

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

MARIA LUIZA RECENA MENEZES

**PROPOSTA DE USO
DE ESTADO EMOCIONAL DO INDIVÍDUO
NA AUTOMAÇÃO DE AMBIENTE INTELIGENTE**

Porto Alegre

2015

MARIA LUIZA RECENA MENEZES

**PROPOSTA DE USO DE ESTADO EMOCIONAL DO
INDIVÍDUO NA AUTOMAÇÃO DE AMBIENTE
INTELIGENTE**
**ESTUDO DE CASO: AUMENTO DO NÍVEL DE ATENÇÃO DO
INDIVÍDUO ATRAVÉS DA ADAPTAÇÃO AUTOMÁTICA DE
AMBIENTE INTELIGENTE**

Dissertação de mestrado apresentada ao
Programa de Pós-Graduação em Engenharia Elétrica,
da Universidade Federal do Rio Grande do Sul, como
parte dos requisitos para a obtenção do título de Mestre
em Engenharia Elétrica/Doutor em Engenharia
Elétrica.
Área de concentração: Controle e Automação

ORIENTADOR: Carlos Eduardo Pereira

Porto Alegre

2015

MARIA LUIZA RECENA MENEZES

**PROPOSTA DE USO DE ESTADO EMOCIONAL DO
INDIVÍDUO NA AUTOMAÇÃO DE AMBIENTE
INTELIGENTE**
ESTUDO DE CASO: AUMENTO DO NÍVEL DE ATENÇÃO DO
INDIVÍDUO ATRAVÉS DA ADAPTAÇÃO AUTOMÁTICA DE
AMBIENTE INTELIGENTE

Esta dissertação/tese foi julgada adequada para a
obtenção do título de Mestre em Engenharia
Elétrica/Doutor em Engenharia Elétrica e aprovada em
sua forma final pelo Orientador e pela Banca
Examinadora.

Orientador: _____

Prof. Dr. Carlos Eduardo Pereira, UFRGS

Doutor pela Universidade de Stuttgart – Stuttgart, Alemanha

Banca Examinadora:

Prof. Dr. Alexandre Balbinot - PPGEE - UFRGS

Doutor pela Universidade Federal do Rio Grande do Sul – Porto Alegre, Brasil

Profª. Dra. Rosa Maria Vicari - PPGC-UFRGS

Doutora pela Universidade de Coimbra – Coimbra, Portugal

Prof. Dr. Renato Ventura Bayan Henriques - PPGEE-UFRGS

Doutor pela Universidade Federal de Minas Gerais – Belo Horizonte, Brazil

Coordenador do PPGEE: _____

Prof. Dr. Luís Fernando Alves Pereira

Porto Alegre, Maio de 2015

DEDICATÓRIA

À minha mãe, pela inspiração.

Ao meu pai, pela força.

AGRADECIMENTOS

Ao Programa de Pós-Graduação em Engenharia Elétrica e aos meus professores, pela oportunidade de realização de trabalhos em minha área de pesquisa.

À CAPES pela provisão da bolsa de mestrado.

Aos amigos, colegas e familiares, por todo carinho, apoio e café.

RESUMO

A questão de pesquisa que este estudo pretende abordar visa melhorar a qualidade de vida dos usuários, especialmente os portadores de necessidades especiais, adaptando o ambiente ao seu conforto emocional. Nesse contexto, o objetivo da presente pesquisa é a elaboração de um ambiente inteligente controlado passivamente através do estado emocional do usuário, utilizando interface cérebro computador. De forma geral, espera-se com este estudo ser capaz de adaptar um sistema inteligente de acordo com a emoção objetivo, visando o aumentando do rendimento do indivíduo numa dada tarefa, auxiliando em tratamentos terapêuticos ou aumentando o seu conforto. Para validação do trabalho foi utilizada a interface cérebro-computador da empresa *Emotiv* com o sistema de automação predial-residencial da empresa *Home Systems*, utilizando algoritmo genético para buscar a configuração adequada do ambiente tendo o nível de atenção como emoção objetivo. Os resultados preliminares dos nove testes realizados com seis indivíduos comprovam que é viável o controle de ambientes baseado no estado emocional dos usuários. Este trabalho situa-se na interdisciplinaridade de áreas como engenharia elétrica, computação, psicologia comportamental e tecnologias assistivas.

Palavras-chave: Ambientes Inteligentes, Tecnologias Assistivas, Eletroencefalograma, Interface Cérebro Computador, Computação Afetiva, Algoritmo Genético, Processos Psicológicos Básicos, Controle e Automação.

ABSTRACT

The research question that this study aims to approach is to improve the quality of life of individuals with or without special needs, by adapting the environment to their emotional comfort. In this context, the goal of this research is to develop an intelligent system passively controlled through brain-computer interface. In general, it is expected with this study to be able to adapt a smart environment according to the emotional target, aiming to increase the yield of a given individual task, assisting in therapeutics or increasing the individual's comfort. In order to validate the experiment, *Emotiv's* brain computer interface was used with *Home Systems'* home automation system, using genetic algorithm to find the appropriate configuration of the environment and attention level as the emotional target. Preliminary results of the nine tests conducted on six subjects indicate that it is feasible to control a smart environment based on the emotional state of the user. This is an interdisciplinary work in areas such as electrical engineering, computer science, behavioral psychology and assistive technologies.

Keywords: Smart Environments, Assistive Technologies, EEG, Control and Automation, Genetic Algorithm, Brain-Computer Interface and Psychological Basic Processes.

SUMÁRIO

1	INTRODUÇÃO	11
2	FUNDAMENTAÇÃO TEÓRICA.....	14
2.1	AMBIENTES INTELIGENTES.....	14
2.2	ALGORITMOS GENÉTICOS	15
2.3	COMPUTAÇÃO AFETIVA.....	17
2.4	TECNOLOGIAS ASSISTIVAS	18
2.4.1	Interface Cérebro Computador (ICC)	18
3	TRABALHOS RELACIONADOS	24
3.1	INTERFACE CÉREBRO COMPUTADOR.....	24
3.2	INTERPRETAÇÃO DE ESTRESSE E ATENÇÃO USANDO EEG	26
3.3	CONTROLE DE AMBIENTES INTELIGENTES	28
3.4	USO DE ALGORITMOS GENÉTICOS EM SISTEMAS DE CONTROLE	29
4	VISÃO GERAL DO SISTEMA	31
5	PROPOSTA DE ARQUITETURA DO SISTEMA.....	35
5.1	CAMADA DE USUÁRIO	37
5.2	CAMADA DE COMPOSIÇÃO.....	40
5.2.1	Algoritmo Desenvolvido	42
5.3	CAMADA PERVASIVA.....	47
6	VALIDAÇÃO DA ARQUITETURA PROPOSTA	50
6.1	PROCESSAMENTO DO SINAL DE EEG	50
6.1.1	Estresse	51
6.1.2	Atenção	52
6.1.3	Engajamento	54
6.2	ALGORITMO GENÉTICO.....	56
6.2.1	Notações e Representações dos Parâmetros.....	56
6.2.2	Fluxo do Algoritmo.....	60
7	TESTES E RESULTADOS	63
7.1	TESTES DAS ANÁLISES DOS SINAIS DE EEG	63
7.2	TESTES COM USUÁRIOS.....	65
7.2.1	Testes Controle	66
7.2.2	Testes Experimentais.....	70
8	CONCLUSÃO.....	75
9	TRABALHOS FUTUROS	77

LISTA DE ILUSTRAÇÕES

Figura 1 - Exemplo de sistema ICC típico.	19
Figura 2 – Visão Geral do Sistema.....	33
Figura 3 – Arquitetura Proposta	36
Figura 4 - Coordenadas dos eletrodos, de acordo com o Sistema Internacional 10-20. [Emotiv, 2012]	39
Figura 5 – Fluxograma simplificado do algoritmo implementado em linguagem C/C++	42
Figura 6 – Algoritmo da Camada Pervasiva.....	48
Figura 7 - Systembox.....	49
Figura 8 - Definição da estrutura “cenário” em código C/C++.....	57
Figura 9 - Exemplos de Crossover de Um Ponto em que o ponto de corte é, respectivamente quatro e seis.	58
Figura 10 - Exemplo de Crossover com Máscara Aleatória.....	59
Figura 11 - Exemplos de Mutação no quarto e sexto bits/genes respectivamente	60
Figura 12 - Voluntário executando teste experimental.....	70
Figura 13 – Modelo Circumplexo de Russel	101
Figura 14 - Escala SAM para os níveis de valência (superior) e alerta (inferior)	102
Figura 15 - Símbolos usados no teste AC vetor	107
Figura 16 - Símbolos usados no TACOM-A.....	107
Figura 17 - Símbolos usados no TACOM-B.....	107

LISTA DE TABELAS

Tabela 1 - Resultados alcançados em trabalhos relacionados com reconhecimento de estresse	27
--	----

LISTA DE ABREVIATURAS

AmI: Ambientes Inteligentes

API: Application Program Interface (interface de programação de aplicações)

DEAP: Database for Emotion Analysis using Physiological Signals

EEG: Eletroencefalograma

ICC: Interface Cérebro Computador

SAM: Self Assessment Manikin

1 INTRODUÇÃO

As chamadas tecnologias assistivas ainda são um termo novo, utilizado para identificar os recursos e serviços que contribuem para proporcionar ou ampliar as habilidades funcionais de pessoas com alguma debilidade, como deficientes físicos, mentais ou idosos. Pesquisas recentes buscam soluções de tecnologias assistivas e dispositivos que acompanham o usuário para ambientes completos de suporte, trazendo uma verdadeira autonomia para o usuário na execução de suas tarefas.

A automação predial e residencial tem se tornado um grande aliado para soluções de autonomia e facilidades para o usuário. Neste contexto define-se o termo “Ambientes Inteligentes” (AmI), que traz uma mudança de paradigma: deixa-se de lado o fato de apenas controlar dispositivos e parte-se para um mundo onde os dispositivos são capazes de autogerenciamento, estando cientes (*aware*) de tudo que os cerca [Ducatel, 2001][Perozzo, 2012]. Começa a se tornar realidade a computação ubíqua vislumbrada por Mark Weiser [Neuman, 1995], definida como sendo um estágio tal no nível de automação e computação de ambientes e pessoas, no qual pessoas e dispositivos interagem, sem que essa interação seja percebida.

Um dos problemas comumente encontrados nesse tipo de aplicação é justamente a dificuldade que o usuário tem em interagir com o ambiente. Por isso, é importante identificar todas as possíveis formas de interação e estruturá-las com base nas condições e no domínio do problema, o que inclui interfaces intuitivas, adaptação ao contexto, sistemas que reagem às ações dos usuários, gerenciamento de conteúdo, diálogo multimodal e aplicações multimídias [Peçanha, 2012]. Em alguns estudos mais recentes, pesquisas estão direcionadas para a interface cérebro-computador, tentando incorporar as respostas do ambiente diretamente às atividades cerebrais do usuário [Edlinger, 2011][Ruscher, 2011] [Lin, Chin-Teng, 2010].

Neste contexto, esta dissertação objetiva estudar possibilidades de integração entre Interfaces Cérebro Computador para Ambientes Inteligentes, de modo a permitir que o sistema de automação se ajuste não apenas baseado em informações de variáveis físicas como temperatura ou luminosidade, mas que se adaptem ao estado emocional dos usuários, buscando reduzir o estresse das pessoas presentes no ambiente, aumentando a sua produtividade ou a atenção no desenvolvimento de suas tarefas. Ou seja, busca-se explorar as modificações dos sinais do cérebro traduzindo-os para acionamento de comandos que permitem a interação com o ambiente automatizado de forma a se obter suporte inteligente nas atividades diárias dos usuários.

Com a análise do estado da arte (a qual será detalhada no capítulo 3) concluiu-se que a grande maioria dos estudos e aplicações se utilizam desta interface para controlar o Ambiente Inteligente de maneira ativa, como em [Cabral, 2002] e [Onusic, 2005], em que o usuário deve treinar para conseguir modular seus padrões cerebrais a fim de selecionar opções num menu, por exemplo. Esta solução em geral é custosa para o usuário e, ao invés de uma facilidade, acaba se tornando um complicador e se distanciando da proposta inicial de computação ubíqua; chegando até mesmo a restringir o sentido da sua aplicabilidade àqueles que realmente não podem interagir por vias motoras.

Esta pesquisa, pelo contrário, se propõe a procurar uma solução de interface natural e transparente, que possa ser usada não apenas por aqueles com dificuldades motoras, mas também por deficientes mentais ou pessoas sem qualquer deficiência: por não requerer treinamento por parte do indivíduo nem ser uma solução mais complicada do que o simples acionar de botões.

Este trabalho tem como objetivo utilizar diretamente o estado emocional do indivíduo para controle e adaptação automática de um Ambiente Inteligente de maneira passiva para o usuário.

O texto desta dissertação está estruturado da seguinte forma: Primeiramente, no Capítulo 2, temos a Fundamentação Teórica, em que conceitos importantes para o entendimento deste trabalho, como Ambientes Inteligentes, Algoritmos Genéticos, Computação Afetiva, Tecnologias Assistivas e Interface Cérebro Computador são apresentados. No Capítulo 3 serão discutidos os Trabalhos Relacionados, dentro das subáreas de Interface Cérebro Computador, Interpretação de Estresse e Atenção utilizando Eletroencefalograma, Controle de Ambientes Inteligentes e o Uso de Algoritmos Genéticos em Sistemas de Controle. No Capítulo 4 é dada uma Visão Geral do Sistema, que será explicada de maneira mais aprofundada no Capítulo 5, Proposta de Arquitetura do Sistema. Neste Capítulo explica-se em detalhes a estrutura em camadas proposta para o sistema: Camadas de Usuário, Composição e Pervasiva; cuja implementação será explicada no Capítulo 6, Metodologia. Os testes experimentais serão mostrados e analisados no Capítulo 7, sendo divididos entre Testes das Análises dos Sinais de EEG, Testes do Sistema e Testes com Usuários, sendo este último ainda subdividido entre Testes de Controle e Experimentais. Por fim, a Conclusão no Capítulo 8 discutirá as contribuições mais importantes deste trabalho e no Capítulo 9 apresentaremos os Trabalhos Futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo serão apresentados conceitos fundamentais utilizados no trabalho, dividindo-se em: Ambientes Inteligentes, Algoritmo Genético, Computação Afetiva, Tecnologias Assistivas e Interfaces Cérebro Computador.

2.1 AMBIENTES INTELIGENTES

No âmbito dos Sistemas Inteligentes, há uma mudança de paradigma: deixa-se de lado o fato de apenas controlar dispositivos e parte-se para um mundo onde os dispositivos são capazes de autogerenciamento, estando cientes (*aware*) de tudo que os cerca [Ark, 1999]. Começa a se tornar realidade a computação ubíqua vislumbrada por Mark Weiser definida como sendo um estágio tal no nível de automação e computação de ambientes e pessoas, no qual pessoas e dispositivos interagem, sem que essa interação seja percebida [Weiser, 1991].

A aplicabilidade e o desenvolvimento de Ambientes Inteligentes está atrelado à evolução da tecnologia, como na área de microeletrônica, cujo desenvolvimento permite que sejam criados dispositivos menores, mais baratos e de maior capacidade computacional, da área de comunicação de dados e redes de computadores, possibilitando que haja diversos dispositivos interconectados, e com o desenvolvimento de interfaces mais simples e eficientes. Ambientes inteligentes englobam o estudo de sensores, da rede de comunicação, de interação homem máquina e de computação, dentro outras diversas áreas de pesquisa.

O foco do estudo em ambientes inteligentes sempre foi centrado no usuário em si, a fim de promover a sua qualidade de vida, levando em consideração situações de entretenimento, de socialização, de trabalho, de aprendizado, de descanso e de cuidados da saúde. Com relação à saúde, o suporte para o gerenciamento de doenças é um fator importante, permite que o usuário participe do controle de sua própria saúde ou da de seus

familiares. Ao monitorar as atividades físicas e psicológicas em pessoas com algum tipo de deficiência, de doenças graves ou de doenças psicológicas, é possível, por exemplo, disponibilizar lembretes para controle de medicamentos e imunização caso o sistema esteja ligado a uma rede de telecomunicações ou à Internet. Esses sistemas podem enviar um alerta para profissionais capacitados e familiares em caso de mudanças bruscas ou que representem perigo ao usuário. Seguindo esse pensamento, o monitoramento por longos períodos de tempo também serve para monitoramento pós cirurgia, para controle de condições crônicas e controle dos efeitos de algum tipo de tratamento com medicamentos.

Um dos problemas comumente encontrados nesse tipo de aplicação é a dificuldade que o usuário tem em interagir com os sistemas, cada vez mais complexos. Por isso, é importante identificar todas as possíveis formas de interação e estruturá-las com base nas condições e no domínio do problema, o que inclui interfaces intuitivas, adaptação ao contexto, sistemas que reagem às ações dos usuários, gerenciamento de conteúdo, diálogo multimodal e aplicações multimídias.

2.2 ALGORITMOS GENÉTICOS

Algoritmos Genéticos, introduzidos por John Holland e popularizados por David Goldberg [Lacerda, 1999], são métodos de otimização e busca inspirados nos mecanismos de evolução de populações de seres vivos. Seguindo o princípio de seleção natural e sobrevivência do mais apto, declarado, em 1859, pelo naturalista e fisiologista inglês Charles Darwin em seu livro “A Origem das Espécies”: quanto melhor um indivíduo se adaptar ao seu meio ambiente, maior será sua chance de sobreviver e gerar descendentes [Lacerda, 1999].

Em algoritmos genéticos, usualmente tem-se uma função objetivo que se pretende minimizar ou maximizar. Em termos genéticos a função objetivo é chamada aptidão. Desta

forma, quando o objetivo é maximização, algoritmos genéticos procuram a maior aptidão possível, já no caso de minimização, procuram a menor aptidão possível.

Parte-se de uma população inicial, em que cada indivíduo da população é uma possível solução para o problema. Através de uma seleção elitista, os indivíduos mais aptos, ou seja, as soluções com o valor da função objetivo mais alto, são selecionados para formar uma nova geração. Uma geração é um conjunto limitado de indivíduos com valores de aptidão elevados.

Após a criação de uma geração, um ordenamento é feito pela aptidão. Em seguida é feita uma seleção que pode ser aleatória ou elitista. A seleção aleatória aumenta a variabilidade gênica e dá a mesma probabilidade para todos os indivíduos se reproduzirem. A seleção elitista seleciona os indivíduos mais aptos para reprodução.

Na reprodução, dois indivíduos são combinados e criam um novo indivíduo. Os operadores genéticos crossover, e mutação são usados na reprodução. Crossover cria uma nova solução, a partir da combinação de duas soluções já existentes. Mutação altera o valor de um bit aleatoriamente de acordo com uma probabilidade estabelecida pela teoria da seleção natural. A mutação contribui para aumentar a variabilidade das soluções e ajuda a aumentar o tempo para convergência para mínimos locais [M. Mitchell,1996].

Os indivíduos mais aptos dentre os velhos e os novos, formarão a próxima geração e o algoritmo roda assim até atingir um critério de parada.

O critério de parada pode ser definido por [Affenzeller, 2009]:

- a) Solução que satisfaz um critério mínimo, ou seja, uma aptidão limite também chamada de aptidão objetivo;
- b) Número fixo de gerações;
- c) Limite de recursos computacionais como limite de tempo, ou alocação de memória;

- d) Número fixo de iterações nas quais não é encontrada nenhuma solução com aptidão superior a solução com melhor aptidão encontrada até o momento;
- e) Intervenção manual.

O critério de parada pode também ser definido por uma combinação dos critérios citados. O critério de parada por aptidão objetivo pode também ser recalculado durante a execução caso em um determinado número de iterações, a aptidão não apresente melhora.

No algoritmo implementado neste trabalho, especificamente, é utilizado o critério da aptidão objetivo para que o algoritmo pare a execução, e quando um valor abaixo da aptidão objetivo é identificado o algoritmo volta a executar. A execução termina com um limite de tempo, ou com o término da atividade que está sendo executada pelo usuário

2.3 COMPUTAÇÃO AFETIVA

Computação afetiva é a computação que se relaciona com, surge de ou deliberadamente influencia a emoção ou outros fenômenos afetivos. Emoção é fundamental para a experiência humana, influencia a cognição e as tarefas diárias como aprendizagem, comunicação e as tomadas de decisões racionais [Picard, 1995]. A pesquisa em computação afetiva é interdisciplinar e combina áreas como engenharia e ciência da computação com a psicologia, a neurociência, a sociologia, a educação e a psicofisiologia dentre outras [Affective, 2014].

O estudo da computação afetiva se iniciou em 1995 com a publicação do paper “Affective Computing” de Rosalind Picard [Picard, 1995] e a motivação de pesquisar a habilidade de simular empatia, a máquina deveria interpretar o estado emocional do humano e adaptar o seu comportamento a ele, dando uma resposta apropriada a estas emoções.

Pode-se separar a computação afetiva em duas grandes áreas:

- a) Detecção e reconhecimento de emoções, das quais podemos citar principalmente: análise de expressão facial, voz, gestos e biossinais.
- b) Simulação de emoções, como robôs sociáveis e a utilização de protocolos sociais [Cosack, 2006].

2.4 TECNOLOGIAS ASSISTIVAS

As chamadas Tecnologias Assistivas, definidas no Brasil pelo Comitê de Ajudas Técnicas – CAT, instituído pela PORTARIA N° 142, DE 16 DE NOVEMBRO DE 2006, como "área do conhecimento, de característica interdisciplinar, que engloba produtos, recursos, metodologias, estratégias, práticas e serviços que objetivam promover a funcionalidade, relacionada à atividade e participação de pessoas com deficiência, incapacidades ou mobilidade reduzida, visando sua autonomia, independência, qualidade de vida e inclusão social" [CAT VII]; ainda são um termo novo, utilizado para identificar os recursos e serviços que contribuem para proporcionar ou ampliar as habilidades funcionais das pessoas. Pesquisas recentes buscam soluções de tecnologias assistivas e dispositivos que acompanham o usuário para ambientes completos de suporte, trazendo uma verdadeira autonomia para o usuário na execução de suas tarefas.

Em alguns estudos mais recentes, pesquisas estão direcionadas para a interface cérebro computador, tentando incorporar as respostas do ambiente diretamente às atividades cerebrais do usuário.

2.4.1 Interface Cérebro Computador (ICC)

Estudos na área de Interface Cérebro-Computador são relativamente recentes, tendo seu início na década de 70, na UCLA (University of California Los Angeles) [Vidal, 1973]. Desde então, com os avanços da tecnologia, tem sido possível tornar o que antes apenas

imaginávamos, em ações. Uma Interface Cérebro-Computador (ICC) direta, como apresentada na Figura 1, propicia uma conexão direta entre os sinais cerebrais do usuário desta tecnologia e um computador, gerando um canal alternativo de comunicação que não envolve as vias tradicionais como músculos e nervos periféricos [Wolpaw, 2002]. Assim, distintas tarefas ou estados mentais podem ser associados a diferentes ações físicas, como por exemplo, o usuário pode enviar o comando “virar à direita” para uma cadeira de rodas robotizada apenas imaginando o movimento de sua mão direita [Ferreira, 2010]. Ou pode utilizar-se da via contrária: captar os sinais de um dispositivo (como as imagens de uma câmera), tratá-los e enviá-los como estímulos para o cérebro [Rita, 2003].

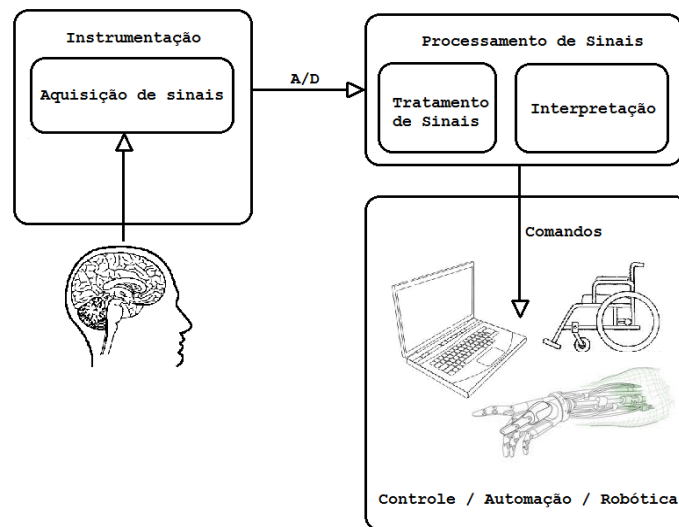


Figura 1 - Exemplo de sistema ICC típico. Fonte: elaborado pela autora.

Dentre os principais tipos de sistemas ICC hoje utilizados, podemos separá-los em três grandes grupos:

- a) Invasivo – Aqueles que são implantados diretamente na substância cinzenta do cérebro, através de cirurgia. Tal procedimento permite que o eletrodo seja implantado no local específico para a aplicação, permitindo alta

resolução de sinal e diminuição dos ruídos. Os estudos mostram, porém, que o implante do eletrodo pode gerar complicações médicas para o usuário, como rejeição ou formação de tecido fibroso ao redor do eletrodo, que pode acabar por bloquear o sinal, tornando-o inútil.

- b) Parcialmente Invasivo – São implantados dentro do crânio, porém externo à massa cinzenta, permitindo uma resolução de sinal intermediária entre os Invasivos e os Não-Invasivos. Assim como menor risco no processo de implantação e posteriores complicações médicas do que os Invasivos.
- c) Não-Invasivo – Utilizados sobre o couro cabeludo ou por outras entradas (alguns utilizam os receptores da língua para enviar sinais sensórios ao cérebro [Kupers, 2004]). Apresentam baixo risco ao usuário, por não necessitar nenhum tipo de cirurgia. Porém, sua localização afastada do ponto de interesse do cérebro tende, de maneira geral, a apresentar uma resolução de sinal mais baixa do que a dos demais tipos e maior dificuldade em determinar a área em que o sinal foi gerado, ou de afetar a área específica à aplicação.

Algumas técnicas utilizadas para obter os sinais cerebrais são:

- a) Obtenção de picos de sinais de neurônios individuais;
- b) Campos de potencial extracelular localizados (LFPs);
- c) Eletrocorticografia;
- d) Oscilações de eletroencefalograma (EEG);
- e) Campos de pontencial do cérebro baseado em eventos (ERPs);
- f) Função em tempo real de imagem por ressonância magnética (rt-fMRI);
- g) Espectroscopia de infra vermelho próximo.

