapathy, S. C.,

- Bhateja, V., Chowdary, P. S. R., Chakravarthy, V. S. e Anguera, J., editores, *Proceedings of 2nd International Conference on Micro-Electronics, Electromagnetics and Telecommunications*, páginas 229–238, Singapore. Springer Singapore.
- Sanei, S. e Chambers, J. (2013). *Fundamentals of EEG Signal Processing*, capítulo: 2, páginas 35–125. John Wiley & Sons, Ltd.
- Sazgar, M. e Young, M. G. (2019). *Overview of EEG, Electrode Placement, and Montages*, páginas 117–125. Springer International Publishing, Cham.
- Scherer, K. R. (2005). What are emotions? and how can they be measured? *Social Science Information*, 44(4):695–729.
- Silva, D. F. S. d. (2014). *Assistente pessoal para suporte ao ensino da leitura do português a crianças*. Tese de doutorado, Universidade do Minho - Escola de Engenharia.
- Silva, P., Costa, E. e de Araújo, J. R. (2019). An adaptive approach to provide feedback for students in programming problem solving. Em *International Conference on Intelligent Tutoring Systems*, páginas 14–23. Springer.
- Silverman, D. (1963). The rationale and history of the 10-20 system of the international federation. *American Journal of EEG Technology*, 3(1):17–22.
- Silverthorn, D. U. (2010). *Fisiologia humana: uma abordagem integrada*. Artmed editora.
- Sleeman, D. e Brown, J. S. (1982). *Intelligent tutoring systems*. London: Academic Press.
- Soares, P., Comesaña, M., Pinheiro, A., Frade, S., Pureza, R. e Costa, A. (2011). Palavras, sons e imagens: Normas afectivas de valência, activação e dominância para o português europeu. *6o Encontro Nacional da Associação Portuguesa de Psicologia Experimental (APPE)*.
- Tae-Gyu, L. (2019). Data pattern modeling for bio-information processing based on openbci platform. Em *Journal of the convergence on culture technology : JCCT*.
- Tarnowski, P., Kołodziej, M., Majkowski, A. e Rak, R. J. (2017). Emotion recognition using facial expressions. *Procedia Computer Science*, 108:1175 – 1184. International Conference on Computational Science, ICCS 2017, 12-14 June 2017, Zurich, Switzerland.
- Teixeira, M. B. (2012). Regulação nervosa e hormonal nos animais. <https://pt.slideshare.net/margaridabt/regulao-nervosa-e-hormonal-nos-animais-13125302>. Acessado em novembro de 2022.
- Tiam-Lee, T. J. e Sumi, K. (2018). Adaptive feedback based on student emotion in a system for programming practice. Em *International Conference on Intelligent Tutoring Systems*, páginas 243–255. Springer.
- Toastr (2022). Toastr. <https://codeseven.github.io/toastr/>. Acessado em novembro de 2022.
- Toisoul, A., Kossaifi, J., Bulat, A., Tzimiropoulos, G. e Pantic, M. (2021). Estimation of continuous valence and arousal levels from faces in naturalistic conditions. *Nature Machine Intelligence*.



- Toisoul, A., Kossaifi, J., Bulat, A., Tzimiropoulos, G. e Pantic, M. (2022). Emonet. <https://github.com/face-analysis/emonet>. Acessado em novembro de 2022.
- Toledo, A. F. S. e Nogueira, F. J. (2021). Uso de brain computer interface para controle de próteses mecânica. *Caderno de Estudos em Engenharia Elétrica*, 3(2).
- Tortora, G. J. e Derrickson, B. H. (2018). *Principles of anatomy and physiology*. John Wiley & Sons.
- Tsang, S. H. e Sharma, T. (2018). Electrooculography. *Atlas of Inherited Retinal Diseases*, páginas 21–22.
- Tyng, C. M., Amin, H. U., Saad, M. N. e Malik, A. S. (2017). The influences of emotion on learning and memory. *Frontiers in psychology*, 8:1454.
- Ultracortex (2022). Ultracortex para impressão 3d. <https://docs.openbci.com/AddOns/Headwear/MarkIV/>. Acessado em novembro de 2022.
- USP (2022). Sinapse neuromuscular. [https://edisciplinas.usp.br/pluginfile.php/4421805/mod\\_resource/content/0/Sinapse%20Neuromuscular.pdf](https://edisciplinas.usp.br/pluginfile.php/4421805/mod_resource/content/0/Sinapse%20Neuromuscular.pdf). Acessado em novembro de 2022.
- Valadares, A. P. e Araújo, D. B. d. (2007). *Mapeamento do córtex somatosensorial através da ressonância magnética funcional: possíveis aplicações clínicas em acidente vascular encefálico e epilepsia extratemporal*. Tese de doutorado, USP.
- Vidal, J. (1977). Real-time detection of brain events in eeg. *Proceedings of the IEEE*, 65(5):633–641.
- VIGOTSKY, L. S. e da Mente, A. F. S. (1994). o desenvolvimento dos processos psicológicos superiores. *Trad. José*.
- Wang, K., Steyn-Ross, M., Steyn-Ross, D., Wilson, M. e Sleight, J. (2014). Eeg slow-wave coherence changes in propofol-induced general anesthesia: Experiment and theory. *Frontiers in systems neuroscience*, 8:215.
- Wiem, M. e Lachiri, Z. (2017). Emotion classification in arousal valence model using mahnob-hci database. *International Journal of Advanced Computer Science and Applications*, 8.
- Woo, C. W., Evens, M. W., Freedman, R., Glass, M., Shim, L. S., Zhang, Y., Zhou, Y. e Michael, J. (2006). An intelligent tutoring system that generates a natural language dialogue using dynamic multi-level planning. *Artificial Intelligence in Medicine*, 38(1):25 – 46. Intelligent Medical Training Systems.
- Xu, T., Zhou, Y., Wang, Z. e Peng, Y. (2018a). Learning emotions eeg-based recognition and brain activity: A survey study on bci for intelligent tutoring system. *Procedia Computer Science*, 130:376–382. The 9th International Conference on Ambient Systems, Networks and Technologies (ANT 2018) / The 8th International Conference on Sustainable Energy Information Technology (SEIT-2018) / Affiliated Workshops.
- Xu, T., Zhou, Y., Wang, Z. e Peng, Y. (2018b). Learning emotions eeg-based recognition and brain activity: A survey study on bci for intelligent tutoring system. *Procedia Computer Science*, 130:376 – 382.