Dentre estas, podemos dizer que a mais utilizada para obter uma intenção do usuário é o EEG, no qual a proposta deste projeto é focada. O sinal de EEG deve ser então amplificado, filtrado e tratado por um algoritmo de classificação para então retornar ao usuário em forma de feedback, o que permite que os usuários modulem suas atividades cerebrais. Este feedback pode ser visual, auditório, tátil, ou a execução do próprio comando da aplicação: uma resposta verbal ou visual da máquina, o movimento da uma prótese, ou até mesmo a estimulação elétrica de um músculo.

Primeiramente, a partir das pesquisas desenvolvidas na UCLA na década de 70, os estudos na área de ICC eram sumariamente focados em neuropróteses e pode-se facilmente imaginar que o público alvo para tal tecnologia seria o de pacientes com severas deficiências na comunicação e nas funções motoras.

Porém, já na década de 70 vários estudos surgiram utilizando treinamento por neurofeedback, ao quais providenciaram sólidas evidências dos efeitos positivos da tecnologia em pacientes com epilepsia, déficit de atenção e hiperatividade (ADHD). Posteriormente, com a introdução das modernas técnicas de processamento de sinais e aprendizado de máquinas, houve um grande aumento da aplicabilidade e melhora do desempenho dos sistemas ICC [Zander].

Na década de 80 começou a era “dos sistemas ICC com usuários treinados” [Zander, 2012], com projetos focados primariamente em definir novos canais de comunicação para pessoas com graves deficiências. São os casos das pesquisas de Gert Pfurtscheller, da Universidade Técnica de Graz, Áustria, que investigam mudanças nas bandas de frequências induzidas pela imaginação do movimento de membros [Pfurtscheller, 1979]; de Niels Birbaumer, da Universidade de Tuebingen, Alemanha, com o treinamento de sujeitos para controlar a polaridade dos sinais de EEG como comandos para um dispositivo de escrita [Birbaumer, 1999] e de Jonathan R. Wolpaw, do Centro Wadsworth, USA, que utilizou várias

técnicas de BCI para desenvolver sistemas de comunicação e controle para aplicações clínicas. De forma geral, todas estas técnicas requeriam um grande esforço de treinamento e concentração por parte do usuário, que só assim conseguia ter um controle básico sobre os sistemas.

Já no final dos anos 90, houve uma mudança de paradigma com a introdução de métodos de análise de dados mais complexos. Ficou possível detectar padrões induzidos por estados cerebrais naturais de forma confiável. A desvantagem destes métodos, porém, é a calibragem requerida pelo sistema. Sendo assim, muitas vezes é necessário refazer a calibragem antes de cada sessão, mesmo que para o mesmo sujeito. A mudança de paradigma, então, é que agora o peso envolvido na realização de uma comunicação ICC confiável mudou do usuário para o sistema [Mueller, 2007]. Destas pesquisas podemos citar do grupo de Gert Pfurtscheller, citado anteriormente, que desenvolveu e implementou diversos algoritmos para detectar padrões específicos, como o “Common Spacial Patterns” [Ramosé, 2000] e Jose Del Milan, em Martigny, Suíça, focou suas abordagens de aprendizado de máquina da detecção de eventos e modelos de mistura gaussiana [Zander, 2012].

Mais recentemente, com o avanço desta área, que levou a um aumento da disponibilidade de dispositivos não invasivos e conseqüente baixa do custo da tecnologia, avanços e pesquisas têm inundado a área de entretenimento e jogos, almejando não apenas aqueles que têm dificuldades motoras, mas todos os usuários interessados em acrescentar uma funcionalidade a um aplicativo ou “super poder” em algum jogos. Atualmente, as pesquisas de interação humano-computador almejam que a utilização de sistemas ICC seja como disponibilizar ao usuário um mouse, um teclado ou um controlador do tipo joystick ou Wii. Além das aplicações médicas, hoje a tecnologia ICC é mais uma maneira de interagir com máquinas.

Esta interação ativa, porém, ainda é bastante custosa para os usuários, por requerer treinamento e bastante concentração para modulação da atividade cerebral, o que acaba por orientar todo foco do usuário para a interação em si e não para a atividade proposta. Por esta razão será proposta uma arquitetura para interação passiva, utilizando o eletroencefalograma como biosinal a ser interpretado como sensor, não requerendo do usuário qualquer treinamento ou atenção na interação. Desta forma, a interação com o sistema inteligente se dará de forma transparente.

Ao contrário dos sistemas ICC clássicos, uma ICC passiva não visa o controle de um sistema por meio de comandos intencionalmente enviados pelo usuário [George, 2010] [Menezes, 2015]. Mas sim acessar e disponibilizar para o sistema informações sobre o estado do usuário com o objetivo de melhorar a interação homem-máquina [Zander, 2012] [Cotrina CBA, 2014] [Cotrina EMBC, 2014].

Até o momento, formas restritas de ICC passivas foram propostas, limitando-se a detectar carga de trabalho mental (conhecido na bibliografia como “mental workload”) [Kohlmorgen, 2007] e a percepção de erros do sistema [Blankertz, 2003]. A descrição destes sistemas normalmente não inclui uma definição de ciclo, descrevendo apenas o fluxo de informações do usuário para a máquina, sendo usadas principalmente como monitoração cognitiva [Zander, 2012].

3 TRABALHOS RELACIONADOS

Este trabalho está no âmbito da interdisciplinaridade e integração de diversas áreas como engenharia elétrica, computação, psicologia comportamental e tecnologias assistivas; sendo que não foram encontrados, até o momento, trabalhos correlacionados a todos os aspectos desenvolvidos nesta pesquisa. Motivo pelo qual nesta seção serão apresentados trabalhos que se relacionam à presente pesquisa dentro de sua subárea.

3.1 INTERFACE CÉREBRO COMPUTADOR

Conforme apresentado na seção 2.4.1., uma Interface Cérebro-Computador propicia uma conexão direta entre os sinais cerebrais do usuário desta tecnologia e um computador, gerando um canal alternativo de comunicação que não envolve as vias tradicionais como músculos e nervos periféricos [Wolpaw, 2002]. Distintos estados mentais podem ser associados a ações físicas, como por exemplo o trabalho de [Ferreira, 2010], em que o usuário pode enviar o comando “virar à direita” para uma cadeira de rodas robotizada apenas imaginando o movimento de sua mão direita. Em [Cheng, 2002] é proposto um sistema que utiliza potencial visual evocado (SSVEP) para controlar equipamentos como TV, vídeo e ar-condicionado, enquanto em [Muller, 2010], SSVEP é usado para controlar uma cadeira de rodas robotizada. Ainda dentre os projetos focados em deficientes físicos, podemos citar [Tanaka, 2005] e [Rebsamen, 2010], que também usam EEG para controlar ativamente uma cadeira de rodas, ou [Guger, 1999] em que o foco é o controle de uma prótese. Em [Ferreira, 2008], duas interfaces homem-máquina são desenvolvidas para controlar um robô, uma usando EEG e outra eletromiografia (EMG).

Embora apresentem inúmeras vantagens, a maioria das ICCs atuais são altamente suscetíveis aos estados emocionais vivenciados por seus usuários, já que as emoções

sinalizam o que é importante e com o que você se preocupa, ao mesmo tempo em que estão diretamente envolvidas em tomadas e na escolha de ações apropriadas [Picard, 1995].

No entanto, as ICCs possuem a vantagem do acesso direto à atividade cerebral, podendo fornecer informação significativa a respeito do estado emocional do usuário. Tal informação é usualmente utilizada de duas formas [Garcia, 2009]:

1) no conhecimento da influência do estado emocional nos padrões de atividade cerebral, permitindo à ICC adaptar seus algoritmos de reconhecimento de modo que a intenção do usuário ainda seja corretamente interpretada apesar das alterações de sinal induzidas pelo estado emocional do usuário;

2) na habilidade de reconhecer corretamente as emoções, para prover ao usuário uma maneira mais natural e intuitiva de controlar a ICC através de modulação afetiva.

Dentre algumas aplicações de ICCs baseadas no emocional humano, podem ser citadas: substituição de tabuleiros pictográficos para pessoas com deficiência, auxílio à navegação de cadeiras de rodas [Ferrez, 2008], avaliação de aspectos ergonômicos por estresse/cansaço, interação com robôs humanoides, entretenimento e jogos.

Além destes exemplos, em [Ashwin, 2002] foi desenvolvido um sistema que utiliza EEG para monitoramento de longo prazo de pacientes com epilepsia, possibilitando o monitoramento dos sinais fisiológicos pelos médicos. Ainda para monitoramento, em [Han Liu, 2013] é proposto um sistema para reconhecer o nível de atenção de alunos usando EEG e sensores móveis.

Os biosinais possuem informações importantes no que diz respeito à saúde do usuário, ao coletar informações inerentes ao indivíduo é possível coletar sinais sobre seu estado físico e mental. A partir disso, é possível adaptar o ambiente para responder da melhor forma aos dados obtidos, por exemplo, o controle de lâmpadas para verificar o seu impacto em pessoas

idosas, principalmente em seu ciclo de sono [Lee, 2008] ou o monitoramento da saúde de pessoas idosas ou com deficiências em um ambiente inteligente [Nakashima, 2009].

Contudo, a maioria dos sistemas propostos foca apenas na monitoração dos biosinais e não na sua análise em tempo real [Nam, 1998] e são ativamente controlados pelo usuário, sem a capacidade de feedback em laço fechado para a automação entre o ambiente e o usuário. Além disto, estes sistemas requerem treinamento do usuário para conseguir controlar o ambiente ou sistema robotizado. Ao contrário do projeto desenvolvido, que busca um método passivo, em que o usuário não tenta controlar a atividade cerebral ou ativamente o ambiente em que se encontra.

3.2 INTERPRETAÇÃO DE ESTRESSE E ATENÇÃO USANDO EEG

A capacidade do computador de reconhecer o nível de estresse humano é avaliado através do processamento e análise de eletroencefalograma (EEG) usando ferramentas computacionais de processamento de sinais, de extração de características e de reconhecimento de padrões. Assim, com vistas à aplicação em ICCs, o que se apresenta neste subcapítulo é o resultado de três técnicas de extração de características que são empregadas em trabalhos de reconhecimento de estados emocionais e são semelhantes às avaliadas neste trabalho: características estatísticas [Picard, 2001][Mampusti, 2011][Schaff, 2009][Yuen, 2011]; características baseadas em PSD (Power Spectral Density) [Lin, 2010]; e características baseadas em HOC (High Order Crossings) [Petrantonakis, 2009][Hadjileontiadis, 2010].

Os trabalhos baseados nas técnicas de PSD [Lin, 2010] e HOC ([Petrantonakis, 2009] e [Petrantonakis, 2011]) obtiveram melhores resultados do que os que empregaram características estatísticas ([Schaff, 2009] e [Manpusti, 2011]); no entanto, o trabalho [Chai,

2011] alcançou bons resultados considerando cinco estados emocionais e usando o perceptron multicamada. Na tabela a seguir pode-se ver um resumo dos resultados alcançados em trabalhos relacionados ao reconhecimento de estresse:

Tabela 1 - Resultados alcançados em trabalhos relacionados com reconhecimento de estresse

Trabalhos	Ano	Técnica	Emoções	Precisão
[Schaaff, 2009]	2009	Est	3	47,11
[Mampusti, 2011]	2011	Est	4	54,09
[Chai, 2011]	2011	Est	5	95,00
[Petrantonalis, 2009]	2009	HOC	6	83,30
[Petrantonalis, 2011]	2011	HOC	6	84,72
[Lin, 2010]	2010	PSD	5	82,29
[Houseini, 2010]	2010	Wav	2	79,20

É pertinente mencionar o resultado alcançado em [Houseini, 2010], que utiliza características baseadas em wavelets, pois alcançou a precisão de 79,2% na classificação dos mesmos estados emocionais avaliados neste trabalho (calma e estresse), mas usando um número maior de canais EEG e um processo de rotulação de dados baseado não apenas na autoavaliação de cada voluntário, mas também na análise qualitativa e quantitativa de sinais psicofisiológicos. Sendo assim, ainda é difícil comparar os resultados alcançados em trabalhos de reconhecimento de emoções, pois a quantidade de estados emocionais varia de um estudo para outro, além das condições distintas no desenvolvimento de pesquisas nesta área, como por exemplo, o protocolo de captura de sinais EEG ou o modo de estimular as emoções dos voluntários. No entanto, é importante salientar trabalhos cujos resultados são muito relevantes na área de computação afetiva.

Estudos para detectar o nível de atenção vêm sendo desenvolvidos já a algum tempo: [Kramer, 1991] avalia diversas pesquisas e sugere o uso de EEG como um método válido e objetivo de medição do nível de atenção e engajamento numa tarefa. O método convencional empregado para detectar atenção usando EEG geralmente envolve o cálculo das densidades

espectrais de potência das clássicas bandas de frequência como alfa, beta, theta e gama, e a relação entre elas [Berka, 2007]. Trabalhos tradicionais como [Prinzel, 2001], [Davidson, 1990] [Davidson, 1988], [Lubar, 1991], [Offenloch, 1990] e [Streitberg, 1987] avaliam a relação entre o nível de atenção e engajamento em tarefas de indivíduos com as ondas de EEG (alfa, beta e theta). Por exemplo, Davidson argumenta que as ondas alfa e beta estão negativamente correlacionadas com níveis de arousal ou excitação. Lubar descobriu que a relação entre as ondas beta e alfa podem discriminar crianças normais das que possuem distúrbio do déficit de atenção. Streitberg reporta que a diferente combinação destas ondas é capaz de distinguir entre estágios de vigília. Já Prinzel, em continuação do trabalho de [Pope, 1995] vai além e testa diversas combinações destas ondas e conclui que a combinação de beta/(alfa+theta) gera o índice que melhor se relaciona ao nível de atenção. Trabalhos posteriores, como [Gevins, 2005], [Wilson, 2005] ou [Han Liu, 2013] também relatam a mesma relação entre ondas e o nível de atenção.

3.3 CONTROLE DE AMBIENTES INTELIGENTES

Muitos sistemas de controle de ambientes já foram propostos e desenvolvidos; contudo, conforme apontado por [Lin, Chin-Teng, 2010], a maioria destes sistemas utilizam sinais de controle como reconhecimento de voz e sensores de temperatura. Em [Yerrapragada, 1993] é apresentada uma casa inteligente com controle dos equipamentos através de técnicas de reconhecimento de voz. Em [Corcoran, 2002] um sistema universal do tipo plug and play é proposto para prover serviços de equipamentos ligados à rede doméstica para usuários através de seus telefones celulares.

Nesta mesma linha, [Wei Lun Ng, 2011] usa um sistema de gestão, localizado num celular para controlar vários componentes do ambiente e [Cook, 2006] sugere o projeto de

uma casa inteligente que se auto-regula em resposta ao horário e às mudanças climáticas. Nos trabalhos de [AIRE, 2004] e [Fox, 2000] são desenvolvidos escritórios e salas de conferências que integram equipamentos heterogêneos e a utilização por múltiplos usuários visando a melhor utilização de ambientes colaborativos. Estes projetos, porém, utilizam cenários pré-configurados dos equipamentos disponíveis conforme horário e leitura dos sensores, como em uma rotina; não sendo possível se adaptar às diferentes necessidades do usuário no decorrer do dia, conforme a atividade do mesmo, ou seja, conforme o seu estado atual.

Poucos estudos focam no controle do ambiente utilizando diretamente o estado do usuário. Além disto, muitos dos sistemas citados anteriormente, não funcionarão com indivíduos com deficiência de fala, visão, motora ou mental, por exemplo.

Trabalhos relativos à automação predial e residencial usualmente se baseiam em variáveis como temperatura e luminosidade para controle dos ambientes, mesmo que normalmente os objetivos principais deste sistema seja um maior conforto – no caso da automação residencial – e num aumento da produtividade – no caso de automação predial, em especial prédios com escritórios [Greenwell, 2011] [Araujo, 2005] [Perozzo, 2007] [Marques, 2014]. Neste trabalho, usamos diretamente o estado do usuário como variável para controle do ambiente e aumento do conforto e/ou produtividade do usuário.

3.4 USO DE ALGORITMOS GENÉTICOS EM SISTEMAS DE CONTROLE

Conforme apresentado na seção 2.2, algoritmos genéticos podem ser aplicados em domínios em que haja o conhecimento insuficiente sobre o sistema e/ou alta complexidade. Podem encontrar as melhores soluções entre o espaço de busca, sendo muito eficazes para encontrar rapidamente uma solução razoável para um problema complexo [Malhotra, 2011],

como no caso tratado neste trabalho, em que não se sabe como e quais equipamentos do ambiente, ou configuração do ambiente, terá qual impacto no estado no usuário.

A utilidade dos algoritmos heurísticos como método de pesquisa para diversos problemas de otimização foi examinado por [Jang, 1998]. Algoritmos imunológicos, algoritmos genéticos e algoritmos evolutivos foram comparados com diversos problemas de otimização e os resultados revelam um desempenho superior dos algoritmos genéticos.

Em [Raymer, 2000], algoritmos genéticos foram aplicados em reconhecimento de padrões e foi sugerida uma nova abordagem para extração de características, na qual a seleção de recursos e a extração de características foram feitas simultaneamente. O algoritmo genético otimiza um vetor de peso de características usado para escalar individualmente as funcionalidades dentro do vetor de padrões original. O problema de encontrar soluções robustas e flexíveis para problemas de escalonamento foi sugerido por [Jensen, 2003].

Uma antena veicular utilizando sistema de posicionamento global (GPS) foi projetada por [Altshuler, 2000] usando algoritmos genéticos. O funcionamento da antena foi simulado e, em seguida, o produto foi fabricado e testado e parece superar o projeto convencional.

No trabalho de [Dimeo, 1995], uma nova abordagem para sistema de controle de turbina de caldeira usando algoritmos genéticos é sugerida e mostram um controle ótimo.

Infere-se, a partir da revisão da literatura acima, que algoritmos genéticos são aplicados com sucesso em muitos problemas de otimização em sistemas de controle, usando operadores genéticos como seleção, cruzamento elitista e mutação.

4 VISÃO GERAL DO SISTEMA

O tema abordado por este estudo está diretamente relacionado ao contexto de tecnologias assistivas, que visam auxiliar o indivíduo nas suas tarefas diárias, visando o aumento de sua produtividade, auxiliando em terapias ou para aumentar a autonomia de usuários com alguma debilidade. Neste estudo busca-se um método passivo, i.e., em que o usuário não tenta controlar a sua atividade cerebral [George, 2010]; para adaptar um sistema inteligente à sua necessidade particular visando a realização de uma tarefa proposta. Por exemplo, adaptando o ambiente de fábrica para otimizar a atenção do trabalhador; adaptar o sistema para manter o nível de atenção continuada de seu piloto, como carros, aviões ou torres de controle; adaptar material de cursos online ou automatizados para manter o engajamento dos alunos; adaptar um sistema para controlar o nível de estresse de sujeitos com autismo para auxílio terapêutico; dentre outros.

O estudo em questão está diretamente ligado ao conceito de sistemas inteligentes, no contexto em que pessoas e equipamentos devem interagir de forma transparente, sem que o equipamento ou sistema se torne mais um fator dispersor, mas ao contrário, realmente auxilie a pessoa na tarefa proposta.

Com o intuito de reduzir a dispersão que o sistema causa e tornar esta interação mais transparente, será proposta uma arquitetura para controlar sistemas inteligentes de forma automatizada, utilizando-se da Computação Afetiva, i.e., computação que se relaciona com, surge das, ou influencia nas emoções [Picard, 1997]; que estuda e desenvolve sistemas capazes de reconhecer, interpretar, processar e até simular emoções humanas. Em paralelo, avanços nas áreas de eletrônica e sistemas de automação tornaram possível o surgimento dos chamados Sistemas Inteligentes, dentro do conceito de Ambientes Inteligentes e da Computação Ubíqua vislumbrada por Mark Weiser em [Weiser, 1999], em que sistemas dotados de sensores, controladores, interfaces homem máquina e atuadores são capazes de

interagir e se adaptar ao usuário. A integração destes conceitos permite o desenvolvimento de um sistema com soluções automatizadas para usuários, inclusive com alguma debilidade ou dificuldade para execução de determinadas tarefas. Um dos desafios está no canal de comunicação entre usuário e ambiente, dentro do conjunto de possíveis interfaces, pesquisas levam à utilização de um meio de controle mais direto ao usuário conhecido como interfaces cérebro-computador (BCI) [Wolpaw, 2012][Ruscher, 2011][Lu, 2010][Allison, 2010][Nijholt, 2008]. Esta proposta aborda uma pesquisa sobre a utilização de interface cérebro-computador para uso aplicado em sistemas de automação.

Porém, este canal de comunicação costuma estar longe de ser pervasivo: um capacete cheio de fios que é bastante desconfortável de usar e que requer muito esforço, foco e concentração do usuário.

Para que se possa desenvolver Interfaces Cérebro Computador mais pervasivas, dois principais problemas devem ser endereçados:

- a) O desconfortável hardware: pesquisar meios de detecção e interpretação de sinais de EEG que usem menos eletrodos, para que a construção de capacetes de EEG menores e mais confortáveis seja possível.
- b) O esforço requerido por parte do usuário: pesquisar maneiras para fazer o uso desta interface requerer menos treinamento, atenção e foco por parte do usuário.

Então, para reduzir a distração que esta interface pode causar e para tornar a interação mais transparente, propomos neste projeto um sistema de controle baseado em processos psicológicos básicos. Tal controle pode gerenciar sistemas inteligentes de maneira automática, baseada na Computação Afetiva.

A visão geral do sistema pode ser vista na figura a seguir:

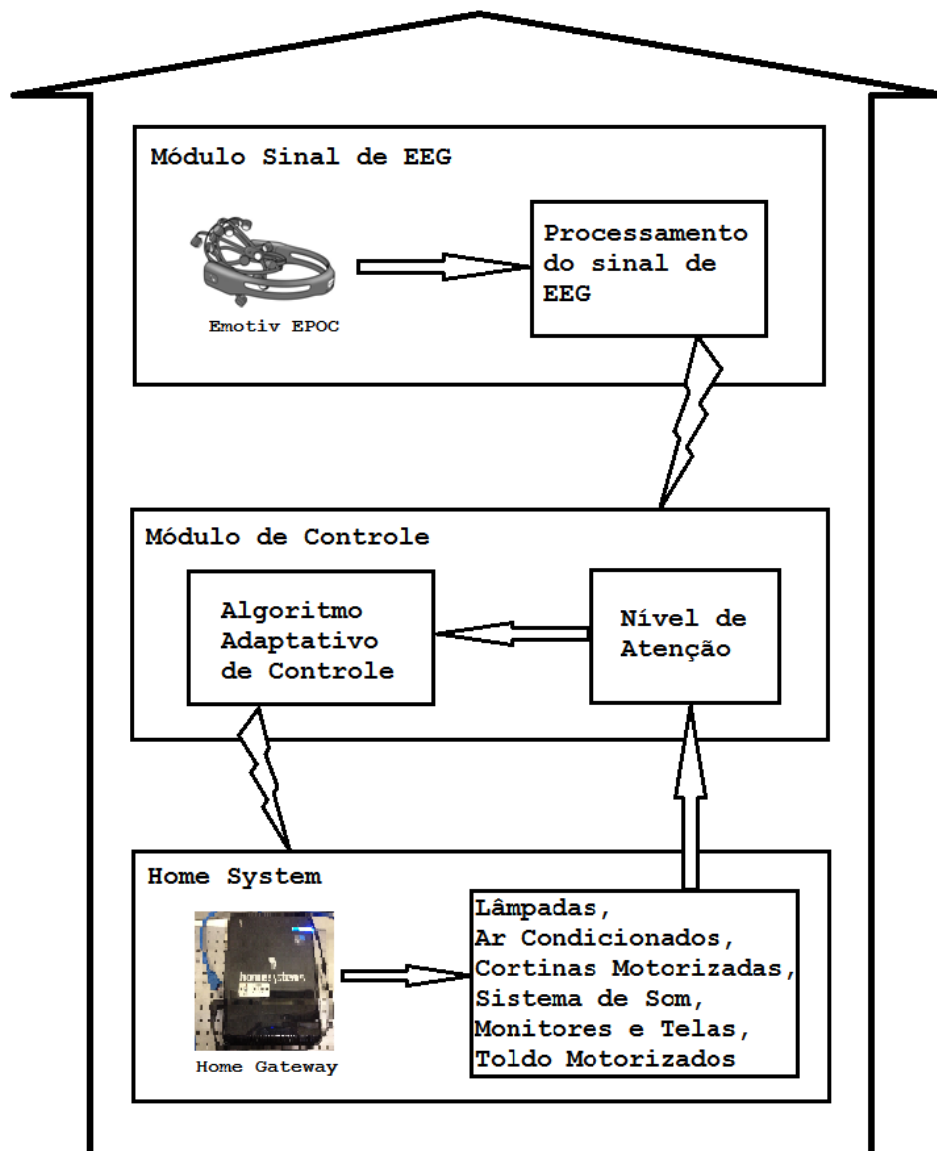


Figura 2 – Visão Geral do Sistema. Fonte: elaborado pela autora.

Na Figura 2 temos a visão geral do sistema, em que o biosinal é capturado do usuário e interpretado em níveis de atenção e estresse. Posteriormente, o sistema vai analisar estes níveis e decidir qual a melhor configuração do ambiente para otimizar estes níveis, i. e., aumentar o nível de atenção ou baixar o nível de estresse. Esta configuração escolhida será então enviada para o sistema de automação predial-residencial que atuará nos equipamentos disponíveis em modo de comandos, como por exemplo, ligar a lâmpadas ou mudar a

temperatura do ar condicionado. Estas ações nos equipamentos mudarão as características do ambiente em que o usuário está inserido, como iluminação, ruído e temperatura; influenciando no estado deste e, conseqüentemente, mudando o seu biosinal e níveis de estresse e atenção. Fechando assim o laço de controle do sistema.

5 PROPOSTA DE ARQUITETURA DO SISTEMA

Com o intuito de reduzir a dispersão que o sistema causa e tornar a interação entre usuário e sistema inteligente mais transparente, será proposta uma arquitetura para controlar sistemas inteligentes de forma automatizada, utilizando-se da Computação Afetiva, i.e., computação que se relaciona com, surge das, ou influencia nas emoções [Picard, 1997]; que estuda e desenvolve sistemas capazes de reconhecer, interpretar, processar e até simular emoções humanas.

Este projeto usa o estado emocional obtido através do processamento e análise dos sinais de eletroencefalograma para controlar e automaticamente adaptar um ambiente inteligente de forma transparente ao usuário.

A arquitetura do sistema pode ser visualizada na figura a seguir e é inspirada no trabalho de [Catarci, 2008], com o diferencial de utilizar EEG para tornar o sistema acessível através de interface cérebro computador. Como podemos ver na figura, a arquitetura é dividida em três camadas: Camada de Usuário, Camada de Composição e Camada Pervasiva.

A camada de Usuário é, na verdade, transparente a este e deve captar seus sinais de EEG que serão transferidos para a camada de Composição onde serão tratados e interpretados conforme o processo psicológico básico de interesse, no texto tratado informalmente como “emoção” ou “estado emocional”. Este estado emocional definirá a configuração do ambiente conforme a base de dados de dispositivos e seus respectivos estados possíveis (ligado, desligado ou ligado em um estado específico). Através da Camada Pervasiva, o ambiente então ajustará sua iluminação, nível de ruído, temperatura e até mesmo canais de televisão ou rádio a fim de melhorar o estado emocional em questão do usuário.

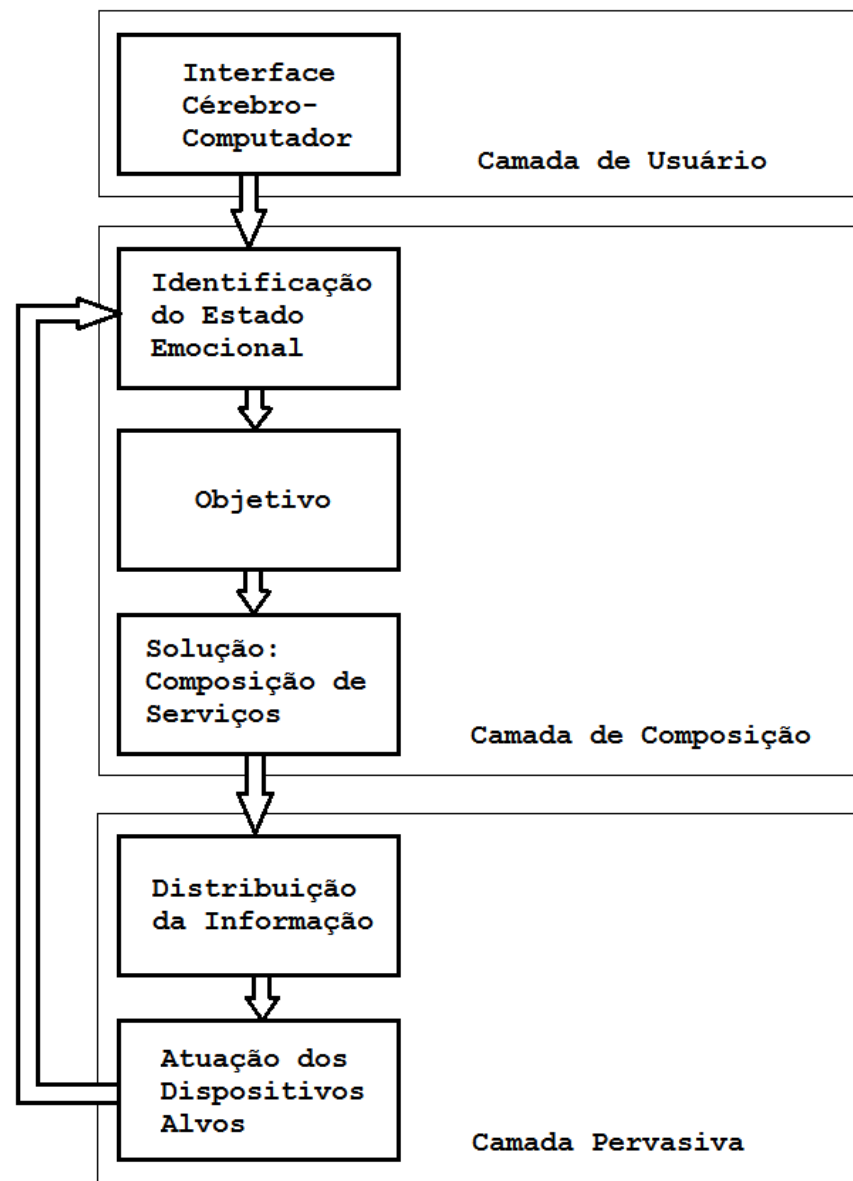


Figura 3 – Arquitetura Proposta. Fonte: elaborado pela autora.

A seguir serão detalhadas as Camadas de Usuário, de Composição e Pervasiva, respectivamente.

5.1 CAMADA DE USUÁRIO

As emoções têm um papel essencial em muitos aspectos do nosso dia-a-dia, incluindo tomadas de decisão, percepções, aprendizados, produtividade, pensamento racional e ações. As primeiras abordagens para reconhecimento de emoções são baseadas em texto, voz, expressão facial e gestos; técnicas bastante estudadas nas últimas décadas [Anderson, 2006]. No entanto, estes métodos não são confiáveis para detectar emoção em casos em que elas ocorrem sem correspondentes expressões faciais ou alteração na voz ou movimentos do corpo; como para pessoas com transtorno do espectro autista, quando a densidade da emoção não é muito alta e especialmente quando as pessoas querem esconder seus sentimentos, que podem ser facilmente dissimulados [Pham, 2012].

Para superar estas desvantagens, muitos estudos se voltaram para a técnicas de interpretação multi-sinal, como frequência cardíaca, condutividade da pele e respiração [Anttonen, 2005][Leng, 2007]. A vantagem é que estas modalidades dificilmente podem ser dissimuladas por controle voluntário. Anttonen e Surakka descobriram que a frequência cardíaca desacelera em resposta a estímulos emocionais, especialmente os negativos [Anttonen, 2005]. Leng verificou que estados de felicidade, como momentos de diversão, produzem uma frequência cardíaca com média e desvio padrão maiores do que estados de medo [Leng, 2007]. No entanto, alguns autores, como Pham apontam que os resultados obtidos com classificação de emoções usando estas técnicas não têm um grau elevado de acertos principalmente para emoções leves como nível de atenção e também não incluem problemas crônicos como estresse.

A utilização do eletroencefalograma (EEG) para detecção de emoção inclui como vantagens [Pham, 2012]:

- 1) atividades cerebrais têm informação direta sobre a emoção,

2) sinais de EEG podem ser medidos a qualquer momento e não são dependentes de outras atividades como falar ou fazer expressões faciais,

3) é possível detectar variações emocionais mais leves se comparadas com as técnicas descritas anteriormente,

4) é possível detectar emoções crônicas ou de longo prazo, como nível de estresse.

Atualmente já é possível obter dispositivos de aquisição de sinais EEG com preços e interfaces acessíveis ao usuário final.

As marcas que até a presente pesquisa lideram o mercado de hardware para BCI utilizando sinais de EEG a baixo custo são *Emotiv* [Emotiv, 2014] e *NeuroSky* [NeuroSky, 2014], sendo que a última também disponibiliza o seu hardware para empresas parceiras desenvolverem seus aplicativos. Sendo que o *Emotiv* tem 14 eletrodos, em contrapartida ao *NeuroSky*, com apenas 1. Isto faz com que o *Emotiv*, embora um pouco mais caro – em torno de U\$300,00, enquanto que as aplicações envolvendo o *NeuroSky* ficam entre U\$50,00 e U\$200,00 -, seja a opção que permite maior flexibilidade nas aplicações, podendo até mesmo ser utilizado em diversas pesquisas com um alto nível de fidelidade de sinais de EEG.

A interação entre o usuário e o resto do sistema se dará através da ICC Emotiv, um capacete com 14 eletrodos e a correspondente análise deste sinal de EEG bruto em estados emocionais, como nível de atenção e estresse.

Emotiv Systems é uma empresa australiana fundada em 2003 que desenvolve interfaces cérebro-computador baseadas em EEG. Um dos seus principais produtos é o Emotiv EPOC, capacete sem-fio de aquisição de sinal de EEG que possui 14 canais (AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4.), mais as referências Common Mode Sense (CMS, eletrodo ativo) e Driven Right leg (DRL, eletrodo passivo), localizados nas

regiões P3 e P4, respectivamente, indicados na figura a seguir. Essas referências oferecem posicionamento otimizado para resoluções espaciais precisas.




Figura 4 - Coordenadas dos eletrodos, de acordo com o Sistema Internacional 10-20. [Emotiv, 2012]

O método de amostragem é sequencial, utilizando conversor analógico digital (ADC). A conversão envolve quantização da entrada, então necessariamente introduz uma quantidade de erro. O ADC faz a conversão coletando amostras da entrada periodicamente. O resultado é uma sequência de valores digitais convertidos do tempo e amplitude contínuos para tempo e amplitude discretas.

A taxa de amostragem é de 128 Amostras por Segundo, 2048 Hz interno, com resolução de 14 bits, sendo 1 Least Significant Bit (LSB) = $0.51 \mu\text{V}$ (16 bit ADC, 2 bits descartados por ruído instrumental). Largura de banda de 0.2 – 45 Hz, utilizando rejeita-faixa digital a 50 Hz e 60 Hz. São utilizados filtros digitais do tipo Sinc construídos na ordem 5.

A variação dinâmica (referido a entrada) é de $8400\mu\text{V}$ (pp) e o modo de acoplamento é em AC. O método de conectividade com o computador é através de uma rede de comunicação sem fio, usando um protocolo de comunicação proprietário do fabricante. O equipamento é

alimentado com bateria de polímeros de Lítio (LiPoly - Lithium Polymer) com autonomia de 12 horas.

O capacete interpreta entradas tanto de sinais elétricos produzidos pelo cérebro, como sinais produzidos pelas células musculares (eletromiografia), bem como pela rotação da cabeça, através de um giroscópio no capacete, que gera informações posicionais para, por exemplo, cursores ou controle de câmera [Emotiv, 2014].

5.2 CAMADA DE COMPOSIÇÃO

O objetivo desta camada é o de ajustar o ambiente conforme o nível emocional do usuário e os dispositivos disponíveis: por exemplo, se o usuário está estressado, o objetivo do ambiente deve ser o de acalmá-lo e para tal, por exemplo, a iluminação deve ser diminuída, a temperatura aumentada ou o volume de uma música específica deve ser aumentada. Esta configuração do ambiente, porém, muda de usuário para usuário e também de momento para momento para o mesmo usuário. Por isto a necessidade de um algoritmo adaptativo: nem sempre a mesma configuração de ambiente causará o mesmo efeito no mesmo usuário e, principalmente, em usuários diferentes.

A partir dos níveis de estresse, atenção ou engajamento lidos, são definidos novos cenários para o sistema de automação predial-residencial, visando a mudança de variáveis do ambiente como luminosidade, temperatura, ruído e qualquer equipamento que esteja disponível na automatização, de modo a reduzir o estresse ou aumentar a atenção ou engajamento das pessoas presentes no ambiente. Para solucionar tal problema, a estratégia de controle adotada utiliza algoritmos genéticos (vide Ítem 2.2).

A abordagem evolutiva é especialmente bem sucedida em problemas que são difíceis de formalizar matematicamente e, que, conseqüentemente, não são fáceis de analisar. Isto inclui sistemas altamente não-lineares, estocásticos, e que se tem pouco conhecimento prévio. Problemas deste tipo tendem a ser difíceis de resolver satisfatoriamente utilizando métodos convencionais. A falta de dependência dos algoritmos genéticos em heurísticas específicas de domínio torna-os fortes candidatos para aplicação nesta área, pois muito pouca informação prévia sobre o problema é necessária [Fleming, 2001].

O problema aqui proposto contém uma mistura de formatos variáveis de decisão, que podem ser problemáticos para técnicas de otimização convencionais que requerem variáveis de um único tipo matemático ou unidade científica. Como o algoritmo genético opera com a codificação do conjunto de parâmetros, diversos tipos de variáveis podem ser representadas e manipuladas dentro de uma única solução. Por exemplo, um vetor de decisão [23 graus Celsius, 1, 0, 1, 0, 30 decibéis, -1, 0.56], que significaria a temperatura da sala, diferentes configurações de ligado/desligados dos quatro circuitos de iluminação, o volume do sistema de som, a inversão do comando da cortina e o correspondente nível de atenção do usuário, respectivamente, não representa um problema intrínseco ao algoritmo.

O algoritmo genético é um método de busca de otimização robusto capaz de lidar bem com problemas que exibem propriedades como multimodalidade (diversos aparelhos com efeitos muito heterogêneos, como ruído, temperatura e iluminação), descontinuidade (talvez o rádio e a televisão ligados separadamente aumente a atenção do indivíduo, mas os dois ligados juntos não), variância no tempo (o estado do indivíduo muda com o tempo, mesmo sem interferência do ambiente), aleatoriedade (não se sabe como cada aparelho influenciará no indivíduo, assim como esta influência pode ser diferente conforme o tempo ou a atividade) e ruído (o estado do indivíduo pode variar por motivos não relacionados ao sistema, como mudanças de humor, causando ruído no controle do sistema). Cada uma destas propriedades

pode causar dificuldades para o uso dos tradicionais métodos computacionais de pesquisa com, além de inviabilizarem uma solução analítica. Além disto, uma pesquisa genética é direta e dirigida, e, portanto, tem muito maior eficiência do que uma pesquisa de solução totalmente aleatória.

5.2.1 Algoritmo Desenvolvido

Na Camada de Composição foi desenvolvido um algoritmo para calcular a melhor solução de configuração dos equipamentos da sala de maneira a aumentar o nível de Engajamento do usuário, captado através do capacete Emotiv na Camada de Usuário.

O algoritmo foi implementado em Linguagem C/C++ utilizando-se da teoria de algoritmos genéticos. Na Figura 5, fluxograma simplificado do algoritmo implementado.

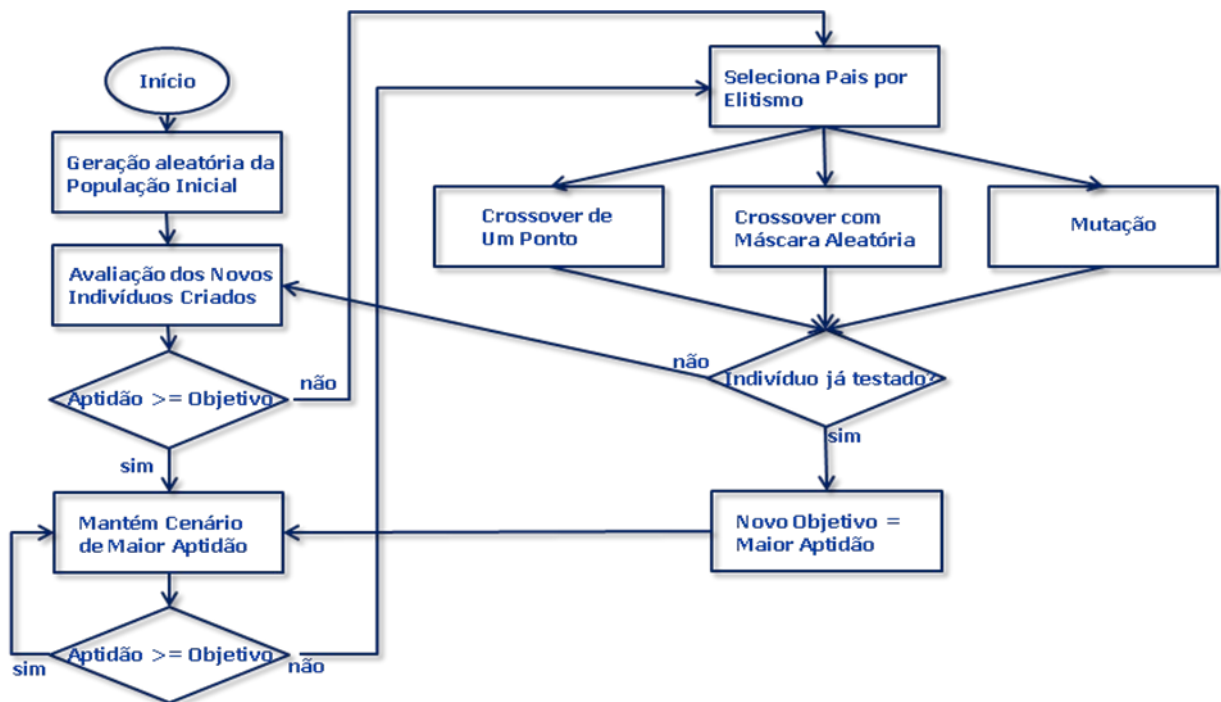


Figura 5 – Fluxograma simplificado do algoritmo implementado em linguagem C/C++. Fonte: elaborado pela autora.

Primeiramente é gerada uma população aleatória inicial, que é implementada no ambiente e tem seu nível de aptidão, no caso o sinal de Engajamento do Emotiv, avaliado. Se o nível de Aptidão for menor do que o objetivo primeiramente setado, novos pais serão selecionados por Elitismo, se for maior, mantém o cenário, ou configuração de ambiente, até que a aptidão seja menor do que o objetivo setado. Os novos pais selecionados por Elitismo passarão por uma combinação de Crossover de Um Ponto, Crossover com Máscara Aleatória e Mutação para criação de novos indivíduos filhos ainda não testados que contenha características dos pais, que então serão testado no passo “Avaliação dos Novos Indivíduos Criados”, repetindo o processo. Se caso não houverem mais indivíduos possíveis a serem testados, i.e., toda a população já foi testada e não foi possível atingir o objetivo setado, o valor do objetivo é atualizado com o maior valor de aptidão encontrado durante todo o teste.

Para testar o funcionamento do sistema em si, foram analisados os arquivo de *log* criados durante a execução do sistema. Utilizando um arquivo de *log* é possível identificar em que momento cada operador genético foi aplicado e assim verificar se o resultado equivale ao esperado. O resultado do teste feito com o sistema pode ser visto no Gráfico 1, em que as informações de engajamento estão representadas em azul, e sua média ponderada, em círculos vermelhos:




Gráfico 1 - Resultado representativo do teste do sistema

Para este teste foram utilizados oito canais/bits/genes, representando oito conjuntos de equipamentos disponíveis no ambiente, e cada cadeia de bits forma um cromossomo/estado. Utiliza-se mais um bit para representar a aptidão, ou, neste caso, nível de engajamento, que iniciará em -1 para representar que o estado associado ainda não foi avaliado.

Inicia-se por “Geração Aleatória da População Inicial” indicado do fluxograma da Figura 5, e cria-se uma geração aleatória inicial. Foram criado três cenários ou indivíduos com valores de genes aleatório de 0 ou 1 e aptidão -1:

1º) 0 1 0 0 1 0 1 0, -1;

2º) 0 1 0 0 1 0 0 0, -1;

3º) 0 0 0 0 0 0 0 0, -1;

Em “Avaliação dos Novos Indivíduos Criados”, a sala assume cada um dos estados criados anteriormente e é feita a leitura do valor de aptidão. O 1º estado teve aptidão de 0.699961, o segundo estado de 0.713178, e o terceiro estado de 0.67399.

Assim que todos os indivíduos foram avaliados, passamos para o estado “Aptidão \geq Objetivo”, onde é verificado se alguma das aptidões encontradas é maior ou igual à aptidão objetivo setada, que, no caso deste teste, foi de 0.9. Como este valor não foi alcançado, a saída do estado é “não” e novos pais serão selecionados.

Em “Seleciona Pais por Elitismo” é aplicada uma seleção elitista para escolher quais serão os pais que participarão das técnicas de Crossover e Mutação. A geração ordenada atual é a seguinte:

1º) 0 1 0 0 1 0 0 0, 0.713178

2º) 0 1 0 0 1 0 1 0, 0.699961

3º) 0 0 0 0 0 0 0 0, 0.67399

Nesse caso a seleção elitista não excluiu nenhum cenário pois o número de indivíduos da geração é igual ao número de pais necessários para as técnicas de Crossover e Mutação. Caso houvessem quatro cenários, o pior deles seria descartado.

No estado “Crossover de Um Ponto” do fluxograma, o primeiro indivíduo da elite fará crossover de um ponto com o segundo indivíduo da elite, criando mais dois indivíduos. No estado “Crossover com Máscara Aleatória”, o primeiro indivíduo fará também um crossover de Máscara Aleatória com o terceiro indivíduo, criando mais um indivíduo. A cada crossover, cada bit possui a chance de alterar seu valor por Mutação. Cenários novos possuem aptidão igual a -1 para indicar que não foram avaliados. A geração tem agora os seguintes cenários ordenados:

- 1) 0 1 0 0 1 0 0 0, 0.713178
- 2) 0 1 0 0 1 0 1 0, 0.699961
- 3) 0 0 0 0 0 0 0 0, 0.67399
- 4) 1 0 0 0 0 0 0 0, -1
- 5) 1 1 0 0 1 0 1 0, -1
- 6) 1 1 0 0 1 0 0 0, -1

Em “Avaliação dos Novos Indivíduos Criados”, os cenários não avaliados serão testados. De acordo com o arquivo de *log*, foram encontrados os valores 0.643085, 0.616878, e 0.723414 de forma que agora temos:

- 1) 1 1 0 0 1 0 0 0, 0.723414
- 2) 0 1 0 0 1 0 0 0, 0.713178
- 3) 0 1 0 0 1 0 1 0, 0.699961
- 4) 0 0 0 0 0 0 0 0, 0.67399
- 5) 1 0 0 0 0 0 0 0, 0.643085
- 6) 1 1 0 0 1 0 1 0, 0.616878

Em “Seleciona Pais por Elitismo”, uma nova geração é criada em que somente os 3 melhores indivíduos passarão para a próxima geração, na qual se tornarão os pais utilizados para o novo *crossover*.

Chegando em “Aptidão \geq Objetivo” é verificado se a aptidão de algum dos cenários é maior ou igual à aptidão ideal. Caso seja, é mantido o cenário de maior aptidão até que esta premissa não seja mais verdadeira. Caso não seja, voltamos ao estado “Seleciona Pais por Elitismo” do fluxograma. Com os dados do log, verificamos que este é o fluxo que o programa executou até o momento do teste.

O fluxo descrito até aqui representa, no Gráfico 1, o ocorrido para definir as configurações dos cenários 1 ao 6 e o respectivo nível de engajamento do usuário. De acordo com os dados apresentados no arquivo de *log*, a próxima saída de “Aptidão \geq Objetivo” será “sim”, pois atingimos uma aptidão maior que a aptidão objetivo, igual a 0.9, como visto na ordem dos indivíduos e suas respectivos aptidões, mostrado a seguir:

- 1) 1 1 0 0 0 0 0 0, 0.906871
- 2) 0 1 0 0 0 0 0 0, 0.844992
- 3) 0 0 0 1 0 0 1 0, 0.81851
- 4) 1 1 0 0 1 0 0 0, 0.723414
- 5) 0 1 0 0 1 0 0 0, 0.713178
- 6) 0 1 0 0 1 0 1 0, 0.699961

O estado “Mantém Cenário de Maior Aptidão” do fluxograma é, então, alcançado, e a sala assume o estado com maior aptidão, i.e., o primeiro indivíduo da lista, 1 1 0 0 0 0 0 0, 0.906871. Em “Aptidão \geq Objetivo”, continuamos a avaliar a aptidão para garantir que o estado da sala ainda tenha contribuições positivas no estado do usuário. A sala não mudará de estado caso a aptidão continue elevada.

Caso a saída deste estado seja “não”, ou seja, o estado do usuário baixou para um nível menor do que o objetivo, voltamos ao estado do fluxograma “Seleciona Pais por Elitismo”. Podemos observar que isso ocorre no cenário 10 do Gráfico 1 em que o ciclo se repete a partir deste estado.

Podemos ver pela análise do Gráfico 1 que o sistema, para as oito variáveis de ambiente testadas se adaptou em torno de 2 a 4 cenários, para conseguir elevar novamente a aptidão ou Engajamento do usuário.

Para fins de exemplificação, apenas foi mostrada aqui a análise de um dos arquivos, mas todos os testes feitos com o sistema foram analisados e tiveram resultados semelhantes, concluindo que o algoritmo genético aqui proposto tem bom desempenho para este tipo de problema e pode ser utilizado de maneira satisfatória para controle de ambientes inteligentes usando biosinais em laço fechado.

5.3 CAMADA PERVASIVA

A camada pervasiva é responsável pela distribuição das ações definidas na camada de composição, dentre os equipamentos disponíveis no sistema automatizado. Nesta etapa há a distribuição dos comandos para os dispositivos disponíveis e sua atuação conforme o objetivo do sistema, como calculado na camada anterior e distribuídos para comunicação com o sistema de automação residencial da empresa gaúcha Home Systems. Na podemos ver o fluxograma simplificado do algoritmo da Camada Pervasiva implementado em Linguagem C/C++.

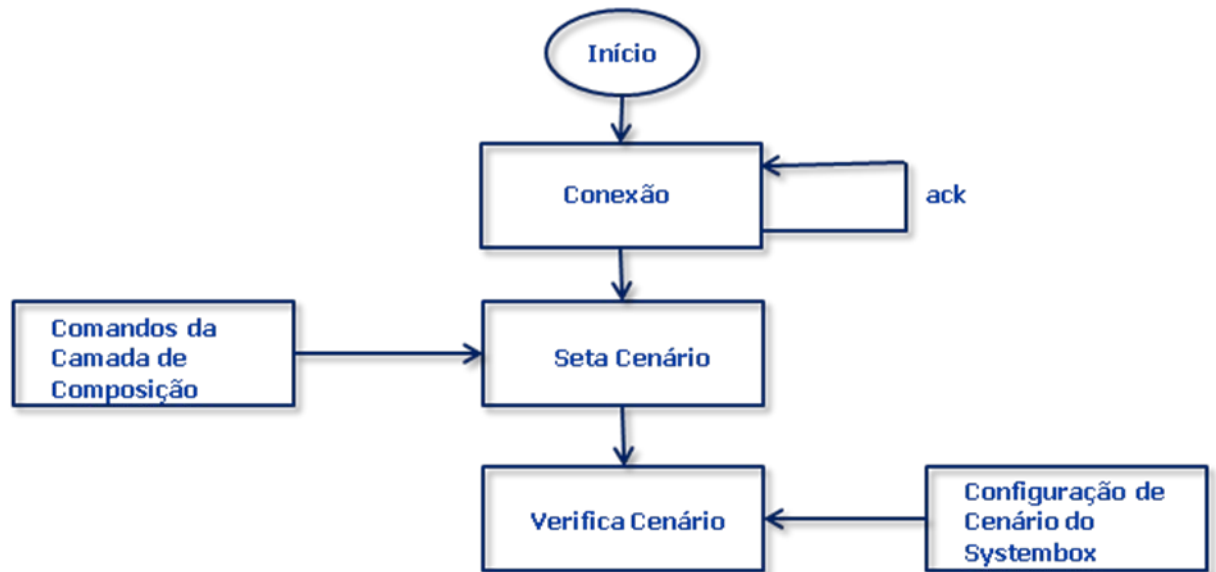


Figura 6 – Algoritmo da Camada Pervasiva. Fonte: elaborado pela autora.