- Yamamoto, S., Tobe, Y., Tawatsuji, Y. e Hirashima, T. (2021). In-process feedback by detecting deadlock based on eeg data in exercise of learning by problem-posing. Em *Proceedings of the 29th International Conference on Computers in Education*, páginas 21–30.
- Zataráin-Cabada, R., Estrada, M. L. B., Camacho, J. L. O. e García, C. A. R. (2014). Affective tutoring system for android mobiles. Em *ICIC*.
- Zheng, J., Huang, L., Li, S., Lajoie, S. P., Chen, Y. e Hmelo-Silver, C. E. (2021). Self-regulation and emotion matter: A case study of instructor interactions with a learning analytics dashboard. *Computers & Education*, 161:104061.

## APÊNDICE A – IMPRESSÃO E MONTAGEM DO OPENBCI

Para a realização do estudo de análise de atividade neural via EEG, foi utilizado o OpenBCI para fazer a interação cérebro-computador, e por se tratar de um projeto de software livre, permite o download dos arquivos do *frame* 3D para impressão.

### A.1 IMPRESSÃO DO *HEADSET* DO OPENBCI

A máquina utilizada para a impressão 3D dos arquivos foi a impressora 3DClonerLab de 200mm x 200mm x 200mm que é controlada por um arduino Mega e possui uma boa qualidade para impressão (Figura A.1). O material utilizado para a impressão foi o PLA, que é um dos polímeros mais utilizados nesse tipo de impressão. Existem outros tipos de materiais, ABS ou PetG, porém, a impressora trabalha melhor com PLA. A cor do filamento escolhido foi branco por ser uma cor neutra e hoje é como um padrão para o OpenBCI, mas poderia ser impresso com qualquer cor.




Figura A.1: Impressora 3DCloner Lab  
Fonte: própria.

Os arquivos para impressão foram baixados do projeto OpenBCI e foi o modelo Mark IV (Ultracortex, 2022), sendo a parte frontal e parte traseira o *frame* médio (M4\_Board\_Cover.stl e M4\_Board\_Mount.stl), trinta e duas polcas (M4\_Hardware\_insert\_loose.STL), trinta e dois cliques (M4\_Wire\_Clip.stl) e a estrutura que segura a placa eletrônica do OpenBCI, boca e capa (M4\_Board\_Cover.stl e M4\_Board\_Mount.stl). A Figura A.2 podem ser vistos os arquivos para download em Ultracortex (2022).




Figura A.2: Arquivos STL para impressão da estrutura 3D do OpenBCI  
Fonte: Adaptado de Ultracortex (2022).

Após o *download* dos arquivos para o computador, a etapa de configuração e fatiamento dos objetos foi realizado com o software *Slic3r*. Fatiamento é a técnica de dividir o objeto 3D em camadas pois a impressora imprime de baixo para cima, camada por camada.






Figura A.3: Arquivos sendo configurados para o fatiamento  
Fonte: Própria.

Uma vez configurado, os arquivos fatiados foram gerados na extensão gcode para que a impressora3D leia e imprima através de um cartão SD, mas havia também a possibilidade de impressão direto do computador através do software RepetierHost, que foi tentado, porém, qualquer queda de energia ou falha no computador, ocasionava a parada da impressão e perda da peça, e por este motivo, foi decidido usar apenas a impressão por cartão SD. A Figura *objetosimpressos* exibe o resultado final após a impressão dos objetos.



Figura A.4: Objetos impressos de acordo com os arquivos STL do OpenBCI

Fonte: Própria.