Nesta automação, há uma unidade de controle central chamada Systembox (vide Fig. 10) que é, basicamente, um computador com sistema operacional Linux, responsável por controlar a Rede da HomeSystems (HSNET protocolo proprietário que trabalha na camada física RS-485) e atuar nos diversos circuitos disponíveis, como iluminação, sistemas de ar condicionado, sistemas de entretenimento, dentre outros que estejam disponíveis na rede.

Para comunicação com o Systembox é utilizado um protocolo do tipo TCP/IP em que é necessário estabelecer comunicação através do envio de senha criptografada, e manter esta comunicação com o envio de alguma mensagem ou *acknowledge*, no tempo máximo de dez segundos ou a conexão se perderá e terá que ser reiniciada com novo envio de usuário e senha para se conectar ao Systembox.



Figura 7 – Systembox. Fonte: elaborado pela autora.

As mensagens seguem o padrão pergunta/resposta com pacotes em formato ASCII. As mensagens do tipo pergunta podem ser de dois tipos, mas a mensagem do tipo resposta sempre terá o mesmo padrão, expostos a seguir:

- a) Pergunta: As mensagens enviadas ao Systembox podem ser de dois tipos:
 - a. Para descobrir o valor de cada equipamento, representado por *unit*:
 $5G*unit1*unit2*...*unitn**'\0'$
 - b. Para envia valor (*val*) a ser setado no equipamento (*unit*): $5S*unit1-val1*unit2-val2*...*unitn-valn**'\0'$
- b) Resposta: O Systembox responde à mensagem pergunta sempre no formato: $'\0'*unit1-val1*unit2-val2*...*unitn-valn**'\0'$

6 VALIDAÇÃO DA ARQUITETURA PROPOSTA

Para implementação da arquitetura proposta foi utilizado o *Emotiv*, capacete de EEG equipado com 14 eletrodos que detectam sinais do cérebro. Com esse capacete, é possível extrair dados e identificar padrões neurológicos que variam conforme a interação do usuário com o ambiente. Através de técnicas de processamento de sinais, extraímos métricas que representam a percepção do usuário em relação a certas sensações nas quais o ambiente tem influência, como estresse ou conforto. Essa métrica será denominada a partir daqui, para utilizar o mesmo termo utilizado na teoria de algoritmos genéticos, aptidão.

O ambiente utilizado foi uma sala automatizada que possui: seis circuitos de iluminação, um toldo, cinco cortinas, dois condicionadores de ar, um sistema de som e cinco monitores. Uma interface foi desenvolvida para permitir que o controle da sala seja feito pelas informações resultantes do algoritmo genético criado.

Através da leitura e interpretação do EEG recebido pelo capacete, temos como saída uma valor que representa uma emoção do usuário em relação ao ambiente, ou seja, uma aptidão. Inicialmente, temos o objetivo de encontrar o estado da sala no qual o usuário possui melhor nível de aptidão (maior atenção ou menor stress). Para isso utilizamos um algoritmo genético para, através de inúmeras iterações, encontrar o melhor estado da sala.

6.1 PROCESSAMENTO DO SINAL DE EEG

O sinal de EEG foi analisado em três tipos de emoção: estresse, atenção e engajamento. Sendo que foram avaliadas três técnicas para interpretação do nível de estresse, enquanto que o nível de atenção foi avaliado levando-se em conta a relação de ondas alfa, beta, gamma e theta; e o engajamento é o sinal processado pelo próprio Emotiv, denominado pela empresa de “Engagement”.

6.1.1 Estresse

Para processamento e análise dos sinais de EEG foi feito o estudo de três técnicas de extração de características que são empregadas em trabalhos de reconhecimento de estados emocionais: características estatísticas [Picard, 2001][Mampusti, 2011][Schaaff, 2009][Tong, 2011]; características baseadas em PSD (Power Spectral Density) [Lin, 2010]; e características baseadas em HOC (High Order Crossings) [Petrantonakis, 2009][Hadjileontiadis, 2010].

A avaliação se realizou via classificação dos estados emocionais de calma e estresse, definidas como em [Hosseini, 2010], usando o classificador baseado em K-NN (K-Nearest Neighbours) em modo off-line usando sinais EEG registrados nas posições Fp1, Fp2, F3, e F4 (Sistema internacional 10-20) da base de dados DEAP (Database for Emotion Analysis using Physiological Signals) [Sander, 2011]. Tendo em vista o incômodo gerado para os usuários dos equipamentos de EEG, a escolha da posição dos eletrodos foi feita visando a utilização de um pequeno número de eletrodos e baseada nos trabalhos de reconhecimento de emoções [Petrantonakis, 2009][Hadjileontiadis, 2010][Petrantonakis, 2011] em vista a permitir a utilização de um capacete de aquisição de EEG pequeno e cômodo.

Como resultado desta classificação, foram produzidos os artigos [Cotrina CBA, 2012], [Cotrina CBEB 2012], [Cotrina RMMG, 2012], [Cotrina CBA, 2014] e [Cotrina EMBC, 2014], em que se concluiu que é possível classificar os estado de calma e estresse utilizando-se apenas quatro eletrodos nas posições Fp1, Fp2, F3, e F4 e que as técnicas baseadas em PSD e HOC apresentam os melhores resultados, com uma taxa de acertos de $70,1\% \pm 0,45\%$ e $69,49\% \pm 0,53\%$ respectivamente, enquanto que os resultados obtidos com características estatísticas alcançaram uma taxa de acerto de $66,25\% \pm 0,6\%$.

6.1.2 Atenção

Como definido no ítem 0, o nível de Atenção está relacionado aos estados de alerta, vigilância, concentração, estimulação e interesse.

Para processamento de tais estados, que constituem o nível de atenção, algumas formas de ondas são mais interessantes:

- a) Ondas Alfa (α), na faixa de 7,5 a 12Hz, estão associadas ao relaxamento e desprendimento, como pensar em algo pacífico com os olhos fechados. Estas ondas estão mais concentradas na parte de trás da cabeça, equivalentes aos eletrodos O1 e O2 e estão inversamente relacionadas ao nível de atenção. [Lukas, Mendelson, & Benedikt, 1995].
- b) Ondas Beta (β), na faixa entre 12 e 30Hz de frequência, são associadas à concentração e foco e estão concentradas nas regiões centrais e frontais da cabeça. Ondas Beta são diretamente proporcionais ao nível de atenção. [Y.Zhang, Chen, Bressler, & Ding, 2009] [7]
- c) Ondas Gama (δ) estão na faixa acima de 31Hz e são associadas ao mecanismo de consciência e, por tanto, diretamente relacionadas ao nível de atenção. [Rangaswamy et al., 2002][8].
- d) Ondas Theta (θ) são consideradas, em humanos, na faixa entre 6 e 7Hz e estão associadas aos estados de sonolência e meditação. Estando, portanto, inversamente relacionados ao nível de atenção.

Alguns autores, como Eugene Y. Bann e Joanna J. Bryson, consideram o nível de Arousal, como descrito em diversos modelos circunplexos de afetividade [Watson &

Tellegen, 1985; Russell, 1980; Cacioppo & Berntson, 1994], para mais detalhes, ver ítem 0, equivalente ao nível de engajamento, e, conseqüentemente, atenção [Bann, 2013].

Para testar tal teoria, foi utilizado o banco de dados DEAP e testadas as relações entre as ondas Alfa, Beta, Gama e Theta e o nível de arousal.

Para cálculo de cada onda, calculou-se a Transformada de Fourier do sinal e respectiva filtragem de cada banda de frequência respectiva a cada onda utilizando Filtro Passa Banda Butterworth. Após este processo, calculou-se a média das Potências do sinal, conforme a fórmula:

$$MeanPower = \frac{a^2 + b^2}{n}, \text{ sendo } n \text{ o número de amostras e } a \text{ e } b \text{ os coeficientes da parte}$$

real e imaginária de Fourier.

Esta relação é útil para medir a atividade média de uma onda durante um período de tempo equivalente ao número de amostras n [Tan, 2012].

Para cálculo do nível de atenção foram usadas as relações baseados no trabalho de Lawrence J. Prinzl [Prinzl, 2001]:

$$\text{I. } \frac{\beta}{\alpha + \theta}$$

$$\text{II. } \frac{\beta}{\alpha}$$

E uma nova equação proposta para este trabalho, em que são usadas todas as ondas citadas de acordo com a sua relação com o nível de atenção – Beta e Gama diretamente e Alfa e Theta inversamente proporcionais:

$$\text{III. } \frac{\beta + \delta}{\alpha + \theta}$$

Os resultados das fórmulas I, II e III e os valores de Arousal do banco de dados foram divididos em dois grupos, separando os valores superiores em “atenção” e os inferiores em “desatenção”.

Foram obtidos 46,7969% de acerto para a equação I, 46,875% para a equação II e 45,8594% para a equação III. Apesar disso, ao analisarmos os valores de Arousal fornecidos pela base DEAP e os valores calculados pelos métodos anteriormente citados, os coeficientes de correlação de Pearson obtidos para I, II e III foram, respectivamente, 0,04148, 0,042595 e 0,051293, o que sugere que os níveis de atenção não equivalem aos níveis de Arousal, como sugerido por [Bann, 2013]. Não relacionando, portanto, o estado de atenção com os modelos circunplexos de afetividade descritos no ítem 0 e amplamente utilizados na área da psicologia e psicopedagogia.

Esta análise, porém, apenas sugere que não há relação entre o nível de atenção e o de arousal, não sugerindo nada sobre a eficácia de tais equações em avaliar o nível de atenção. Muitos trabalhos, porém expõem a relação das ondas Beta e Alfa com os níveis de atenção dos indivíduos [Prinzel, 2001].

6.1.3 Engajamento

Foi escolhido também avaliar os níveis de engajamento (“*engagement*”) processados pelo aparelho Emotiv. A empresa define o estado de *engagement* como “Engajamento é experimentado como o estado de alerta e direção consciente de atenção para estímulos relevantes para a tarefa. É caracterizado pelo aumento da excitação fisiológica e ondas Beta, juntamente com a atenuação das ondas Alfa. O polo oposto desta detecção é referido como tédio.” [Emotiv, 2014]. A forma como o nível de engajamento é determinado não é explicitado pela empresa, a qual também se recusou a fornecer maiores informações em contatos feitos pela autora com a empresa via email. Pela descrição provida na documentação do aparelho, entende-se que o engajamento pode ser considerado equivalente ao processo psicológico básico conhecido como atenção.

O sistema Emotiv disponibiliza através de interface de programação de aplicação (API) uma *flag* (mecanismo lógico utilizado em programação) que indica se o sinal de Engajamento está ruidoso ou não. Esta *flag* foi utilizada no programa de captura e interpretação de sinal e apenas os sinais não ruidosos foram aproveitados no sistema, de forma a maximizar a acuidade do sinal obtido.

A seguir podemos visualizar um exemplo de gráfico do sinal Engajamento obtido durante um teste em que o usuário executa tarefas que demandam atenção, usando o capacete *Emotiv*. Os dados foram analisados *off-line* utilizando a ferramenta *Matlab*.




Gráfico 2 - Engajamento. A diminuição do engajamento fica evidenciada pela aproximação linear, representada em vermelho.

O Gráfico 2 mostra o sinal de Engajamento do Emotiv que, conforme a documentação da empresa, entende-se ser equivalente à atenção. Assim, a diminuição do sinal de engajamento é equivalente ao aumento de tédio do indivíduo enquanto executa a tarefa.

6.2 ALGORITMO GENÉTICO

Estendendo a explicação de algoritmos genéticos apresentadas no item 2.2, será apresentado o algoritmo desenvolvido. Este capítulo será dividido em duas partes, primeiramente será explicado alguns conceitos implementados, em 6.2.1 e em 6.2.2 o fluxo do algoritmo propriamente dito.

6.2.1 Notações e Representações dos Parâmetros

Gene – representação individual dos parâmetros utilizados. Cada gene representa uma funcionalidade da sala de conferência, vários genes formam um cromossomo. Um gene é um elemento do vetor de estados que compõe a estrutura denominada *cenário*. Quando um gene possui o valor 1, a funcionalidade associada estará ativa, quando o valor for 0, a funcionalidade associada estará desativada.

Estado/cromossomo/individuo – O estado é representado por uma cadeia de bits que assumem valores 0 e 1, sendo 0 desativado e 1 ativado. Um cromossomo é formado por vários genes. Cada posição dessa cadeia de bits representa uma funcionalidade diferente da sala de conferência. Um estado ou cromossomo é considerado uma possível solução para o problema.

Aptidão – parâmetro de saída da camada de usuário, representa a emoção objetivo do usuário em relação ao ambiente.

Cenário – Estrutura que contém informação de um estado/cromossomo/individuo, e sua respectiva aptidão. O estado é representado por um vetor de inteiros, enquanto a aptidão é representada por um *float*. A estrutura *cenário* é definida da seguinte forma:

```
struct CENARIO {  
    std::vector<int> estados;  
    float aptidao;  
} cenario;
```

Figura 8 - Definição da estrutura “cenário” em código C/C++. Fonte: elaborado pela autora.

População – Conjunto de indivíduos no espaço de busca. Os melhores indivíduos da população formarão a próxima geração.

Geração – iteração completa do Algoritmo Genético que fará parte da nova população. Cada geração é representada por um vetor do tipo *cenário*. A geração será, então, um vetor de estruturas em que cada estrutura possui um vetor de inteiros e um *float*.

Elite – conjunto de indivíduos com maior aptidão. A elite será replicada para próxima geração e será usada no processo de *crossover*, a ser explicado adiante. Para definir a elite, é feito um processo de ordenação pela aptidão. Em seguida, os n primeiros indivíduos serão selecionados para compor a elite, utilizando seleção elitista.

Aptidão Objetivo- Valor objetivo de aptidão. Quando o algoritmo genético alcança essa aptidão, pára de procurar novos indivíduos e mantém o estado da sala no último cenário setado. Caso a aptidão do estado atual da sala passe a ser inferior à aptidão objetivo, o algoritmo genético volta a executar. Nem sempre o usuário pode estar em condições de atingir a aptidão setada originalmente, pois questões pessoais podem estar influenciando o seu estado de estresse, atenção e engajamento. Entao, se a aptidão objetivo inicial não é atingida dentro de x populações setadas, ela é recalculada em tempo de execução para a maior aptidão atingida nas últimas x populações executadas. Então, assim que um aumento na emoção objetivo for identificado, a aptidão objetivo é recalculada para este novo valor. Desde modo, a aptidão é sempre coerente com as limitações do usuário.

Crossover - operador genético que faz o brutozamento dos genes de dois indivíduos, e cria novos indivíduos. Utilizamos *Crossover De Um Ponto*, e *Crossover com Máscara Aleatória*, que serão explicados posteriormente no texto.

Mutação - operador genético que a cada *crossover* tem 5% de probabilidade de mudar o valor de um bit aleatoriamente.

A seguir será explicado o funcionamento dos Operadores Genéticos citados anteriormente:

Crossover de Um Ponto - O crossover de um ponto quebra os dois cromossomos recebidos em duas partes. Um novo indivíduo é formado de forma que sua primeira metade será a primeira metade do primeiro elemento, e sua segunda metade será a segunda metade do segundo elemento. Outro novo indivíduo é formado de forma que sua primeira metade será a segunda metade do primeiro elemento, e sua segunda metade será a primeira metade do primeiro elemento. O ponto de corte é definido aleatoriamente e pode assumir valores entre 1 e n , sendo n o tamanho do cromossomo. Técnica sugerida por [D. Beasley, 1993]. Podemos observar dois exemplos de crossover de um ponto na Figura a seguir.

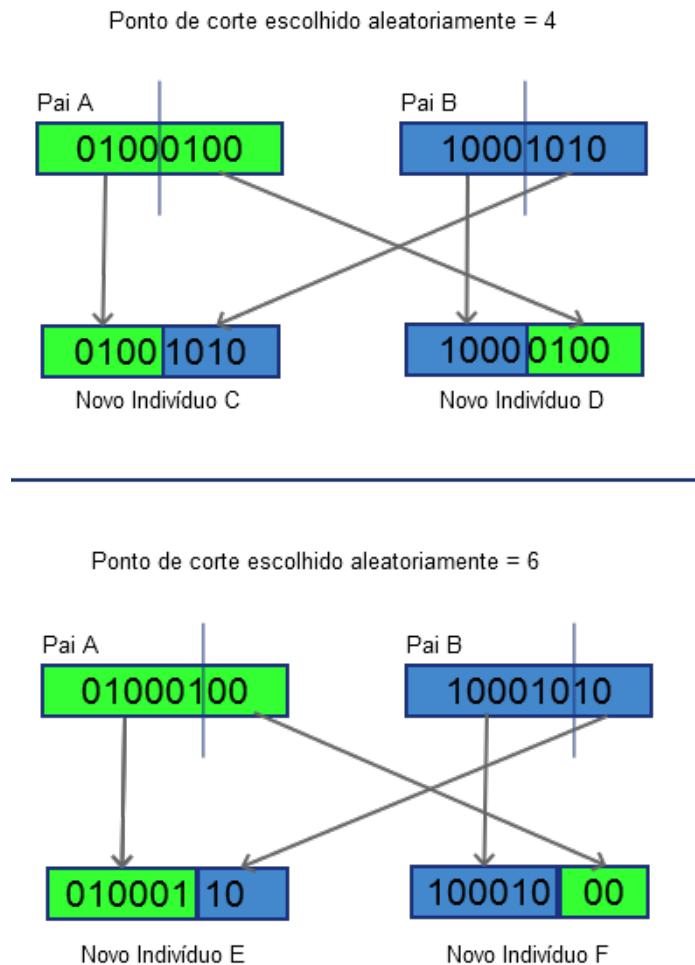
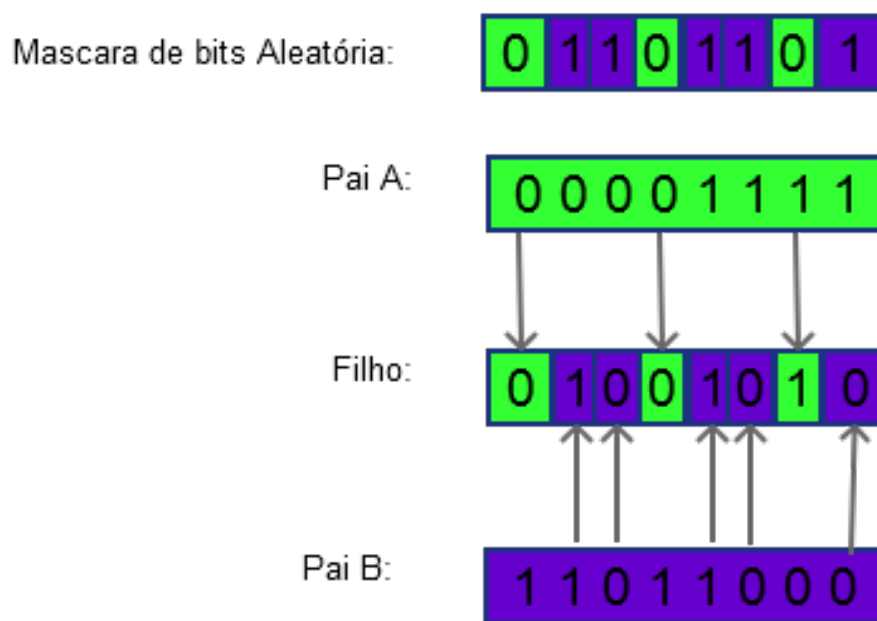


Figura 9 Exemplos de Crossover de Um Ponto em que o ponto de corte é, respectivamente quatro e seis. Fonte: elaborado pela autora.

Crossover com Máscara Aleatória - O crossover com Máscara Aleatória recebe dois cromossomos de tamanho n , e a partir deles cria um novo cromossomo baseado numa máscara aleatória. Uma máscara de bits de tamanho n é criada, com valores aleatórios de 0 e 1. A máscara define de qual elemento virá a informação para cada gene. Por exemplo, caso a máscara tenha valor 1 na sua 3ª posição, o terceiro gene terá o valor do 3º gene de um dos indivíduos pais. Caso o valor seja 0, o gene terá o valor do outro indivíduo pai. Técnica sugerida por [D. Beasley, 1993]. Podemos ver um exemplo de crossover com máscara aleatória na Figura a seguir:



Caso bit da mascara tenha valor 1, Filho recebe informação do Pai A
 Caso bit da mascara tenha valor 0, Filho recebe informação do Pai B

Figura 10 - Exemplo de Crossover com Máscara Aleatória. Fonte: elaborado pela autora.

Mutação - Mudança de um gene (bit). Um bit aleatório muda de 0 para 1, ou vice-versa. Toda vez que um crossover é aplicado, cada indivíduo resultante tem uma chance de

5% de sofrer mutação. Esta taxa de mutação sugerida por [Affenzeller, 2009]. Na Figura a seguir podemos ver uma mutação acontecendo: no primeiro exemplo o quarto gene é escolhido aleatoriamente para mudar seu valor, então muda de 0 para 1; no segundo exemplo, o sétimo gene é escolhido aleatoriamente para mudança de valor, e muda de 1 para 0. “A operação de mutação é utilizada para garantir uma maior varredura do espaço de estados e evitar que o algoritmo genético convirja muito cedo para mínimos locais.” [Mitchell, 1996].




Figura 11- Exemplos de Mutação no quarto e sexto bits/genes respectivamente. Fonte: elaborado pela autora.

6.2.2 Fluxo do Algoritmo

Primeiramente, é criado aleatoriamente um conjunto de estados iniciais, que compõem a primeira geração do algoritmo genético. Essa geração inicial é inicializada com valores de aptidão igual à -1 para indicar que o estado ainda não foi avaliado. Isso significa que cada cenário que compõe a geração inicial, terá um valor aleatório no campo *estados*, e valor -1 no campo *aptidão*. A sala de conferência assumirá cada um dos estados criados e a avaliação da

aptidão será feita pela camada de usuário. Após a avaliação da aptidão, o valor -1 do campo *aptidão* será substituído pela aptidão avaliada.

Após a avaliação de todos os estados iniciais, é feita a seleção elitista: é aplicado um algoritmo de ordenação pela aptidão para que seja possível separar a elite do resto da população. Os indivíduos no topo da população ordenada serão considerados a elite.

A partir da elite a próxima geração é criada. O primeiro indivíduo da elite fará *crossover de um ponto* com o segundo indivíduo da elite, retornando dois novos indivíduos. O primeiro elemento fará um *crossover de Máscara Aleatória* com o terceiro indivíduo, criando assim mais um novo indivíduo. A cada processo de *crossover* há uma probabilidade de 5% de ocorrer mutação em um gene, ou seja, um bit passar de 0 para 1 e vice-versa, como sugerido em [Affenzeller, 2009].

A seguir, é criada uma nova geração que conterá a elite da geração e os novos indivíduos criados com os processos de *crossover*. Tem-se novamente uma geração com indivíduos que possuem aptidão não avaliada. Os estados dos indivíduos da nova geração serão passados para os equipamentos disponíveis na sala através da camada pervasiva e a sala assumirá o cenário correspondente a cada um dos indivíduos e novamente a avaliação de suas aptidões será executada pela camada de usuário.

Após a avaliação de todos os indivíduos da população, é feito o processo de ordenação, e a próxima elite é calculada. A partir desse ponto o processo passa a se repetir, com a aplicação de *crossover*, criação de novos indivíduos, avaliação da aptidão destes novos indivíduos, ordenamento da população, e, por fim, cálculo da próxima elite.

O algoritmo genético desenvolvido tem o objetivo de manter o melhor ambiente possível para o usuário. Para isto, é utilizado um valor de aptidão ideal, denominado aptidão objetivo, que representa o valor mínimo de aptidão que se quer que o usuário. O algoritmo para de criar novos indivíduos quando encontra um indivíduo com aptidão maior ou igual à

aptidão objetivo e a sala fica setada no mesmo cenário, até que o nível de aptidão baixe do valor objetivo, buscando novamente um estado com aptidão maior. Este algoritmo é baseado em [D. Whitley,1989] e [T. Back,1996].

O algoritmo pode adaptar seu valor de aptidão objetivo caso o usuário não consiga alcançá-la por um número muito alto de iterações. A aptidão objetivo adaptável se mostra necessária pois cada usuário possui diferentes limitações, sejam por diferenças intrínsecas ao indivíduo, como déficit de atenção, ou momentâneas, como diferentes momentos de vida que influenciam nas emoções em questão.

7 TESTES E RESULTADOS

Os testes foram divididos entre Testes da Análise dos Sinais de EEG, em que é exposto como as análises dos sinais de EEG propostas anteriormente se comportam para este tipo de problema; Testes do Sistema, em que foi testado o comportamento do sistema e do Algoritmo Genético proposto para a solução do problema; e Testes com Usuários, em que testamos a influência do sistema no estado do indivíduo.

7.1 TESTES DAS ANÁLISES DOS SINAIS DE EEG

Os resultados dos testes de Atenção e Estresse, calculados como descrito no item 6.1.2, não mostraram variação significativa ao longo dos 40 minutos de teste, significando que estes cálculos dos níveis de atenção e estresse talvez não sejam sensíveis o suficiente para detectar variações do estado do indivíduo dentre um mesmo tipo de tarefa, conforme mostrado nos gráficos a seguir:




Gráfico 3 Gráfico mostrando pouca variação da Atenção Calculada ao longo do tempo




Gráfico 4 Gráfico mostrando pouca variação do nível de Estresse Calculado ao longo do tempo

Uma análise mais aprofundada dos cálculos para atenção e estresse ou da extração de ruído e artefatos do sinal é necessária para utilização destes estados neste tipo de problema.

Os dados de Engajamento calculados pelo Emotiv, por outro lado, mostraram variações representativas. Embora a empresa não dê detalhes sobre o algoritmo usado para cálculo do engajamento, este é um sinal cujos valores são creditados por estudos como [Pham, 2012] e [Castermans, 2011] e utilizados em diversos estudos como [Louwerse, 2012], [Mavros, 2012], [Fraga, 2013], [Pierce, 2010][Tarkesh, 2011][Inventado, 2011][Gonzalez-Sanchez, 2011]; motivo pelo qual este sinal foi escolhido para ser utilizado nos testes com usuários.

7.2 TESTES COM USUÁRIOS

Para realização dos testes experimentais com usuários foi montado um projeto de extensão intitulado “Sistema de Controle Baseado em Emoções Através de Interface Cérebro Computador” o qual foi aprovado no início de dezembro de 2014 (ver Apêndice 1 para maiores detalhes). Até o momento foram realizados testes com seis indivíduos, identificados pelas letras A, B, C, D, E e F, os quais serão descritos na sequência. Todos os indivíduos que participaram dos testes são voluntários e assinaram termo de consentimento conforme Apêndice 2. Os dados sócio-culturais dos indivíduos são:

- a) Indivíduo A: sexo masculino, 23 anos de idade, graduação em andamento.
- b) Indivíduo B: sexo masculino, 26 anos de idade, mestrado em andamento.
- c) Indivíduo C: sexo feminino, 34 anos de idade, graduação em andamento.
- d) Indivíduo D: sexo masculino, 26 anos de idade, mestrado em andamento.
- e) Indivíduo E: sexo feminino, 31 anos de idade, mestrado em andamento.
- f) Indivíduo F: sexo masculino, 60 anos de idade, doutorado.

Até o momento foram executados dois tipos de testes com os usuários:

- a) Teste Controle, em que o indivíduo executa as mesmas tarefas do teste Experimental, pelo mesmo tempo, enquanto o seu EEG é gravado e avaliado em níveis de atenção. Porém, neste caso, não é usado o sistema de controle do ambiente, i.e., o ambiente não está se adaptando conforme o seu nível de atenção.
- b) Teste Experimental, em que o indivíduo executa tarefas repetitivas durante trinta minutos enquanto o seu EEG é gravado e avaliado em níveis de atenção. Durante o experimento, o ambiente, conforme o algoritmo de controle descrito anteriormente, se adapta buscando aumentar o nível de atenção do indivíduo.

O grupo de tarefas executadas pelos indivíduos durante os experimentos é constituído de um conjunto de testes doze de atenção, sendo seis do tipo “AC Vetor” e seis do tipo “TACOM” descritos no ítem 0 e a duração de cada experimento foi de aproximadamente 40 minutos, sendo que o mais rápido executou em 35min e o mais lento em 45min. Os testes controle e experimental foram executados em dias separados.

7.2.1 Testes Controle

Os testes de controle foram executados na Empresa Home Systems, empresa de automação residencial sediada em Porto Alegre/RS, em sala silenciosa, com iluminação adequada e ar condicionado na temperatura escolhida pelo indivíduo a ser testado. As atividades desenvolvidas foram os testes de atenção descritas no Ítem 7.2, utilizando-se o capacete Emotiv para leitura e posterior interpretação do sinal de Engajamento.

Os resultados dos testes controle executados usando o nível de engajamento calculado pelo Emotiv explicado no ítem 6.1.3 podem ser vistos nos gráficos a seguir. Os testes de controle foram executados com os indivíduos A, B, D e F, cujos dados podem ser visualizados nos gráficos a seguir. Os gráficos mostram o Engajamento pelo número de amostras ao longo do tempo, em azul; dão valor médio do engajamento em verde e a aproximação linear, em vermelho.

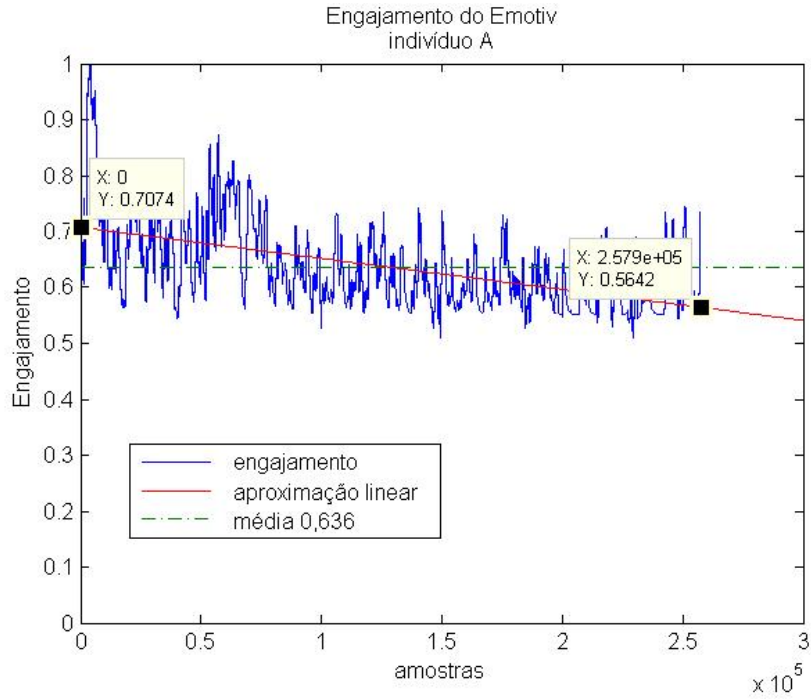


Gráfico 5 - Resultado do teste com Engajamento do indivíduo A

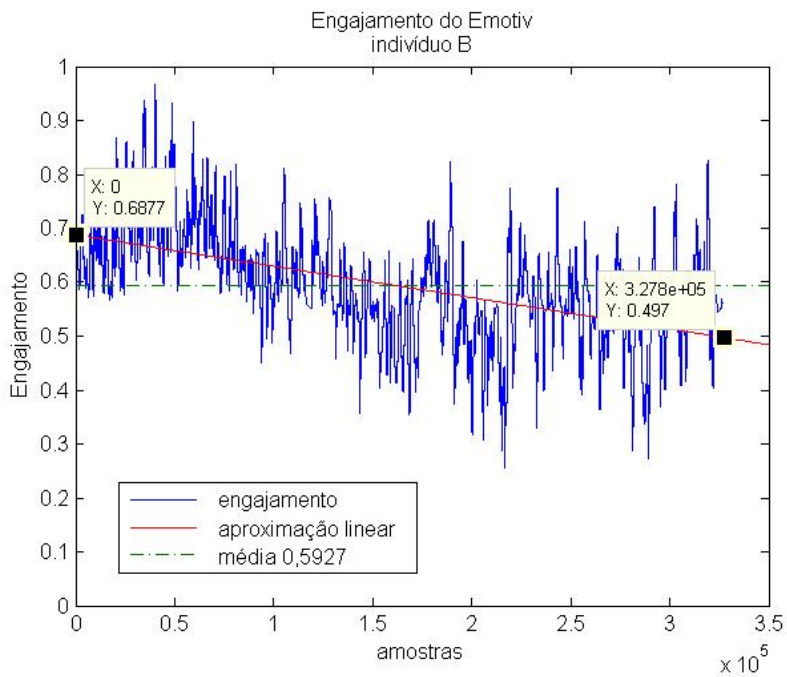


Gráfico 6 - Resultado do teste com Engajamento do indivíduo B

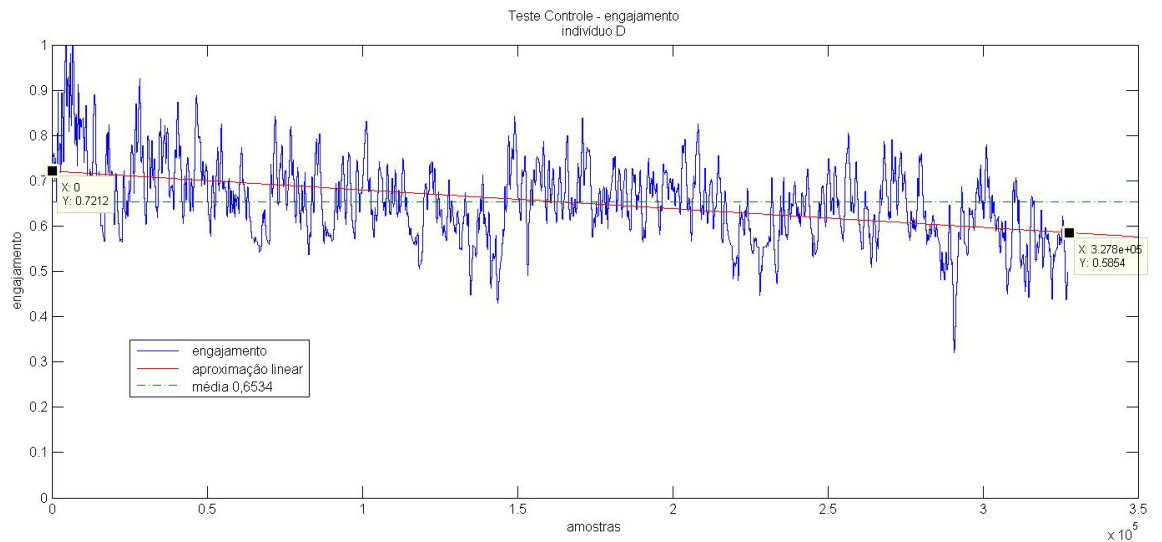


Gráfico 7 - Resultado do teste com Engajamento do indivíduo D

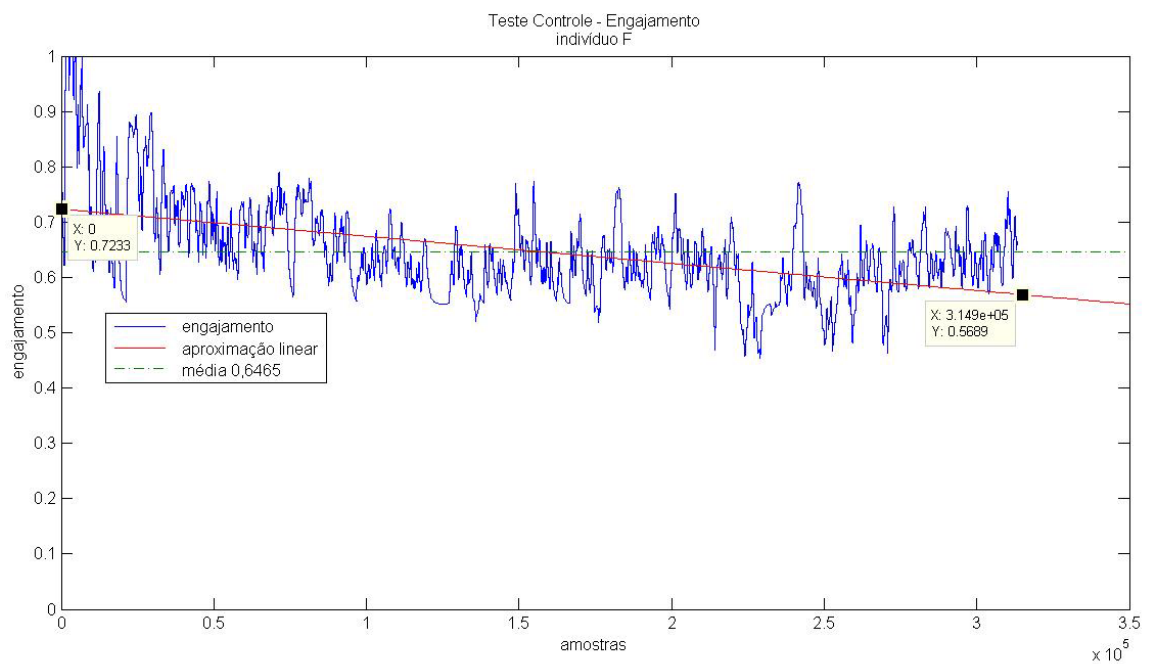


Gráfico 8 - Resultado do teste com Engajamento do indivíduo F

Conforme esperado, os gráficos dos resultados nos mostram que no início há um aumento do nível de engajamento, devido à excitação com a nova tarefa, mas com o tempo, os indivíduos tendem a ficar entediados com a execução das tarefas repetitivas e seu nível de

engajamento baixa. Isso fica evidente quando fazemos uma aproximação linear dos resultados, representada no gráfico por uma linha vermelha.

Ao analisarmos o início e o final dos dados, podemos ver uma diminuição do nível de engajamento de 0,7074 para 0,5642 para o indivíduo A, representando uma baixa de aproximadamente 20,24% no nível de engajamento. Para o indivíduo B, os valores baixam de 0,6877 para 0,497, representando uma baixa de 27,73% do engajamento do indivíduo com a tarefa executada. Já para o indivíduo D, os valores vão de 0,7212 para 0,5854, baixando 18,83%, e para o indivíduo F, de 0,7233 pra 0,5689, equivalente a uma baixa de 21,35%.

Para ser possível fazermos uma análise quantitativa sólida, é necessária a execução de mais testes para termos mais dados. Os resultados avaliados até o momento, porém, indicam que o nível de engajamento dos indivíduos tende a baixar ao longo do tempo. Ao fazermos a média dos valores para os quatro indivíduos, vemos uma baixa de aproximadamente 22% no nível de engajamento, em apenas 40min, o que pode impactar negativamente a execução de tarefas e a produtividade do mesmo. Inclusive aumentando o risco de acidentes se a tarefa envolver risco, como no dia a dia de controladores de voo, pilotos, motoristas, operadores de máquinas, entre outros. Além disto, também impacta negativamente em outras tarefas, como estudo ou terapias cognitivas, em que o ideal é manter ou até mesmo aumentar o nível de engajamento do indivíduo, mesmo que os problemas de matemática que ele tem que resolver lhe sejam entediantes.

7.2.2 Testes Experimentais

Os testes experimentais também foram executados na Empresa Home Systems, empresa de automação residencial sediada em Porto Alegre/RS, que possui uma sala de reuniões totalmente automatizada com seis circuitos de iluminação, um toldo, cinco cortinas, dois ar condicionados e sistema de mídia com seis monitores e som estéreo. Na figura a seguir podemos ver um voluntário executando o teste experimental.



Figura 12 - Voluntário executando teste experimental¹. Fonte: elaborado pela autora.

Durante o teste, o sistema cria uma população de cenários iniciais, e os executa, avaliando o nível da emoção em questão (estresse, atenção ou engajamento). Conforme os resultados do nível da emoção, novos cenários são criados, utilizando-se dos princípios dos algoritmos genéticos em que apenas os cenários cujo nível de emoção fosse melhor, sobreviveriam na população e gerariam (através de crossover e mutação) cenários filhos e a princípio melhores em termos de manter ou até mesmo melhorar o nível da emoção em questão.

¹ A publicação da foto foi autorizada pelo mesmo

Os resultados dos testes experimentais, utilizando todo o sistema e executados usando o nível de engajamento calculado pelo *Emotiv* explicado no ítem 6.1.3 podem ser vistos nos gráficos a seguir, cujos gráficos foram gerados usando a ferramenta *Matlab*, onde podemos visualizar: em azul o engajamento no decorrer dos cenários; o engajamento médio para cada cenário, marcados por círculos; a média do engajamento durante todo o experimento em verde e a aproximação linear do engajamento em vermelho.

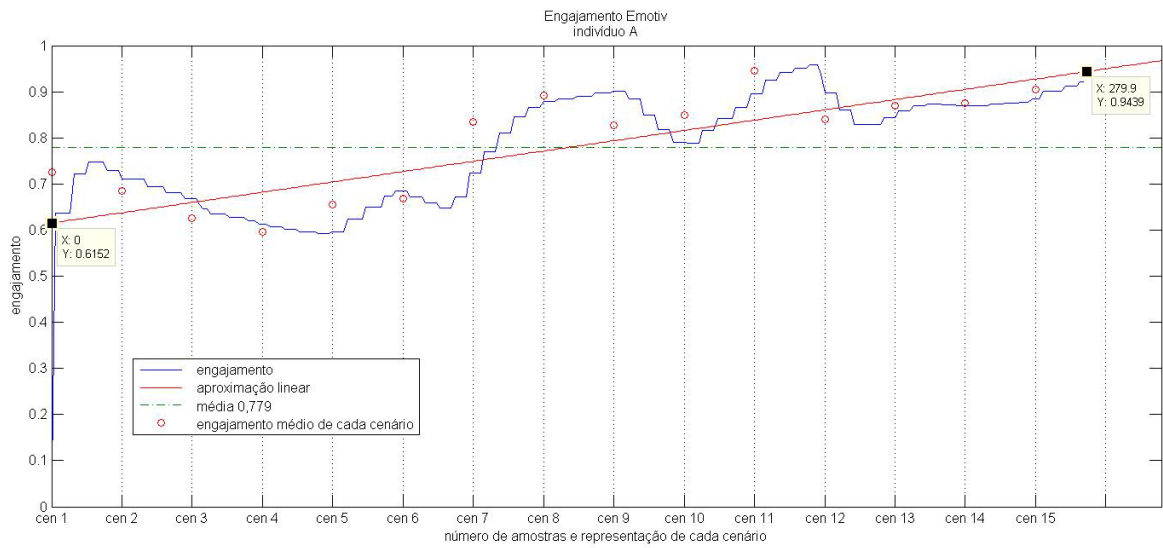


Gráfico 9 - Resultados dos testes com engajamento do indivíduo A




Gráfico 10 - Resultados dos testes com engajamento do indivíduo B

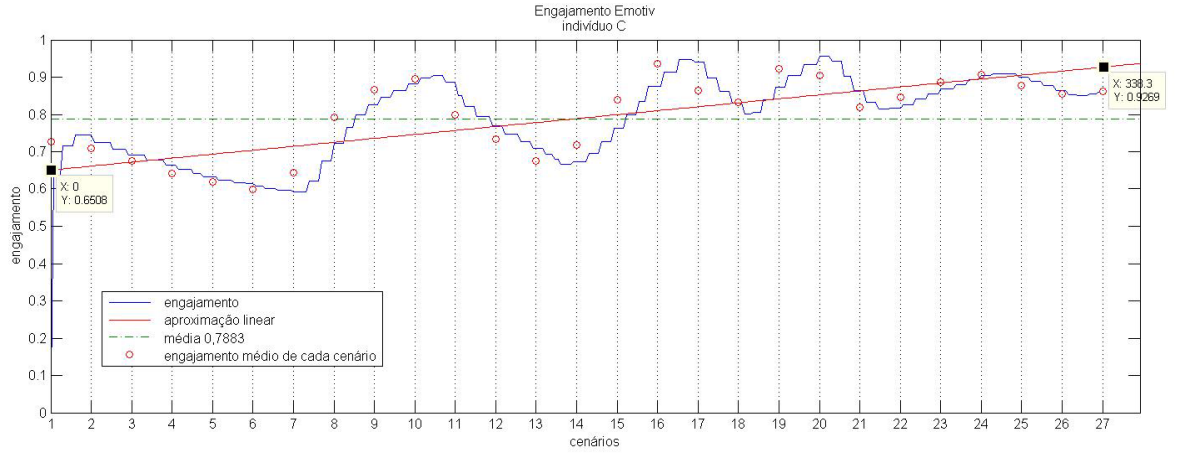


Gráfico 11 - Resultados dos testes com engajamento do indivíduo C

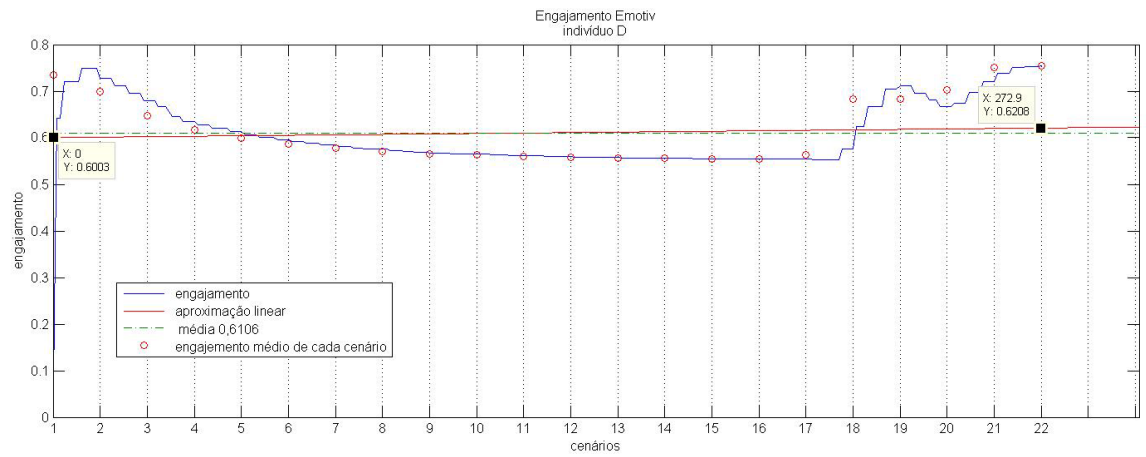


Gráfico 12 - Resultados dos testes com engajamento do indivíduo D

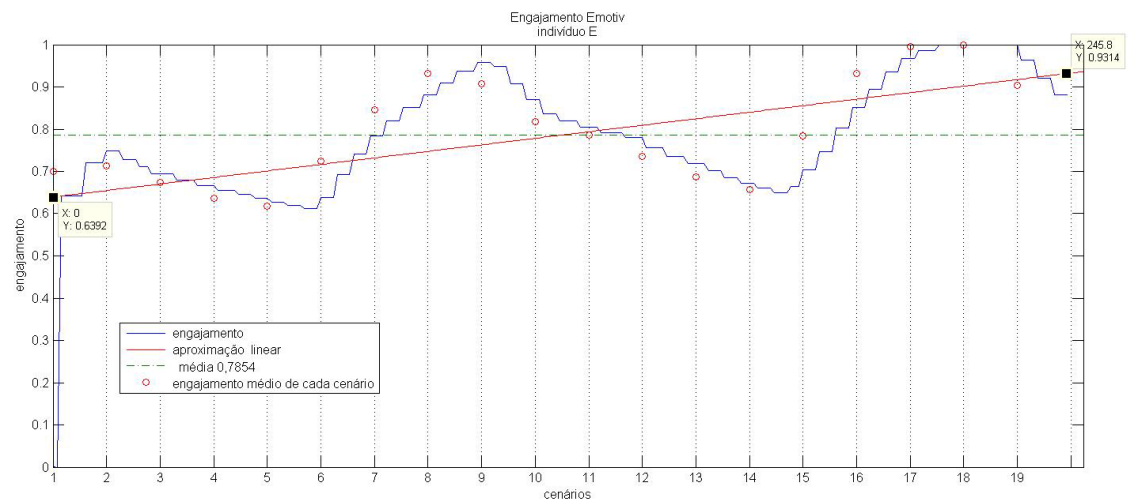


Gráfico 13 Resultados dos testes com engajamento do indivíduo E

Os gráficos dos resultados nos mostram, ao contrário do teste controle, um aumento do nível de engajamento para os indivíduos. Significando que, apesar da tarefa ser entediante com o tempo, como mostrado nos resultados dos testes de controle, o sistema conseguiu não só manter, mas elevar o nível de engajamento dos indivíduos. Isto fica evidente ao analisarmos a aproximação linear, representada nos gráficos por uma linha vermelha. Também podemos observar que a média de engajamento do cenário inicial para o final também aumentou.

Ao analisarmos o início como final do gráfico, observamos um aumento do nível de engajamento de 0,6152 para 0,9434, equivalente a um aumento de aproximadamente 53,35% para o indivíduo A; de 0,6175 para 0,7011, equivalente a um aumento de 13,54% no nível de engajamento para o indivíduo B; de 0,6508 para 0,9269 ou um aumento de 42% para o indivíduo C. Já para o indivíduo D, o nível de engajamento sobe de 0,6003 para 0,6208, equivalente a um aumento de apenas 3,41%, mas para o indivíduo E podemos notar novamente um grande ganho de 0,6392 para 0,9314, ou seja, 45,71% de melhora no nível de atenção. Embora os valores no teste Experimental tenham uma variação maior do que o teste Controle, em todos os casos podemos notar um aumento no nível de atenção, de 3,41% até 45,71%, totalizando em média um aumento de 31,6% no nível de engajamento dos indivíduos.

Se analisarmos o engajamento médio de cada cenário, representados nos gráficos por círculos vermelho, observamos um aumento de 0,7248 para 0,9048, para o indivíduo A; de 0,7072 para 0,7510 para o indivíduo B; de 0,7267 para 0,8616 para o indivíduo C; de 0,7347 para 0,7551 para o indivíduo D e de 0,70 para 0,9045 para o indivíduo E. Ou seja, comparando o primeiro cenário com o último, lembrando que se analisarmos os resultados dos testes controle, os primeiros minutos tendem a ter um nível de engajamento maior, percebemos um aumento de 24,83%, 6,19%, 18,56%, 2,76% e 29,21% respectivamente. Ou

seja, comparando o primeiro cenário – que no teste controle costumam ter o maior valor de todo teste -, equivalente aos primeiros 2 ou 3 minutos de teste com o último cenário, temos um aumento médio de 16,31% no nível de engajamento dos indivíduos testados.

Os indivíduos A, B e D participaram dos testes Controle e Experimental e ao compararmos o engajamento médio destes indivíduos durante todo o período para cada teste, representados nos gráficos pelas linhas verdes tracejadas, podemos ver um aumento de 0,636 para 0,779 ou 22,49% do nível de engajamento para o indivíduo A. E de 0,5927 para 0,6593 ou 11,24% para o indivíduo B durante todo o período de 40min equivalente à execução das tarefas, se compararmos os casos sem e com uso do sistema. Já para o indivíduo D, há uma queda na média do engajamento de 0,6534 para 0,6106, equivalente a 6,55%. Mas é importante salientar que o indivíduo D já começou o teste Experimental com um nível de engajamento 16,76% menor: o teste controle iniciou com um nível de engajamento de 0,7212 e o teste controle com apenas 0,6003 e que estados emocionais como nível de engajamento em tarefas dependem também de fatores psicológicos e individuais da pessoa e não apenas da influência do ambiente, analisada neste trabalho.

8 CONCLUSÃO

Conforme o objetivo definido na Introdução deste trabalho, concluímos que é possível utilizar diretamente o estado emocional do indivíduo para controle e adaptação automática de um Ambiente Inteligente de maneira transparente e passiva para o usuário. Neste trabalho foi mostrado que não apenas é possível o fechamento do laço de controle de um ambiente inteligente não somente com variáveis de ambiente, como temperatura e luminosidade, como nos trabalhos relacionados desenvolvidos até então, mas também com informações geradas a partir do processamento e análise de biosinais; como é possível se obter bons resultados mensuráveis com esta abordagem de se usar diretamente o estado do indivíduo.

Geralmente, ao se fazer uma tarefa repetitiva por algum tempo, o nível de atenção e consequente engajamento do indivíduo tende a baixar, pois como foi explicado no ítem 0, a atenção depende do estímulo atrativo da informação e, com o tempo, em tarefas repetitivas, o indivíduo tende a ficar entediado e seu nível de atenção a baixar.