Inicialmente tentou-se imprimir o *frame* médio na posição normal, ou seja, em pé, porém, verificou-se que além de gastar muito filamento PLA, verificou-se que o tempo para impressão era muito grande por conta do suporte que precisava ser impresso para sustentar a estrutura. Por esse motivo, a segunda tentativa foi imprimir de cabeça para baixo, pois assim não seria necessária a impressão de todo o suporte, economizando filamento e tempo.

Foram impressas três *frames*, dois de tamanho médio, sendo duas partes, e um de tamanho grande, sendo quatro partes, pois a impressora não comportava duas partes do *frame* grande por sua base ser apenas de 200x200 mm. Foram impressos estes tamanhos para uma eventual necessidade nos dias dos experimentos.

Uma vez impressas as peças do Ultracortex, foi necessária um trabalho de pós-processamento, como lixamento, retirada de rebarbas e detalhes. Os detalhes das peças impressoras, o processo de pós-processamento e de montagem podem ser vistos nas Figuras próxima seção.



Figura A.5: Peças impressas: Estrutura que segura a placa eletrônica.  
Fonte: Própria.



Figura A.6: Peças impressas: Polcas que seguram os eletrodos.  
Fonte: Própria.



Figura A.7: Peças impressas: Clipes para segurar *jumpers*.  
Fonte: Própria.



Figura A.8: Peças impressas: *Frames* dividida em duas partes.  
Fonte: Própria.



## A.2 ETAPA DE PÓS-PROCESSAMENTO



Figura A.9: Material para pós-processamento das peças do *frame*.  
Fonte: Própria.




Figura A.10: Pós-processamento das peças do *frame*.  
Fonte: Própria.




Figura A.11: Pós-processamento das peças do *frame*.  
Fonte: Própria.



Figura A.12: Colagem das duas partes do *frame*.  
Fonte: Própria.



Figura A.13: Montagem: inserindo as polcas.  
Fonte: Própria.

## A.3 COMPONENTES ELETRÔNICOS DO OPENBCI




Figura A.14: Pós-processamento das peças do *frame*.  
Fonte: Própria.




Figura A.15: Bateria de Lipo utilizada no OpenBCI, com o carregador USB.  
Fonte: Própria.



Figura A.16: Eletrodos secos de cloreto de prata.  
Fonte: Própria.




Figura A.17: *jumpers* para conexão entre eletrodos e pinos da placa Cyton.  
Fonte: Própria.



Figura A.18: Eletrodos em forma de pinça para fixação no lobo auricular, A1 e A2 no sistema 10-20, servindo como terra.

Fonte: Própria.




Figura A.19: Eletrodos para serem fixados no lobo auricular (A1 e A2 no sistema 10-20, servindo como terra.

Fonte: Própria.

## A.4 MONTAGEM FINAL DO OPENBCI




Figura A.20: Montagem: fixação do compartimento da placa eletrônica no *frame headset*.  
Fonte: Própria.



Figura A.21: Montagem: encaixando um eletrodo no *frame*.  
Fonte: Própria.




Figura A.22: *jumpers* para conexão entre eletrodos e pinos da placa Cyton.  
Fonte: Própria.





Figura A.23: Montagem: encaixando os quatro eletrodos, F3, F4, AF3 e AF4, de acordo com o sistema 10-20, necessários para o FEA.

Fonte: Própria.




Figura A.24: Montagem: eletrodos F3, F4, AF3 e AF4 no *frame*.

Fonte: Própria.




Figura A.25: Montagem: detalhe dos eletrodos secos do lado esquerdo.  
Fonte: Própria.



Figura A.26: Montagem: Eletrodos secos mais aproximados.  
Fonte: Própria.




Figura A.27: Montagem: conectando *jumper*s dos eletrodos na placa Cyton.  
Fonte: Própria.




Figura A.28: Montagem: encaixando a placa Cyton no compartimento.  
Fonte: Própria.




Figura A.29: Montagem: encaixando a tampa do compartimento para proteção da placa Cyton.  
Fonte: Própria.




Figura A.30: Montagem: teste do funcionamento da placa Cyton  
Fonte: Própria.

## A.5 UTILIZAÇÃO DO OPENBCI NOS DIAS DO EXPERIMENTO



Figura A.31: Utilização do OpenBCI: Estudante se senta na cadeira e ao lado está o OpenBCI.  
Fonte: Própria.




Figura A.32: Utilização OpenBCI: O estudante veste o OpenBCI, fazendo contato com todos os eletrodos no couro cabeludo.

Fonte: Própria.



Figura A.33: Utilização OpenBCI: Visão lateral direita do estudante com OpenBCI.  
Fonte: Própria.





Figura A.34: Utilização OpenBCI: Visão lateral esquerda do estudante com OpenBCI.  
Fonte: Própria.




Figura A.35: Utilização OpenBCI: Aproximação da visão lateral direita do estudante com OpenBCI.  
Fonte: Própria.




Figura A.36: Utilização OpenBCI: Visão superior do estudante com OpenBCI, os *jumpers* não se tocam em momento algum.

Fonte: Própria.