Com o sistema, conseguimos não só manter o nível de engajamento do indivíduo ao adaptar o ambiente, mas inclusive conseguir um ganho significativo na emoção proposta. Este aumento do nível de engajamento não só sugere a estreita relação do estado emocional do indivíduo com o meio em que o rodeia, servindo de apoio para teorias de ergonomia e bem estar no trabalho, mas também pode ser ativamente utilizado em sistemas que auxiliem tarefas em que a atenção do indivíduo é crucial, como tarefas em fábricas, pilotagem de caminhões, controladores de voo, aprendizado em sala de aula, entre outros. Ou auxiliar em terapias para indivíduos com dificuldades de atenção, como Transtorno do Déficit de Atenção com Hiperatividade (TDAH) ou autismo.

Referente ao uso de algoritmo genético em controle de ambiente inteligente com laço fechado, conclui-se que o algoritmo se comporta bem para tal problema e conseguiu se adaptar após aproximadamente 20 minutos, quando o nível de engajamento do indivíduo

começa a baixar, gerando boas soluções após a execução de aproximadamente dois a sete indivíduos.

No âmbito deste trabalho, mostra-se interessante a análise dos sinais de eletroencefalograma para a possibilidade de utilizar-se o sistema aplicado a outras emoções. Neste sentido, o trabalho já desenvolvido até o momento pode ser visto em maiores detalhes no APÊNDICE 4: Interpretação de Processos Psicológicos Básicos através de Eletroencefalograma.

Sobre a análise dos níveis de estresse utilizando sinais de eletroencefalograma, concluímos que é possível classificar os estado de calma e estresse utilizando-se apenas quatro eletrodos e que as técnicas baseadas em PSD e HOC apresentam os melhores resultados do que a técnica de Características Estatísticas. Analisando os resultados do cálculo de comparação entre o nível de *Atenção* e *Arousal*, não é possível concluir que haja relação entre estes dois, como sugerido por alguns autores.

Para ser possível usarmos análise e interpretação dos níveis de estresse e atenção a partir de sinais de EEG em sistemas como o proposto neste trabalho, concluímos que é necessário um estudo mais aprofundado de técnicas de análise e extração de ruído para ser possível chegarmos numa técnica sensível o suficiente para detectar diferenças relevantes no estado do indivíduo.

9 TRABALHOS FUTUROS

Como trabalhos futuros, podemos citar, sobre se utilizar diretamente o estado emocional do indivíduo para controle e adaptação automática de um Ambiente Inteligente, o estudo de outros estados emocionais além do nível de engajamento, assim como testar a utilização do sistema com diversos usuários ou com objetivos mistos, como conforto do usuário e eficiência energética.

Referente ao uso de algoritmo genético em controle de ambiente inteligente com laço fechado, acha-se interessante o estudo de outros algoritmos semelhantes e a posterior comparação dos resultados conforme fatores como eficiência, capacidade de evitar mínimos locais, dentre outros.

Na área de processamento de sinais e interpretação dos níveis de estresse e atenção, faz-se necessário um estudo mais aprofundado para se chegar numa técnica sensível o suficiente para detectar variações relevantes do estado do indivíduo dentre uma mesma tarefa, sendo possível avaliarmos inclusive a integração de diversos biosinais para se ter uma avaliação mais sensível e acurada.

Sobre a relação entre o estado emocional do indivíduo e o meio em que o rodeia e a possibilidade de alterarmos este estado emocional mudando-se os cenários do ambiente, pretende-se aplicar o sistema em grupos específicos de indivíduos, e avaliar a influência do sistema em terapias para déficit de atenção e espectros do autismo, assim como avaliar se o sistema pode influir efetivamente no aumento da produtividade de trabalhadores de fábricas e escritórios. Assim como propor a adaptação do sistema para ser utilizado em outros sistemas automatizados que não apenas ambientes, como tutores inteligentes, robôs ou carros.

Pretende-se dar continuidade a um ou mais estudos aqui propostos durante o doutorado que se iniciará em 2015 na Universidade de Halmstad, Suécia (proposta selecionada no âmbito do Edital Ciências Sem Fronteiras) . Pretende-se que este doutorado

ocorra em sistema de co-tutela entre UFRGS e a universidade sueca e esta proposta será encaminhada logo após a conclusão do mestrado.

REFERÊNCIAS

- [Adriane, 1998] Adriane S Antoniazzi, Débora D Dell’Aglío, Denise R Bandeira, “Conceito de Coping: Uma Revisão teórica”, Estudos de Psicologia, p 273-294, 1998.
- [Affective, 2014] Affective Computing Media Lab, Massachusetts Institute of Technology, <http://affect.media.mit.edu/>, 2014.
- [Affenzeller, 2009] M. Affenzeller, S. Winkler, S.Wagner, A.Beham “Genetic Algorithms and Genetic Programming, Modern Concepts and Practical Applications ”,CRC Press, A CHAOMAN & HALL BOOK, 2009.
- [AIRE, 2004] AIRE Group: MIT Project AIRE – About Us (2004), <http://www.ai.mit.edu/projects/aire>
- [Allison, 2010] B. Z. Allison, “Toward ubiquitous BCIs”, in Bernhard Graimann, Gert Pfurtscheller, and Brendan Allison, editors, “Brain-Computer Interfaces”, The Frontiers Collection, pages 357-387. Springer Berlin Heidelberg, 2010.
- [Altshuler, 2000] Altshuler E.E. “Design of a vehicular antenna for GPS/Iridium using a genetic algorithm”, Transactions n Antennas and propagation, 48 (6), pp. 968-972. IEEE, 2000
- [Anderson, 2006] Anderson, K., McOwan, W.P. “A real-time automated system for the recognition of human facial expressions”. IEEE Trans. System, Man, and Cybernetics, Part B: Cybernetics 36(1), 96–105 (2006)
- [Anttonen, 2005] Anttonen, J., Surakka, V.: “Emotions and Heart Rate while Sitting on a Chair”. In: CHI 2005: Proceedings of the SIGCHI Conference on Human Factors in Computing Systems, pp. 491–499 (2005)
- [Araujo, 2005] Jair Jonko Araujo. “Framework Orientado a Objetos para o Desenvolvimento de Aplicações de Automação Predial e Residencial”. Dissertação (Mestrado em Computação) - Universidade Federal do Rio Grande do Sul, 2005
- [Ark, 1999] W. S. Ark, “A look at human interaction with pervasive computers”, in IBM Systems Journal, vol 38 issue 4, pages 504-507, 1999.
- [Back,1996] Back, T., “Evolutionary Algorithms in Theory and Practice”, Oxford University Press, 1996.
- [Bann, 2013] Bann, Eugene Y. and Bryson, Joanna J., “Measuring Cultural Relativity of Emotional Valence and Arousal using Semantic Clustering and Twitter”, 35th Annual Meeting of the Cognitive Science Society (Cogsci 2013), berlin ,Germany), 2013.

- [Beasley, 1993] Beasley, D., David R. Bull, Ralph R. Martin, “An Overview of Genetic Algorithms :Part 1, Fundamentals”, University of Cardi and University of Bristol, 1993.
- [Berka, 2007] Berka, C., Levendowski, D. J., Lumicao, M., N., Yau, A., Davis, G., Zivkovic, V., T., Olmstead, R., R., Tremoulet, P. D. and Craven, P. L., “EEG Correlates of Task Engagement and Mental Worload in Vigilance, Learning, and Memory Tasks”, *Aviation, Space, and environmental Medicine*, vol, 78, No. 5, Section II, 2007.
- [Blankertz, 2003] Blankertz, B., Dornhege, G., Schafer, C., Krepki, R., Kohlmorgen, J., Mueller, K., Kunzmann, V., Losch, F., and Curio, G.: “Boosting bit rates and error detection for the classification of fast-paced motor commands based on single-trial EEG analysis”. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 11, 127–131, 2003.
- [Birbaumer, 1999] N. Birbaumer, N. Ghanayim, T. Hinterberger, I. Iversen, B. Kotchoubey, A. Kuebler, J. Perelmouter, E. Taub and H. Flor, “A spelling device for the paralysed”, in *Nature* 398, 6725, 297–298, 1999.
- [Brenda, 2012] Brenda L. Lyon, “Stress, Coping, and Health: A Conceptual Overview”, capítulo 1, p 1-19, 2012.
- [Cabral, 2002] Cabral, S.C.B., Muhlen, S.S., “Interferência eletromagnética em equipamentos eletromédicos ocasionada por telefonia celular” *Revista Brasileira de Engenharia Biomédica*, v. 18, n. 3, p. 113-22. 2002
- [CAISR, 2014] “CAISR Intelligent Environment”, Halmstad University. http://islab.hh.se/mediawiki/index.php/CAISR_Intelligent_Environment, 2014.
- [Cannon, 1932] Cannon, W. B., “The wisdom of the body”, 2nd ed., New York, NY: Norton, 1932.
- [Castermans, 2011] Castermans, T., “Detecting Biosignals with Emotiv EPOC headset: a critical review”. Université de Mons, web presentation. 2011. <http://www.slideshare.net/iMALorg/detecting-biosignals-with-the-emotiv-epoc-headset-a-review>
- [CAT VII] ATA VII - Comitê de Ajudas Técnicas (CAT) - Coordenadoria Nacional para Integração da Pessoa Portadora de Deficiência (CORDE) - Secretaria Especial dos Direitos Humanos - Presidência da República.
- [Catarci, 2008] Catarci, T., Cincotti, F., De Leoni, M., Mecella, M., and Santucci, G.. “Smart Homes for All: Collaborating Services in a for-All Architecture for Domotics.” E. Bertino and J.B.D. Joshi (Eds.): *CollaborateCom. LNICST 10*, 2008.
- [Cook, 2006] Cook, D. J., Youngblood, M., Das, S. K., “A Multi-agent Approach to Controlling a Smart Environment”, *Designing Smart Homes Lectures Notes in Computer Science*, volume 4008, pp 165-182, 2006.
- [Cosack, 2006] C. Kleine-Cosack, “Recognition and Simulation of Emotions”, in *Seminar: Human-Robot Interaction*, 2006.
- [Cotrina CBA, 2012] A. Cotrina, A. Ferreira, T. Bastos Filho, M. L. Menezes, C. E. Pereira. “Reconhecimento de componentes emocionais no eletroencefalograma para aplicações em

interfaces cérebro-computador”. XIX Congresso Brasileiro de Automática CBA 2012, Campina Grande/Brasil.

[Cotrina CBEB, 2012] A. Cotrina, A. Ferreira, T. Bastos Filho, M. L. Menezes, C. E. Pereira. “Avaliação de Técnicas de Extração de Características baseadas em PSD, HOC e Características Estatísticas no reconhecimento de Estados Emocionais.” XXIII Congresso Brasileiro de Engenharia Biomédica CBEB 2012.

[Cotrina RMMG, 2012] A. Cotrina, A. Ferreira, T. Bastos Filho, M. L. Menezes, C. E. Pereira. “Avaliação de Características estatísticas e HOC de Sinais EEG no Reconhecimento de Estados Emocionais.” Revista Médica de Minas Gerais (RMMG) 2012

[Cotrina CBA, 2014] A. Cotrina, A. Ferreira, T. Bastos Filho, M. L. Menezes, C. E. Pereira. “Evaluation of Emotional Components to Improve SSVEP-BCI” XX Congresso Brasileiro de Automática CBA 2014, Belo Horizonte. 2014.

[Cotrina EMBC, 2014] A. Cotrina, A. Ferreira, T. Bastos Filho, M. L. Menezes, C. E. Pereira. “Towards an Architecture of a Hybrid BCI Based on SSVEP-BCI and Passive-BCI” 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society EMBC 2014, Chicago/USA.

[Davidson, 1988] Davidson, R. J., “EEG measures of cerebral asymmetry: Conceptual and Methodological issues”, *International Journal of Neuroscience*, 39, 71-89. 1988.

[Davidson, 1990] Davidson, F. J., Chapman, J. P., Chapman, L. J., and Henriques, J. B., “Asymmetrical brain electrical activity discriminates between psychometrically matched verbal and spatial cognitive tasks”, *Psychophysiology*, 27, 528-543. 1990.

[DEAP, 2012] Koelstra, S., Muhl, C., Soleymani, M., Jong-Seok Lee, Yazdani, A., Ebrahimi, T., Pun, T., Nijholt, A., Patras, I., “DEAP: A Database for Emotion Analysis using Physiological Signals”, *Affective Computing, IEEE transactions on Issue 1, Volume 3*, pages 18-31, IEEE, 2012.

[Dimeo, 1995] Dimeo R., and Lee K.Y. Boiler-turbine control system design using a genetic algorithm, *IEEE Transactions on Energy Conservation*, 10(4), pp. 752-759.

[Ducatel, 2001] Ducatel, K. et al. “Scenarios for ambient intelligence (ISTAG Report)”. Seville: Institute for Prospective Technological Studies (European Commission). 2001

[Edlinger, 2011] Edlinger, G., Holzner, C. and Guger, C., “A Hybrid Brain-Computer Interface for Smart Home Control” in *Human-Computer Interaction, Part II, HCII 2011, LNCS 6762*, pp. 417-426, Springer-Verlag Berlin Heidelberg 2011.

[EMS, 2014] Energy Management Solutions, “Benefits of Building Automation Systems”, in *Metropolitan Energy Policy Coalition*, 2014.

[Emotiv, 2012] “Emotiv Forums – Number of electrodes and number of measurements channels”. <https://emotiv.com/forum/forum12/topic2343/messages/>. Emotiv Systems. 2012 [Emotiv, 2014] “Emotiv Software Research Kit – User Manual”. Emotiv Systems. 2014

[Ferreira, 2008] Ferreira, A., Cleste, W., C., Cheein, F. A., Bastos-Filho, T. F., Sarcinelli-Filho, M. and Carelli, R., “Human-machine interfaces on EMG and EEG applied to robotic systems”, in *Journal of NeuroEngineering and Rehabilitation*, BioMed Central, 5-10, 2008.

[Ferreira, 2010] Ferreira, A., Bastos-Filho, T., Sarcinelli-Filho, M., J. L. M., S., Garcia, J., and Quintas, M. “Improvements of a Brain-Computer Interface Applied to a Robotic Wheelchair”, p. 64. 2010.

[Ferrez, 2008] Ferrez, P. W., Millan J. R., “Error-Related EEG Potentials Generated during Simulated Brain-Computer Interaction” in *Interaction IEEE Trans. On Biomedical Engineering*, 55, 2008.

[Fleming, 2001] Fleming, P. J. and Purshouse, R. C., “Genetic Algorithms in Control Systems Engineering”, Research Report No. 789 of Department of Automatic Control and Systems Engineering, University of Sheffield, UK, 2001.

[Fox, 2000] Fox, A., Johanson, B., Hanrahan, P., Winograd, T.: Integrating information appliances into an interactive space. *IEEE Computer Graphics and Applications* 20, 54–65, 2000.

[Fraga, 2013] Tania Fraga, Mauro Pichiliani, and Donizetti Louro. "Experimental Art with Brain Controlled Interface." *Universal Access in Human-Computer Interaction. Design Methods, Tools, and Interaction Techniques for EInclusion 8009* (2013): 642-51. *Experimental Art with Brain Controlled Interface*.

[Garcia, 2009] Garcia, M. G., Anton, N., “Emotional Brain-Computer Interfaces” in 3rd International Conference on Affective Computing and Intelligent Interaction and Workshops, ACII 2009, 2009.

[George, 2010] L. George and A. Lécuyer, “An overview of research on ‘passive’ brain-computer interfaces for implicit human-computer interaction”, in *International Conference on Applied Bionics and Biomechanics ICABB 2010. Workshop W1 'Brain-Computer Interfacing and Virtual Reality'*, 2010.

[Gevins, 2005] Gevins A, Smith ME. “Assessing fitness-for-duty and predicting performance with cognitive neurophysiological measures”. In: Caldwell JA, Wesensten NJ, eds. *Proceedings of SPIE Defense and Security Symposium, Biomonitoring for Physiological and Cognitive Performance during Military Operations*. Orlando, FL: SPIE: The International Society for Optical Engineering; 2005; 127–38.

[Gonzalez-Sanchez, 2011] Gonzalez-Sanchez, J.Chavez-Echeagaray, M.E.Atkinson, and R. Burleson W. "ABE: An Agent-Based Software Architecture for a Multimodal Emotion Recognition Framework." *Software Architecture (WICSA), 2011 9th Working IEEE/IFIP Conference on* (2011): 187-93. *IEEE Xplore Abstract*.

[Greenwell, 2011] Greenwell, J., “Smart Building Automation ROI: What are the R’s in your ROI?” in *Automated Buildings*, CEPOR, LLC. 2011.

[Guger, 1999] Guger, C., Harkam, W., Hertnaes, C., & Pfurtscheller, G. (1999, November). Prosthetic control by an EEG-based brain-computer interface (BCI). In *Proc. aaate 5th european conference for the advancement of assistive technology* (pp. 3-6).

- [Hadjileontiadis, 2010] Hadjileontiadis Panagiotis C., Petrantonakis Leontios J. “Emotion Recognition From EEG Using Higher Order Crossings” *IEEE Transactions on Information Technology in Biomedicine*. 2010;14:186–197.
- [Hamdi, 2012] H. Hamdi, P. Richard, A. Suteau, P. Allain, “Emotion Assessment for Affective Computing Based on Physiological Responses”, *IEEE World Congress on Computational Intelligence*, June, 10-15, 2012.
- [Holmes, 1967] Holmes, T H and Rahe, R H, “The social readjustment rating scale”, *Journal of Psychosomatic Research*, 1967.
- [Hosseini, 2010] Hosseini M A. “Emotional stress recognition system using EEG and psychophysiological signals: in *Biomedical Engineering and Computer Science (ICBECS)*”, 2010 International Conference on: 1 – 6 2010.
- [Inventado, 2011] P. Inventado, R. Legaspi, M. Suarez, and M. Numa. "PREDICTING STUDENT EMOTIONS RESULTING FROM APPRAISAL OF ITS FEEDBACK." *Research and Practice in Technology Enhanced Learning* 6.2 (2011): 107-33.
- [Jang, 1998] Jang-Sung Chun, Hyun-Kyo Jung and Song-Yop Hahn. “A study on comparison of optimization performances between immune algorithm and other heuristic algorithms”, *IEEE Transactions on Magnetics*, 34 (5), pp. 2972-2975. 1998
- [Jensen, 2003] Jensen M.T. Generating robust and flexible job shop schedules using genetic algorithms, *IEEE. 2003 Transactions on Evolutionary Computation*, 7(3), pp. 275-288.
- [Koelstra, 2012] S. Koelstra, M.Soleymani, A. Yazdani, A. Nijholt, “DEAP: A Database for Emotion Analysis Using Physiological Signals”, *IEEE transactions on affective computing*, vol. 3, no. 1, january-march 2012.
- [Kohlmorgen, 2007] Kohlmorgen, J., Dornhege, G., Braun, M., Blankertz, B., Mueller, K.-R., Curio, G., Hagemann, K., Bruns, A., Schrauf, M., and Kincses, W.: Improving human performance in a real operating environment through real-time mental workload detection, vol. *Toward Brain-Computer Interfacing*. Eds. Cambridge, MA: MIT press, 2007.
- [Kramer, 1991] Kramer, A. F., “Physiological metrics of mental workload: A review of recent progress”, in D. L. Damos (Ed.), *Multiple task performance* (pp. 279-328). Washington, DC: Taylor & Francis., 1991.
- [Kupers, 2004] Kupers R., & Ptito M., “‘Seeing’ through the tongue: cross-modal plasticity in the congenitally blind”, in *International Congress Series*, 1270:79-84, 2004
- [Lazarus, 1984] Lazarus, R S and Folkman, S, “Stress, Appraisal, and Coping”, Springe, New York, 1984.
- [Lacerda, 1999] Lacerda, E.G.M, Carvalho, A.C.P.L. “Introdução aos algoritmos genéticos”. In: Galvão, C.O., Valença, M.J.S. (orgs.) *Sistemas inteligentes: aplicações a recursos hídricos e ciências ambientais*. Porto Alegre: Ed. Universidade/UFRGS : Associação Brasileira de Recursos Hídricos. p. 99-150. 1999. (Coleção ABRH de Recursos Hídricos; 7.).
- [Lang, 1994] Margaret M. Bradley, Peter J. Lang, “Mesuring Emotion: The Self-Assessment Manikin and the Semantic Differential”, *B&w Thu. & Exp. Psvchrar*. Vol. 25, 1994.

- [Lee, 2008] Lee, H., Kim, Y. T., Jung, J. W., Park, K.H., Bang, B., Bien, Z.Z., “A 24-hour health monitoring System in a smart house”, *Gerontechnology*, 7(1):22-35, 2008.
- [Leng, 2007] Leng, H., Lin, Y., Zanzi, L.A.: An Experimental Study on Physiological Parameters Toward Driver Emotion Recognition. In: Dainoff, M.J. (ed.) *HCI 2007 and EHAWC 2007*. LNCS, vol. 4566, pp. 237–246. Springer, Heidelberg (2007)
- [Han Liu, 2013] Liu, N. Hang, Chiang, C. Y and Chu H. C., “Recognizing the Degree of Human Attention Using EEG Signals from Mobile Sensors”, in *Sensors Journal*, 10273-10286, 2013.
- [Lin, 2010] Lin YP, Wang Chi-Hong, Jung TP, Wu TL. “EEG-based emotion recognition in music listening”, *IEEE Transactions on Biomedical Engineering*. 2010;57:1798–806.
- [Lin, Chin-Teng, 2010] Chin-Teng Lin, Fu-Chang Lin, Shi-An Chen, Shao-Wei Lu, Te-Chi Chen, Li-Wei Ko, “EEG-based Brain-computer Interface for Smart Living Environmental Auto-adjustment” *Journal of Medical and Biological Engineering*, 30(4): 237-245, 2010.
- [Liu, 2013] Y. Liu, O. Sourina, “EEG Databases for Emotion Recognition”, *International Conference on Cyberworlds*, 2013.
- [Lu, 2010] S. Lu, T. Chen, L. Ko, “EEG-based Brain-computer Interface for Smart Living Environmental Auto-adjustment”, in *Journal of Medical and Biological Engineering*, 2010.
- [Lubar, 1991] Lubar, J. F., “Discourse on the development of EEG diagnostics and biofeedback for attention-deficit/hyperactivity disorders”, *Biofeedback and Self-Regulation*, 16, 201-225. 1991
- [Malhotra, 2011] Malhotra, R., Singh, N. and Singh, Yaduvir, “Genetic Algorithms: Concepts, Design for Optimization of Process Controllers”, in *Computer and Information Science*, vol. 4, No. 2, Published by Canadian Center of Science and Education, 2011.
- [Mampusti, 2011] Mampusti Ella T., Ng Jose S., Quinto Jarren James I., Teng Grizelda L., Suarez Merlin Teodosia C., Trogo Rhia S.. “Measuring Academic Affective States of Students via Brainwave”, *Signals Knowledge and Systems Engineering*, 2011 Third International Conference on. 2011:226–231.
- [Marques, 2014] Patric Marques. “Integração de uma cadeira de rodas automatizada com um ambiente inteligente para a localização Indoor a partir da fusão de diferentes tecnologias.” *Dissertação (Mestrado em Programa de Pós-Graduação em Engenharia Elétrica) - Universidade Federal do Rio Grande do Sul*. 2014.
- [Mavros, 2012] Mavros, P, Coyne, R, Roe, J & Aspinall, P., “Engaging the brain: Implications of mobile EEG for spatial representation”. in *Digital Physicality | Physical Digitality: Proceedings of the 30th eCAADe Conference*. Molab, Prague, Czech Republic, pp. 657, eCAADe 2012 - The 30th International Conference on Education and research in Computer Aided Architectural Design in Europe, Prague, Czech Republic, 12-14 September 2012.[Mitchell,1996] Mitchell, M., “An Introduction to Genetic Algorithms”. MIT Press, 1996.

[Menezes, 2015] Menezes, M. L., Pereira, C. E. “Proposed Use of Passive Brain-Computer Interface in Smart Environments” 24th IEEE International Symposium on Industrial Electronics ISIE 2015, Búzios/Brazil. 2015.

[Mueller, 2007] K. Mueller, M. Krauledat, G. Dornhege, G. Curio and B. Blankertz, “Machine learning and applications for brain-computer interfacing”, in Human Interface and the Management of Information Methods, Techniques and Tools in Information Design 705–714, 2007.

[Muller, 2010] Muller, S. M. T., Celeste, W., C., Bastos-Filho, T., F., Sarcinelli-Filho M., “Brain-computer Interface Based on Visual Evoked Potentials to Command Autonomous Robotic Wheelchair”, in Journal of Medical and Biological Engineering, 30(6): 407-4016, 2010.

[Nakashima, 2009] Nakashima, H., Aghajan, H. and Augusto, J. C., “Handbook of Ambient Intelligence and Smart Environments”, Springer Science+Business Media, LLC, 2010.

[Neuman, 1995] Neuman, M.R., “Biopotential Amplifiers”, In: Medical Instrumentation, Ed.: J.G. Webster, New York: John Wiley and Sons, p. 227-288. 1995

[Nijholt, 2008] A. Nijholt and D. Tan, “Brain-computer interfacing for intelligent systems”, IEEE Intelligent Systems, 23(3):72-72, 2008.

[Offenloch, 1990] Offenloch, K., and Zahner, G., “Computer aided pshysiological assessment of the functional state of pilots during simulated flight”, NATO Advisory Group for Aerospace research and Development Conference Proceedings, USA, 490 9-1-9-9, 1990.

[Onusic, 2005] Onusic, D.M., “Construção de um Dispositivo Eletrônico para Determinação de Camada Semi-Redutora em Feixe de Raios-X Diagnóstico”, Dissertação de Mestrado, Departamento de Engenharia Biomédica, FEEC/UNICAMP, Campinas, 60 p., 2005.

[Oppenheim, 1975] Oppenheim, A.V., Schafer, R.W., “Digital Signal Processing”, London: Prentice-Hall International. 1975

[Osgood, 1957] Osgood, C.E., Suci, G., & Tannenbaum, P., “The measurement of meaning”, Urbana, IL: University of Illinois Press, 1957.

[Peçanha, 2012] Peçanha, C. C., “Ambiente Inteligente Controlado por Dispositivos Móveis”. Trabalho de Conclusão de Curso em Bacharel em Ciência da Computação da Universidade Vila Velha. Portugal, 2012.

[Perozzo, 2007] Perozzo, R. “Framework para Construção de Sistemas Supervisórios em Dispositivos Móveis”. Dissertação (Mestrado em Programa de Pós-Graduação em Engenharia Elétrica) - Universidade Federal do Rio Grande do Sul, Conselho Nacional de Desenvolvimento Científico e Tecnológico. Orientador: Carlos Eduardo Pereira. 2007

[Perozzo, 2012] Perozzo, R. F., Zamberlan, A. O., PEREIRA, C. E., “Serviços Microcontrolados em Ambientes Inteligentes”. In: VI Congresso Sul Brasileiro de Computação, 2012, Criciúma. Anais SULCOMP, 2012. v. 6.

[Petrantonakis, 2009] Petrantonakis Panagiotis C, Hadjileontiadis Leontios J. “EEGBased Emotion Recognition Using Hybrid Filtering and Higher Order Crossings” in Affective

Computing and Intelligent Interaction and Workshops, 2009. ACII 2009. 3rd International Conference on:1-6 2009.

[Petrantonakis, 2011] Petrantonakis P., Hadjileontiadis L.. “A Novel Emotion Elicitation Index Using Frontal Brain Asymmetry for Enhanced EEG-Based Emotion Recognition”. *IEEE Transactions on Information Technology in Biomedicine*. 2011;15:737–46.

[Pfurtscheller, 1979] G. Pfurtscheller and A. Aranibar, “Evaluation of event-related desynchronization(ERD) preceding and following voluntary self-paced movement”, *Electroencephalography and clinical neurophysiology* 46, 2, 138–146, 1979.

[Pham, 2012] Pham, T. D. and Tran, D., “Emotion Recognition using the Emotiv EPOC Device”, Springer-Verlag Berlin Heidelberg ICONIP 2012, Part V, LNCS 7667, pp. 394-399, 2012.

[Picard, 1995] R. W. Picard, "Affective Computing" MIT Technical Report #321, 1995.

[Picard, 2001] Picard, R. W., Elias, V., “Toward machine emotional intelligence: Analysis of affective physiological state”, in *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 23:1175-1191, 2001.

[Pierce, 2010] Pierce, Franklin. "EmoChat: Emotional Instant Messaging with the Eloc Headset." Thesis submitted to the Faculty of the Graduate School of the University of Maryland, Baltimore County, Master of Science, 2010.

[Prinzel, 2001] Prinzel, Lawrence J., Freeman, F. G., Scerbo, M. W., Mikulka, P. J. and Pope, A. T., “A Closed-Loop System for Examining Psychophysiological Measures for Adaptive Task Allocation”, *The International Journal of Aviation Psychology*, 10(4), 393-410, 2001.

[Ramos, 2012] Ramos, D, Bueno, J. I. O., “A percepção de emoções em trechos de música ocidental erudita”, *Per Musi*, Belo Horizonte, n.26, p.21-30, 2012.

[Ramoser, 2000] H. Ramoser, J. Mueller-Gerking and G. Pfurtscheller, “Optimal spatial filtering of single trial EEG during imagined hand movement”, in *IEEE Transactions on Rehabilitation Engineering* 8, 4, 441–446, 2000.

[Raymer, 2000] Raymer M.L., Punch W.F., Goodman E.D., Kuhn L.A., and Jain, A.K. “Dimensionality reduction using genetic algorithms”, *IEEE Transactions on Evolutionary Computation*, 4(2), pp. 164-171. 2000

[Rebsamen, 2010] Rebsamen, B.; Cuntai Guan; Haihong Zhang; Chuanchu Wang; Cheeleong Teo; Ang, V.M.H.; Burdet, E., "A Brain Controlled Wheelchair to Navigate in Familiar Environments," *Neural Systems and Rehabilitation Engineering*, *IEEE Transactions on* , vol.18, no.6, pp.590,598, Dec. 2010

[Rita, 2003] Bach-y-Rita, P., Tyler, ME., & Kaczmarek, KA, “Seeing with the Brain”, in *International Journal on Human-Computer Interaction*. 15:285-296. 2003

[Robson, 2013] Robson, “Manual do Psicotécnico”, <http://b1.pinger.pl/50ea264d95734bb4e7f2be666ea18550/manpsico2ed.pdf>, 2 ed., 2013.

- [Ruscher, 2011] G. Ruscher, F. Kruger, S. Bader, T. Kirste, “Controlling Smart Environments using Brain Computer Interface”, in Proceedings of the 2nd Workshop on Semantic Models for Adaptive Interactive Systems, SEMAIS’11, 2011.
- [Russell, 1980] J.A. Russell, “A Circumplex Model of Affect,” J. Personality and Social Psychology, vol. 39, no. 6, pp. 1161-1178, 1980.
- [SA3L, 2014] “SA3L – Situation Awareness for Ambient Assisted Living”, Halmstad University, http://islab.hh.se/mediawiki/SA3L_-_Situation_Awareness_for_Ambient_Assisted_Living, 2014.
- [Sanei, 2007] Sanei, S. and Chambers, J. A., “EEG Signal Processing”. Centre of Digital Signal Processing, Cardiff University, UK. Ed. John Wiley & Sons, Ltd. 2007. ISBN 978-0-470-02581-9.
- [Schaaff, 2009] Schaaff Kristina, Schultz Tanja. “Towards an EEG-based Emotion Recognizer for Humanoid Robots” in The 18th IEEE International Symposium on Robot and Human Interactive Communication,:792–796 2009.
- [Selye, 1956] Selye, H, “The Stress of Life”, New York: McGraw-Hill, 1956.
- [Sternberg, 2000] Sternberg, R. J., “Psicologia Cognitiva”, Porto Alegre, Artmed, 2000.
- [Streitberg, 1987] Streitberg, B., Rohmel, J., Herrmann, W. M., and Kubicki, S., “COMSTAT rule for vigilance classification based on spontaneous EEG activity”, Neuropsychobiology, 17, 105-117. 1987.
- [Tan, 2012] Tan, B. H., “Using a Low-cost EEG Sensor to Detect Mental States” Thesis of Master of Science of School of Computer Science at Carnegie Mellon University, Pittsburg, PA, 2012.
- [Tanaka, 2005] Tanaka, K.; Matsunaga, K.; Wang, H.O., "Electroencephalogram-Based Control of an Electric Wheelchair," Robotics, IEEE Transactions vol.21, no.4, pp.762,766, Aug. 2005.
- [Tarkesh, 2011] EHSAN TARKESH, ESFAHANI, and V. SUNDARARAJAN. "USING BRAIN-COMPUTER INTERFACES TO DETECT HUMAN SATISFACTION IN HUMAN-ROBOT INTERACTION." International Journal of Humanoid Robotics 8.1 (2011): 87-101.
- [Tong, 2011] Yuen Chai Tong, San Woo San, Rizon Mohamed, Seong Tang Ching. “Classification of Human Emotions from EEG signals using Statistical Features and Neural Network” in International Journal of Integrated Engineering. 2011.
- [Vidal, 1973] J. J. Vidal, “Toward Direct Brain-Computer Communication”, in Annual Review of biophysics and Bioengineering Vol. 2: 157-180, 1973.
- [Weiser, 1991] M. Weiser, “The Computer for the 21st Century”, in Scientific American #265, pages 94-104, 1991.
- [Weiser, 1999] M. Weiser, R. Gold, J. S. Brown, “The origins of ubiquitous computing research at PARC in the late 1980s”, in IBM Systems Journal, vol 38, num 4, 1999.

[Whitley,1989] Whitley, D., “A Genetic Algorithm Tutorial”, Computer Science Department, Colorado State University, 1989.

[Wilson, 2005] Wilson G. “Operator functional state assessment for adaptive automation implementation”. In: Caldwell JA, Wesensten NJ, eds. Proceedings of SPIE Defense and Security Symposium, Biomonitoring for Physiological and Cognitive Performance during Military Operations. Orlando, FL: SPIE: The International Society for Optical Engineering; 2005; 100–4.

[Wolpaw, 2002] Wolpaw J. R., Birbaumer N., McFarland D. J., Pfurtscheller G., Vaughan T. M.. “Brain-computer interfaces for communication and control”, *Clinical Neurophysiology*, 113:767-791, 2002

[Wolpaw, 2012] J. R. Wolpaw, “Brain-computer interfaces: progress, problems, and possibilities”, in IHI '12 Proceedings of the 2nd ACM SIGHIT International Health Informatics Symposium, 2012.

[Zander, 2012] T. O. Zander, “Utilizing Brain-Computer Interfaces for Human-Machine Systems”, tese para obtenção do grau acadêmico de Doutor em Ciências Naturais, Universidade Técnica de Berlim, 2012.

APÊNDICE 1:

Projeto de Extensão

UFRGS

Quadro de Avisos Participações Atividades Salões de Extensão Gerência

CARLOS EDUARDO PEREIRA [Sair]

2014 27340

2007

2009

2010

2011

2012

2013

Título: Sistema De Controle Baseado Em Emoções Através De Interface Cérebro Computador

Coordenador: Carlos Eduardo Pereira

Orgão Responsável: Departamento De Engenharia Elétrica

Modalidade: Produção E Publicação

Área Temática: Tecnologia E Produção

Execução e Elaboração de Relatório - EXTENSIONISTA

Participação: Coordenador(a) Geral

Data: De 01/12/2014 a 31/03/2015

[-] - Coordenador(a) Geral

10:19 09/12/2014

APÊNDICE 2:

Termo de Consentimento Livre e Esclarecido

Termo de Consentimento Livre e Esclarecido

Estamos realizando um estudo com o objetivo de investigar o impacto do ambiente sobre o nível de estresse e atenção em adultos.

Contamos com sua colaboração para se expor ao ambiente e responder da melhor forma possível os seguintes instrumentos: Questionário de dados sócio-demográficos, Teste de Atenção Concentrada (AC) e Self Assessment Manikin (SAM).

Sua participação é voluntária e pode ser interrompida a qualquer momento sem que isto acarrete qualquer prejuízo. Esta pesquisa está de acordo com os procedimentos éticos estabelecidos e não apresenta risco à sua saúde física e emocional. Sua identidade será mantida em sigilo e os dados obtidos serão de uso exclusivo para fins de pesquisa, podendo receber os resultados se assim desejar.

A engenheira e pesquisadora Maria Luiza Recena Menezes é responsável por esta pesquisa em nível de Pós-Graduação, sob orientação do Dr. Carlos Eduardo. Quaisquer dúvidas poderão ser esclarecidas através do telefone (51)99599030.

Desde já agradecemos sua participação.

Eu, _____, concordo em participar da pesquisa acima descrita.

Endereço: _____

Telefone: _____ Data: ____/____/____

Assinatura do participante:

Assinatura da pesquisadora:

APÊNDICE 3:

Email comprovando concessão de bolsa do CsF

Cnpq <cgcecx@cnpq.br>
To: 00114045@ufrgs.br
Cc: coeng@cnpq.br, cgect@cnpq.br, dehs@cnpq.br

Mon, Dec 1, 2014 at 5:58 PM

Nome: Maria Luiza Recena Menezes
Processo: 207611/2014-9
Modalidade: Doutorado no Exterior - GDE
Instituição: Halmstad University - Suécia
Chamada: Doutorado no Exterior - GDE

Prezado (a) Senhor(a),

Comunicamos que, com base na recomendação do Comitê de Engenharia Elétrica e Biomédica, a Diretoria do CNPq aprovou a concessão da bolsa discriminada acima pelo período de 36 meses.

Para a implementação da bolsa é necessário preencher e realizar o envio eletrônico do Formulário de Dados Complementares de Bolsa no Exterior que se encontra disponível através da chave de acesso abaixo:

<http://efomento.cnpq.br/efomento/termo?token=WJI24808W13725095430097554411235>

Após o processamento do formulário de Dados Complementares, o CNPq lhe enviará mensagem eletrônica contendo uma chave de acesso para emissão do Termo de Concessão. O CNPq realizará o pagamento dos valores relativos à passagem aérea e auxílio instalação, após a assinatura eletrônica do Termo de Concessão pelo seu representante legal e a respectiva publicação no Diário Oficial da União.

O atendimento a proponentes com dúvidas ou dificuldades no preenchimento do Formulário de Dados Complementares, se dará através do telefone 0800.61.9697, de segunda a sexta-feira, no horário de 8h30 às 18h30, ou através do e-mail atendimento@cnpq.br. No caso de envio de email, solicitamos que sejam incluídos na mensagem nome completo, CPF e número do processo.

Atenciosamente,

Alexandre Garcia Costa da Silva
Coordenador Geral de Programas de Pesquisa em Ciências Exatas
cgcecx@cnpq.br

APÊNDICE 4:

Interpretação de Processos Psicológicos Básicos através de Eletroencefalograma

INTERPRETAÇÃO DE PROCESSOS PSICOLÓGICOS BÁSICOS ATRAVÉS DE ELETROENCEFALOGRAMA

Os sistemas de automação predial e residencial usuais se baseiam em variáveis como temperatura e luminosidade para controle dos ambientes, mesmo que normalmente os objetivos principais deste sistema seja um maior conforto – no caso da automação residencial – e num aumento da produtividade – no caso de automação predial, em especial prédios como escritórios [Greenwell, 2011]. A automação predial de escritórios oferece uma economia de aproximadamente 15% se comparado com prédios não automatizados [EMS, 2014]. Sendo que neste cálculo apenas entram reduções energéticas, sem contar fatores como:

Redução de queixas: um prédio mais confortável reduz queixa dos usuários e isto significa menos tempo resolvendo conflitos e um ambiente de trabalho mais produtivo.

Aumento da produtividade: melhor ventilação do ar aumenta produtividade do trabalho e diminui o tempo em que empregado ficam doentes.

Estima-se que estes fatores equivalem a uma economia de aproximadamente U\$25,00/pé quadrado de área do prédio, sendo destes, U\$5,00 com a diminuição de faltas relativas à doenças e U\$20,00 relativos ao aumento do conforto do usuário e aumento da produtividade [EMS, 2014].

Neste trabalho, usa-se diretamente o estado de estresse e atenção como variáveis para controle do ambiente e aumento do conforto ou produtividade do usuário.

Os conceitos de Estresse e Atenção, embora utilizados somente no texto deste trabalho como “emoção”, para facilitar o entendimento por parte do leitor não ligado a área da psicologia; pertencem à categoria psicológica de “Processos Psicológicos Básicos” e serão explicados mais profundamente a seguir.

1 ESTRESSE

Estresse é um termo amplamente citado atualmente devido a uma crescente preocupação com a qualidade de vida dos indivíduos, da família e do trabalhador, pois a baixa qualidade de vida, muitas vezes diretamente relacionado com doenças, pois exposições contínuas ao estresse causam mudanças emocionais, fisiológicas e comportamentais, que deixam o indivíduo suscetível a doenças como estresse crônico, ansiedade e depressão e, por alterar o sistema autoimune, pode deixar o sujeito suscetível a doenças infecciosas. No caso da saúde do trabalhador, o chamado Estresse Ocupacional é estudado com interesse medicinal e econômico, uma vez que trabalhadores sob estresse tentem a render menos e representam um maior custo para as empresas.

Devido à grande subjetividade, muitos teóricos criaram preceitos para tentar realizar uma classificação científica e assim utilizar o estresse como parâmetro de avaliação em trabalhos, pesquisas e métodos efetivos para programas de controle de estresse. A divisão adotada no texto para abordagem dos conceitos de estresse segue a autora Brenda L. Lyon conforme abordado no primeiro capítulo de seu livro *“Stress, Coping, and Health: A Conceptual Overview”*, que são: estresse como uma resposta, estresse como um estímulo e estresse como uma relação [Brenda, 2012].

O início do conceito de estresse como uma resposta se dá a partir de aspectos fisiológicos. Cannon criou um modelo que aponta a reação fisiológica ao estresse, como uma resposta ao estado de ‘luta ou fuga’, levando o organismo a um estado de emergência através de descargas de adrenalina, incremento dos batimentos cardíacos, do fluxo de sangue e dos níveis de açúcar [Cannon, 1932]. Dando segmento ao conceito, Hans Selye em sua teoria de Síndrome Geral de Adaptação, aborda o estresse como o estado de manifestações de qualquer tipo de síndrome e ele constitui todas as alterações produzidas no sistema biológicos [Selye, 1956].

No foco da abordagem psicológica, o conceito de estresse se baseia não somente na quebra da homeostase, mas na quebra da estabilidade psicológica. Muitos dos conceitos que surgiram estavam em paralelo com os conceitos de Hooke para tensões e deformações. O sistema era tratado basicamente como uma entrada (carga ou necessidade do sistema) e uma saída (tensão, quebra, deformação), ou seja, reação do sistema a determinada entrada. Tal conceito influenciou muitos modelos de estresse na psicologia, seguindo estresse como estímulo. Sob esse preceito, Holmes, juntamente com Masuda e Rahe, criou um método que trata eventos de mudança como agentes estressores na qual o indivíduo deve responder, nessa análise o estresse é uma variável independente do sistema [Holmes, 1967].

O conceito de estresse como uma relação surgiu com Lazarus que desde a apresentação dos conceitos em 1966, teve uma série de revisões em sua teoria (Lazarus e Launier 1978, Lazarus e Folkman 1984, Lazarus 1991). Seu conceito diz respeito ao estresse como uma variável heurística que não pode ser classificada por somente um aspecto e, ao contrário do conceito supracitado, o estresse não está ligado somente a um evento específico, mas sim na interação do indivíduo com agentes estressores e relacionado com o conceito de *coping* (ou enfrentamento, é o esforço cognitivo e comportamental para lidar com situações de dano, ameaça ou de desafio quando não está disponível uma rotina ou uma resposta automática), além de fatores cognitivos e emocionais.

Lazarus define o termo como: ‘constantly changing cognitive and behavioral efforts to manage specific external and/or internal demands that are appraised as taxing or exceeding their sources of the person’ [Lazarus, 1984], ou seja, é a maneira como a pessoa lida com suas relações com o ambiente consideradas estressantes e as emoções que isso gera. Agentes estressores podem ser resultado de frustrações, de insatisfações ou de aborrecimentos que surgem de fatos do cotidiano, mas a melhor definição de fator estressor são mudanças súbitas

na vida, no ambiente ou qualquer coisa relacionada ao indivíduo que teste a sua capacidade de adaptação á nova realidade. [Adriane, 1998]

A principal medida utilizada na determinação das relações do indivíduo com o ambiente é a avaliação cognitiva (Cognitive Appraisal), pois leva em conta características cognitivas específicas do indivíduo e sua forma de interpretar as situações e determina o porquê e como as pessoas se relacionam com o ambiente. A teoria determina 3 tipos de avaliação: primário, secundário e reavaliação. A primária é a ponderação da pessoa a uma situação que a aguarda. Caso não haja recursos disponíveis para superar as exigências, há algumas representações possíveis: potencial dano, dano ocorrido e percepção de ganho e/ou desafio. A situação de dano ou ameaça desencadeia a avaliação secundária que diz respeito a determinação da abordagem ou opções de reações para lidar com a ameaça e a sua eficácia. A última avaliação é a reavaliação, processo contínuo que permite a pessoa observar as avaliações anteriores e determinar como a situação evoluiu, pois a percepção da situação pode ter mudado e passado a ser inofensivo.

As Emoções são uma parte importante do estudo de Lazaros, pois ele acredita que apesar das emoções serem fruto de pensamentos elas também podem ser formadoras de pensamentos. Podendo assim modelar a avaliação do indivíduo frente a uma situação através de emoções, não somente negativas, mas geralmente associado à ansiedade, tristeza, medo e/ou raiva.

Como observado anteriormente, o experimento consiste em avaliar os sinais cerebrais, através do EEG, de um indivíduo frente a mudanças no ambiente em que ele se encontra e classificar as emoções analisadas como calma ou estresse e assim utilizar o resultado como uma nova entrada do sistema. Portanto para a validação dos dados obtidos pelo EEG é necessário escolher um conceito de estresse para trabalhar. Após a avaliação dos conceitos e seus principais autores e levando em consideração as necessidades do experimento descrito,

foi observado que os conceitos de estresse apresentado por Lazarus e seu modelo de estresse baseado tanto em características do ambiente quanto características particulares do indivíduo e sua capacidade de adaptação a mudanças se encaixa melhor que os demais conceitos apresentados.

1.1 ANÁLISE DO ESTRESSE

Em geral, sistemas com integração homem máquina podem ter deficiências na detecção de fatores emocionais do usuário. Tal informação poderia ser utilizada como entrada para o sistema e assim criar um algoritmo personalizado para tomada de decisões ou uma validação para a resposta do sistema.

Para a criação de um sistema de detecção do estado emocional do usuário, o principal problema é a definição de emoção e a diferenciação entre os diversos tipos de estados emocionais. Tendo em vista o foco da análise, o modelo que a ser utilizado neste trabalho é o criado por Russell [Russell, 1980], amplamente utilizado para descrever emoções de forma qualitativa. Ele aponta um modelo 2D cujos eixos se referem à excitação (arousal) e valência (valence) e afirma que a partir desses dois eixos pode-se classificar qualquer tipo de emoção, como mostrado na :




Figura 13 – Modelo Circumplexo de Russel. [Russell, 1980] modificado pela autora.

A excitação, ou *arousal*, é classificada desde inativo (desinteresse, tédio) até ativo (alerta excitação), enquanto a valência, ou *valence*, vai do desagrado (estresse) ao contentamento (calma, felicidade). Dependendo da aplicação, um terceiro eixo pode ser adicionado: Dominância, esse eixo diz respeito ao controle que a pessoa possui da emoção que está vivenciando.

Em geral, os mesmos dados devem ser levantados por mais de um meio a fim de se ter um baixo erro associado à classificação do estado emocional. Seguindo uma outra vertente para a do estresse que utiliza características subjetivas para a classificação do estresse, Masuda, juntamente com Holmes e Rahe [Masuda, 1967], criou uma ferramenta conhecida como *Social Readjustment Rating Scale* (SRRS) que mede o estresse como o ajuste ou

adaptação requerida por certos eventos de mudança. O método é basicamente uma lista de eventos com seus respectivos pesos relativos à quantidade de estresse que tal evento causa. Contudo, a interpretação do resultado final é difícil, pois o método não leva em conta a diferença entre as pessoas analisadas e suas reações particulares aos fatores de estresse.

Utilizando a teoria de Russel, porém, para medir a emoção desejada, basta limitá-la em uma escala que utiliza variáveis relacionadas, como ansiedade, prazer, calma, atenção, entre outras, como mostrado no trabalho de Osgood e sua teoria de diferencial semântico, em que apresenta um modelo que possibilita medir a reação do indivíduo exposto a diversos tipos de estímulos [Osgood, 1957].

Seguindo esta ideia, Peter Lang desenvolveu uma escala não verbal e pictográfica para avaliação de valência e alerta chamado *Self-Assessment Manikin* (SAM) [Lang, 1985], como mostrado na figura abaixo:

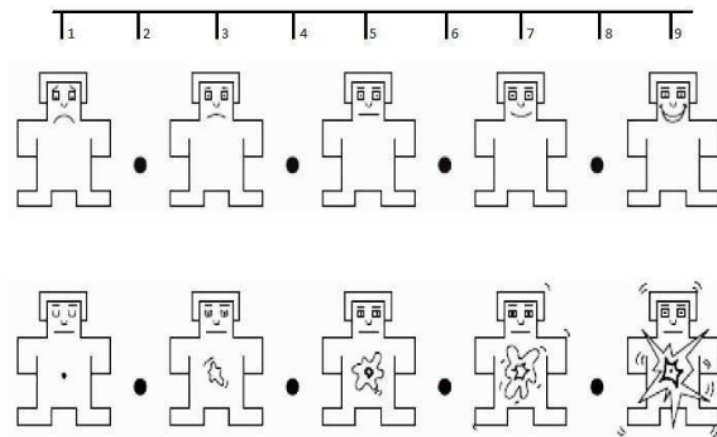


Figura 14 - Escala SAM para os níveis de valência (superior) e alerta (inferior). [Lang, 1985]

Nesta escala, os participantes avaliam a sua resposta emocional a um estímulo assinalando um dos bonecos do desenho ou um dos pontos entre eles, consistindo, então, em uma avaliação de 9 pontos. SAM é um bom instrumento de medição de características psicológicas devido ao fato de ser de fácil implementação, não requerer muitas explicações, nem necessidade de acompanhamento intensivo do avaliador, rápida análise dos dados

obtidos também possui uma ampla gama de aplicações. Para a avaliação do estado emocional, é muito utilizado a auto-avaliação, pois a resposta a agentes estressores envolve avaliações subjetivas. Muitos trabalhos utilizam essa técnica como meio de validação dos resultados obtido, não importando o estímulo utilizado para levantar tais emoções [Hamdi, 2012] [Ramos, 2012] [Koelstra, 2012] [Liu, 2013].

2 ATENÇÃO

Durante o tempo todo recebemos milhares de estímulos e a atenção é o processo cognitivo que desempenha um papel importante no processamento dessa grande quantidade de informações, no sentido de possibilitar definir quais informações serão úteis em determinados momentos. Contudo, não existe somente uma definição de atenção, para Sternberg, *"atenção é o fenômeno pelo qual processamos ativamente uma quantidade limitada de informações do enorme montante de informações disponíveis através de nossos sentidos, de nossas memórias armazenadas e de outros processos cognitivos* [Sternberg, 2000].

A atenção está basicamente dividida em:

- a) Capacidade de focar a atenção, que flutua durante o tempo devido a fatores intrínsecos;
- b) Seleção dos estímulos relevantes para o sujeito e processamento cognitivo, que limita o número de informações que serão processadas para um bom desempenho cognitivo;
- c) Controle seletivo, que define o ato de 'prestar atenção', o que geralmente está associado com um tipo de ação;
- d) Concentração, que diz respeito a capacidade de manter a atenção por um longo período de tempo. Este fator varia com o tempo, normalmente decaindo pois o foco depende do estímulo atrativo da informação e da motivação do sujeito, que vai da excitação até a fadiga.

Embora a atenção tenha a seletividade como seu elemento central, foi definida a existência de diferentes tipos de atenção devido a diferentes características e as consequências atribuídas a tais características. Sternberg classificou a atenção em 4 tipos:

- a) Atenção seletiva, na qual é selecionado a relevância dos estímulos e a concentração se volta para o estímulo desejado;
- b) Vigilância, constante tentativa de detecção de algum estímulo;
- c) Sondagem, procura ativa de um estímulo;
- d) Atenção dividida, distribuição da atenção em mais de um estímulo, a fim de executar mais de uma tarefa ao mesmo tempo.

Dalgalarrondo, ainda apresenta em seu trabalho o conceito de atenção sustentada como a capacidade de manter estável o foco da atenção em um estímulo sem distrações durante a execução de uma tarefa [Dalgalarrondo, 2000]. Na literatura ainda aparece o conceito atenção concentrada de Cambraia [Cambraia, 2003], que consiste em identificar o estímulo relevante e manter o seu foco sobre ele. Cambraia ainda aponta em seu trabalho que em qualquer tarefa que precise ser realizada é necessário que o indivíduo focalizasse a sua atenção concentrada por um maior intervalo de tempo com o objetivo de facilitar o processo de aprendizagem, promovendo o bom aproveitamento e a qualidade de seu trabalho.

Com base nos conceitos vistos, a classificação de atenção que mais se encaixa no trabalho é o de atenção concentrada, pois ele permite avaliar a atenção de um sujeito que recebe estímulos do ambiente e tem a capacidade de se concentrar nele. A melhoria da atenção concentrada pode ajudar na produtividade de empregados, no aprendizado em geral e para parâmetros de seleção psicológica.

2.1 ANÁLISE DA ATENÇÃO

Os testes de atenção continuada são aplicados em diferentes contextos, como, por exemplo, escolas, seleção de pessoal, concursos, teste de obtenção da carteira de motorista e avaliação para porte de armas de fogo. São testes de rápida e simples aplicação e têm como resultado a capacidade do avaliado de manter a sua atenção em determinada tarefa por determinado tempo. A partir disso, psicólogos podem determinar algum tipo de problemas de adaptação ou comportamento.

O primeiro instrumento conhecido em muitos países foi o teste de Toulouse e Pierón que exige grande concentração e resistência a monotonia e seu objetivo é detectar dentre 1.600 símbolos, quadrados associados com riscos em suas laterais, distribuídos em 40 filas o modelo requisitado pelo teste. Tal instrumento deu origem a diversos outros tipos de testes, incluindo os apresentados a seguir.

Os instrumentos focados serão os testes utilizados para a obtenção da carteira de motorista: Teste de AC vetor, D2, TEACO-FF e TACOM. Todos os testes são similares e testam a capacidade de selecionar apenas uma fonte de informação dentre várias em um tempo limitado, mudando somente os tipos de símbolos usados e o tempo de teste.

O Teste AC vetor, bastante utilizado no Brasil, foi criado pelo psicólogo Suzy Cambraia a fim de reavaliar as pessoas que haviam sido submetidas ao teste de atenção Toulouse - Pieron, que era na época o único instrumento disponível no Brasil. Consiste em uma folha de avaliação com 21 linhas e cada uma com 21 símbolos como os mostrados na . No topo da folha está o modelo de símbolo que deve ser assinalado durante o teste. O teste é aplicado em 4 minutos e a sua pontuação consiste no número de erros e omissões subtraídos do número de acertos e a pontuação em percentil e a classificação do resultado (muito inferior, inferior, médio, superior e muito superior) é dada pelo psicólogo através de uma tabela que apresenta valores distribuídos de acordo com a escolaridade do avaliado.



Figura 15 Símbolos usados no teste AC vetor. [Robson, 2013].

O teste TACOM possui 4 tipos de testes A, B, C e D que se diferenciam pela complexidade devido a quantidade de símbolos de distração e a grande similaridade entre os símbolos utilizados. O teste TACOM-A e TACOM-C utilizam placas de regulamentação de trânsito e TACOM-B e TACOM-D utilizam placas de advertência. Todos funcionam da mesma forma, uma folha com símbolos e um modelo que deve ser assinalado na folha durante o teste. A e B são os mais utilizados por serem os mais simples, o teste A segue como modelo placas sem o símbolo de proibido e o B pede placas que tenham somente linhas retas. O tempo de duração do TACOM-A e B é de um minuto e meio e o TACOM-C e D de três minutos.



Figura 16 Símbolos usados no TACOM-A. [Robson, 2013].



Figura 17 Símbolos usados no TACOM-B. [Robson, 2013].

APÊNDICE 5:

Artigos

Proposed Use of Passive Brain-Computer Interface in Smart Environments

Maria Luiza Recena Menezes
Electrical Engineering Department
Universidade Federal do Rio Grande do Sul (UFRGS)
Porto Alegre, RS/Brazil
Email: luiza.menezes@ufrgs.br

Carlos Eduardo Pereira
Electrical Engineering Department
Universidade Federal do Rio Grande do Sul (UFRGS)
Porto Alegre, RS/Brazil
Email: cpereira@ece.ufrgs.br

Abstract—The paper presents an emotion-based control system used to passively control an intelligent environment through Brain Computer Interface. The proposed control system is capable of intelligent adaptation in accordance with the target emotion – attention –, increasing the engagement level of an individual in a given task. The system can be used for therapeutic treatments, or in order to increase productivity or comfort. This proposal lies in interdisciplinary areas such as electrical engineering, computer science, behavioral psychology and assistive technologies. Preliminary results, which are presented in the paper, indicate that this can be a promising approach.

I. INTRODUCTION

The research question considered here is directly linked to the concept of Smart Environments, equipped with sensors, controllers, human-machine interfaces and actuators that are able to interact and adapt to the user. Using the concept of Ubiquitous Computing envisioned by Mark Weiser in [1], such interaction should be done seamlessly.

One main challenge in the accomplishment of this ideal, is on how users can interface with the intelligent system. Within the set of possible interfaces, one use of a direct mean of control is known as brain-computer interface (BCI) [2] [3] [4] [5] [6].

This communication channel, BCI, is generally far from being pervasive: a helmet full of wires that is very uncomfortable to wear and requires too much effort and attention focus to use.

So, in order to reduce the distraction that this interface may cause and to make the interaction more transparent, in this article an emotion-based control system is proposed. Such control can manage intelligent systems in an automated way based on affective computing, i.e. computing that relates to, arises from, or influences emotions [7]. This includes studying and developing systems that can recognize, interpret, process, and adapt to human emotions. The proposed emotion-based control system through BCI is directly linked to intelligent systems, seeking for a seamlessly interaction between user and equipment, aiming to efficiently assist the user in accomplishing a task, rather than distracting the user from the task.

mds

June, 2015

II. METHODOLOGY

The construction of the proposed control system comprises the use of an intelligent system and a helmet for EEG signal acquisition, capable of interpreting the subjects emotional state. This system will be used to control a smart environment (a room equipped with a home automation system), adjusting elements such as air conditioning, opening and closing windows, playing media, and other elements available. For signal acquisition, the Emotiv device, described below, will be used. This device is comfortable for the user because it is light and uses wireless technology.

A. Brain-Computer Interface

Studies in Brain-Computer Interface (BCI) started in the 70s, at UCLA (University of California Los Angeles) [8]. Today, users can control a device only imagining the movement of their hands, for example, without requiring any muscle activity. A Brain-Computer Interface can directly capture the various mental states of the user and turn them into commands for controlling a wheelchair or to select options on a computer menu [9].

This active interaction, however, is still quite costly for users. It requires training and a good amount of concentration and effort to modulate ones brain activity, which ultimately causes the user to focus more on the interaction itself than the proposed activity. For this reason, a system based on passive interaction is proposed, using the EEG as a biosignal sensor to be analyzed, not requiring any user interaction training or attention. In this way, the interaction with the intelligent system will be done transparently.

Nowadays it is possible to obtain devices for EEG signals acquisition with affordable prices and user friendly interfaces. One of the existing low cost BCI hardware available in the Market is the Emotiv [10], which was selected for this work.

Emotiv Systems is an Australian electronic company founded in 2003 that develops brain-computer interfaces based on EEG technology. One of their main products is the Emotiv EPOC EEG wireless helmet Fig. 1 that has 14 channels (AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4.), added to the references Common Mode Sense (CMS, active electrode) and Driven right leg (DRL passive electrode), located in the regions P3 and P4, respectively, shown in Fig. 2. These references offer optimal positioning for accurate spatial resolutions.




Fig. 1. Emotiv EPOC [10]




Fig. 2. Coordinates of the electrodes, according to the International 10-20 System. [11]

The Emotiv EPOC Research Edition provides a suite that uses proprietary algorithms to recognize specific types of emotion, such as Engagement, Instantaneous Excitement, and Long-Term Excitement.

In this article the detected emotion called Engagement is used, which, according to the company, is experienced as alertness and the conscious direction of attention toward task-relevant stimuli and is related to concentration and interest [10].

B. Smart Environment

The Smart Environment used in this study is the fully automated Conference Room of the Brazilian Home Automation Company Home Systems. The automation system uses a central control unit called Systembox (Fig. 3) which is basically a computer with Linux operating system, responsible for controlling the Home Systems network (HSNET proprietary protocol that works at the physical layer RS -485) and acts on lighting circuits, air conditioning systems, entertainment systems, among other devices that may be available in the environment.

The fully automated conference room used has six separated lighting circuits, motorized awning and curtains, two air



Fig. 3. Systembox

conditioners, a sound system and five monitors; that can be used to vary not only intensity, but the type of luminosity, such as natural sun light, dichroic or incandescent artificial lighting; temperature, sound and image.

C. Control System

In order to control the Smart Environment, a control system was developed using adaptive algorithms to change the room scenarios in order to increase the users engagement level.

The Control System uses genetic algorithm to adapt the environment in order to maximize the users attention level. Genetic algorithms are good solutions for problems where there is insufficient knowledge about or high complexity of the system. According to [12], you can find best solutions into a given domain and very reasonably solutions to a complex problem, in a quickly and efficient way, as in the case addressed in this article, where it is not known how and what environmental equipment or configuration will impact on the users engagement level.

In the proposed strategy, initially a random set of initial scenarios are created. This first generation of scenarios is then tested for the first three minutes each and the engagement level of the user is collected and used to classify the scenarios, creating an elite, with the scenarios that provided higher level of engagement.

The elite will then create the next generations using genetic algorithm techniques, such as cross over and mutation, creating child scenarios that typically share many of the parents characteristics, enhancing the probability of creating scenarios that will also provide a high level of engagement and updating the elite set of scenarios.

The proposed system's architecture can be seen in Fig. 4 and is mainly divided in three different modules: EEG Signal capture, Control module and Home Automation module.

The EEG Signal module corresponds to the Emotiv EPOC helmet and its given signal processing into the users Engagement level. The Home Systems module is the room automation and the Control module is the adaptive algorithm that analyzes the users Engagement level and adapts the room scenario accordingly.

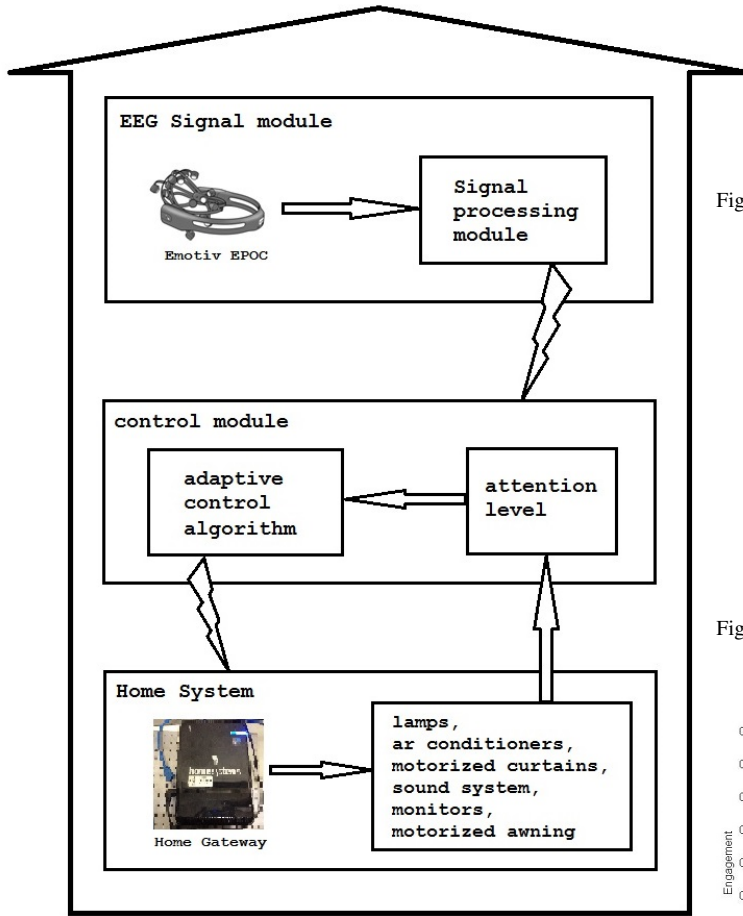


Fig. 4. System Architecture

III. TESTS AND RESULTS

In order to validate, preliminary tests were conducted with six subjects, named A, B, C, D, E and F. All subjects were adult volunteers who signed an agreement term. The socio-economic data of the volunteers tested until the moment are:

- Subject A: male, 23 years old, undergraduation student.
- Subject B: male, 26 years old, incomplete master degree.
- Subject C: female, 34 years old, complete graduation degree.
- Subject D: male, 26 years old, incomplete master degree.
- Subject E: female, 31 years old, incomplete master degree.
- Subject F: male, 60 years old, PhD.

During the tests the individuals were asked to perform twelve attention tests like the ones used to accomplish driving license tests in Brazil, for about 40 minutes.



Fig. 5. TACOM test



Fig. 6. Subject performing a Control Test




Fig. 7. Control Test Results for Subject A

The tests mainly consist on marking where a given sequence of four street signs, like in Fig. 5, appears in a matrix of 264 symbols. This test is called TACOM (Concentration Attention Test) [13] and aims to be a repetitive task that requires a good amount of attention, during 40 minutes.

Two tests were performed with each individual, a Control Test and an Experimental Test. In Fig. 6 we can see a subject performing the Control Test using the Emotiv EPOC helmet and the system proposed in this article.

A. Control Test

Control Tests were performed in order to collect data that could allow to analyse changes in the subject's engagement level during the execution of repetitive tasks without using the proposed control system. These tests were performed with volunteers, A, B, D and F, at the Home Systems Conference Room. The room were quite and illuminated during all the tests and the subjects were asked to adjust the air conditioning to their preferred temperature, so they would feel comfortable.

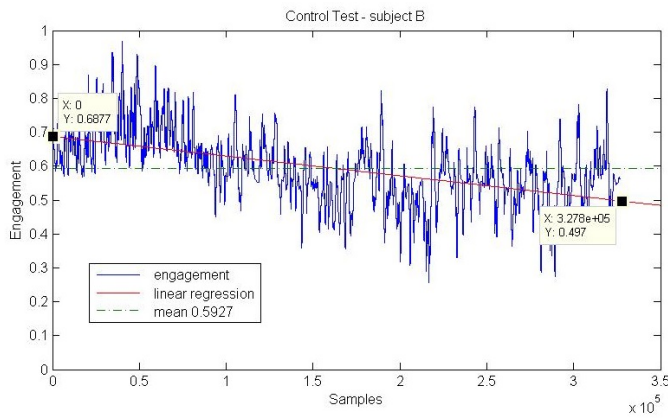


Fig. 8. Control Test Results for Subject B




Fig. 9. Control Test Results for Subject D




Fig. 10. Control Test Results for Subject F

Figs. 7, 8, 9 and 10 present the measured engagement levels for each individual. As it can be observed, for all tests two phases can be identified: first there is an excitement moment at the beginning of the task, and as the experiment goes on the subjects tend to get bored and their attention level goes down, as can be seen in the linear approximation represented by the red line.

A decrease of 0.7074 of the engagement level to 0.5642 for subject A can be observed in Fig 4, representing a decrease of approximately 20.24%. For subject B, the values fall from 0.6877 to 0.497, representing a decrease of 27.73% of the

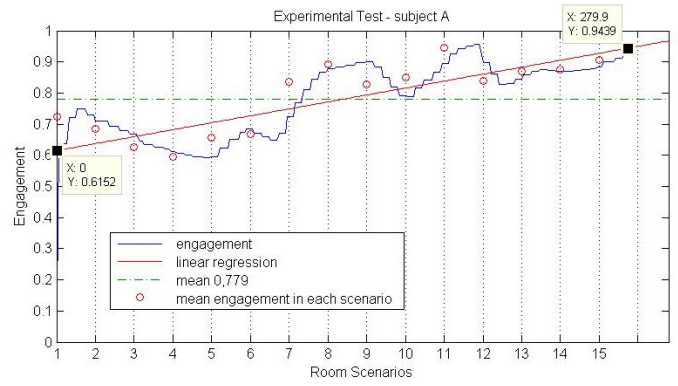


Fig. 11. Experimental Test Results for Subject A




Fig. 12. Experimental Test Results for Subject B

subjects engagement within the performed task. As for subject D, the values range from 0.7212 to 0.58854, down 18.83%, and for subject F, from 0.7233 to 0.5689, equivalent to a decrease of 21.35%.

In average, for all tests, 22% reduction in the engagement level could be observed, even for an activity with a short duration (about 40 minutes). Such decrease can negatively impact the subjects performance and productivity. Including the risk of accidents in tasks such as flight controller, piloting, driving and heavy machine operation.

B. Experimental Test

The Experimental Tests were performed in the same Conference Room, but using the Emotiv EPOC system and a control system developed using the proposed adaptive algorithm to control the Smart Environment, changing the room scenarios in order to increase the users engagement level. The developed system was able to control the entire automation system of the conference room, constituted by six lighting circuits, five motorized curtains and an awning, two air conditioners and a media system with six monitors and stereo sound. Five subjects performed the Experimental Tests, A, B, C, D and E.

The obtained results are obtained from Figs.11, 12, 13, 14 and 15. As it can be observed in the graphs, the Experimental Test show results very distinct to the Control Tests: instead of a decrease, an increase in the engagement level was observed towards the end of the experiment. Meaning that, even if the task is tedious over time, as shown in the results of Control




Fig. 13. Experimental Test Results for Subject C




Fig. 14. Experimental Test Results for Subject D




Fig. 15. Experimental Test Results for Subject E

Tests, the system could not only maintain but increase the level of engagement of the subjects. This is evident when analyzing the linear regression, represented by the red line.

An increase of the engagement level from 0.62152 to 0.9434, equivalent to 53.35% for subject A can be observed in Fig. 11. For subject B an increase from 0.6175 to 0.7011, or 13.54% of engagement level, ; from 0.6508 to 0.9269 or 42% for subject C. As for subject D, the engagement level increases from 0.6003 to 0.6208, equivalent of as increase of only 3.41%, but for subject E again a significative increase of 45.71% in the engagement level from 0.6392 to 0.9314. Although the Experimental Tests values have a larger variation than the Control Tests, in all cases an increase in the level of

engagement from 3.41% to 45.71% was observed, totaling an average increase of 31.6% of the engagement level for all the subjects tested.

If we analyze the average engagement for each scenario, represented in the graphs by red circles, an increase of 0.7248 to 0.9048 can be observed for subject A; of 0.7072 to 0.7510 for subject B; of 0.7267 to 0.8616 for subject C; of 0.7347 to 0.7551 for subject D and 0.70 to 0.9045 for subject E. That is, comparing the first scenario to the last one, remembering that if we analyze the results of Control Tests, the first few minutes tend to have a higher level of engagement, we can notice an increase of 24.83%, 6.19%, 18.56%, 2.76% and 29.21% respectively. So, contrary to the Control Test, a mean increase of 16.31% can be noticed when using the system proposed in this article.

Subjects A, B and D participated in both the Control and Experimental Tests and comparing the average engagement of these subjects during the whole period of each test, represented in the graphs by the dashed green lines, an increase of 0.636 to 0.779 or 22.49% can be observed for subject A and of 0.5927 to 0.6593 or 11.24% for subject B during the 40 min equivalent to the execution of the tasks. As for subject D, there is a decrease in average engagement from 0.6534 to 0.6106, or 6.55%. But it is important to note that the subject D had begun the Experimental Test with an engagement level 16.76% lower: the Control Test started with an engagement level 0.7212 and the Experimental Test with only 0.6003 and that emotional states as level of engagement in tasks may depend on psychological and individual factors and are not only influenced by environmental elements, such the ones analyzed in this study. As we can see form the graphs of subjects A and B, they also started the Experimental Test with initial engagement levels lower by 13.03% and 10.21% if compared with the beginning of the Control Tests, and ended the Experimental Tests with an engagement level bigger by 67.30% and 41.07% respectively.

IV. CONCLUSIONS AND FUTURE WORK POSSIBILITIES

In this work it was shown that it is possible to close a loop to control a Smart Environment not only using environmental variables, such as temperature and light in order to increase the comfort of the user, but also the users' mental states.

Generally, when doing a repetitive task for some time, the engagement level of human beings tend to fall because the attention depends on attractiveness of the stimuli [14]. With the use of the proposed control systems we were able not only to adapt the environment to keep the engagement level of the subjects, but even make a significant gain on the engagement level.

This increased level of engagement suggests not only the close relationship of the emotional state of the individual with the environment that surrounds it, serving as support for ergonomics theories and well-being at work, but can also be actively used in systems that assist in tasks that the individual's attention is crucial, as tasks in factories, driving trucks, flight controllers, learning in the classroom, among others. Another possible application would be the use of the proposed systems in therapies for individuals with attention difficulties such

as Attention Deficit Disorder with Hyperactivity (ADHD) or autism. Those are planned in our future work activities.

Concerning the use of genetic algorithm to control intelligent environments with closed loop, we can see that the algorithm performed well for this problem and succeeded to adjust itself after approximately 20 minutes, when the individual's engagement level started to drop, creating good solutions after running between two and seven scenarios.

For a more consistent statistical analysis of both the system and the relationship between the environment and the subject's attention level, it is necessary to test it with a larger and more heterogeneous group of individuals, with a wide diversity of educational, financial, cultural and even medical backgrounds.

ACKNOWLEDGMENT

The authors would like to thank the Home Systems Company, as well as the Brazilian research agencies Capes (project PROCAD), FINEP (project CRIAI) and CNPq for their financial support.

REFERENCES

- [1] M. Weiser, R. Gold, J. S. Brown, *The origins of ubiquitous computing research at PARC in the late 1980s*. IBM Systems Journal, vol 38, num 4, 1999.
- [2] J. R. Wolpaw, *Brain-computer interfaces: progress, problems, and possibilities*. IHI '12 Proceedings of the 2nd ACM SIGHIT International Health Informatics Symposium, 2012.
- [3] G. Ruscher, F. Kruger, S. Bader, T. Kirste, *Controlling Smart Environments using Brain Computer Interface*. Proceedings of the 2nd Workshop on Semantic Models for Adaptive Interactive Systems, SEMAIS11, 2011.
- [4] S. Lu, T. Chen, L. Ko, *EEG-based Brain-computer Interface for Smart Living Environmental Auto-adjustment*. Journal of Medical and Biological Engineering, 2010.
- [5] B. Z. Allison, *Toward ubiquitous BCIs*. Bernhard Graimann, Gert Pfurtscheller, and Brendan Allison, editors, Brain-Computer Interfaces, The Frontiers Collection, pages 357-387. Springer Berlin Heidelberg, 2010.
- [6] A. Nijholt and D. Tan, *Brain-computer interfacing for intelligent systems*. IEEE Intelligent Systems, 23(3):72-72, 2008.
- [7] R. W. Picard, *Affective Computing*. MIT Technical Report #321, 1995.
- [8] J. J. Vidal, *Toward Direct Brain-Computer Communication*. Annual Review of biophysics and Bioengineering Vol. 2: 157-180, 1973.
- [9] A. Ferreira, T. F. Bastos-Filho, M. Sarcinelli-Filho, J. L. M. Sanches, J. Garcia and M. Quintas, *Improvements of a Brain-Computer Interface Applied to a Robotic Wheelchair*. Biomedical Engineering Systems and Technologies Communications in Computer and Information Science Volume 52, pp 64-73, 2010.
- [10] *Emotiv Software Research Kit User Manual*. Emotiv Systems, 2014.
- [11] *Emotiv Forums - Number of electrodes and number of measurements channels*. <https://emotiv.com/forum/forum12/topic2343/messages/>. Emotiv Systems, 2012.
- [12] R. Malhotra, N Singh, and Y. Singh, *Emotiv Software Research Kit User Manual*. Emotiv Systems, 2014.
- [13] F. J. M. Rueda, *Evidências de validade para o Teste de Atenção Concentrada TEACO-FF*. Tese (doutorado) Programa de Ps-Graduação Stricto Sensu em Psicologia da Universidade So Francisco. Orientado de: Fermino Fernandes Sisto. Itatiba, 2009.
- [14] R. J. Sternberg, *Psicologia Cognitiva*. Porto Alegre, Artmed, 2000.

EVALUATION OF EMOTIONAL COMPONENTS TO IMPROVE SSVEP-BCI

ANIBAL COTRINA*, ALESSANDRO B. BENEVIDES*, ANDRE FERREIRA*, TEODIANO BASTOS*, MARIA L. R. MENEZES†, CARLOS E. PEREIRA†, JAVIER CASTILLO‡

**Post-Graduate Program of Electrical Engineering, Federal University of Espirito Santo (UFES),
Av. Fernando Ferrari 514, Vitoria, Brazil*

†*Post-Graduate Program of Electrical Engineering, Federal University of Rio Grande do Sul (UFRGS),
Av. Osvaldo Aranha 103, Porto Alegre-RS, Brazil*

‡*Post-Graduate Program of Electronics Engineering, University del Valle (UNIVALLE),
Av. Paso Ancho 1300, Cali, Colombia*

Emails: anibal.atencio@ufes.br, sandro@ele.ufes.br, andrefer@ele.ufes.br,
tfbastos@ele.ufes.br, luiza.menezes@ufrgs.br, cpereira@ece.ufrgs.br,
javier.castillo@correounivalle.edu.co

Abstract— Brain-computer interface (BCI) provides a direct connection between the user's brain signals and a computer, generating an alternative channel of communication that does not involve the traditional way as muscles and nerves. Recent decades have seen BCI applications as a novel and promising new channel of communication, control and entertainment for disabled and healthy people. However, BCI technology can be prone to errors due to the basic emotional state of the user: the performance of reactive and active BCIs decreases when user becomes stressed or bored, for example. Passive-BCI is a recent approach that fuses BCI technology with cognitive monitoring, providing valuable information about the user's intentions, the situational interpretations and mainly the emotional state. In order to improve the accuracy of BCIs, subjects can perform simultaneous or sequential tasks typically used in two BCI approaches in a hybrid condition that combines both BCIs. In this work, a system composed of a passive-BCI co-working with a reactive-BCI, with the aim of improving the performance of the reactive-BCI is proposed. Thus the possibility of adjusting recognition characteristics of SSVEP-BCIs using a passive-BCI output is evaluated.

Keywords— Emotional components, passive-BCI, reactive-BCI, SSVEP-based BCI, asymmetry index

1 Introduction

A Brain-Computer Interface (BCI) provides a direct connection between the user's brain signals and a computer, generating an alternative channel of communication that does not involve the traditional way as muscles and nerves (Wolpaw et al., 2002). A BCI defines a new input modality for human-machine interaction (HMI), which could substitute or add up to other input modalities like manual input. Distinct mental states can be associated with physical actions, such as sending the command "turn right" to a wheelchair robot just imagining the movement of the right hand (Ferreira et al., 2010). Although presenting many advantages, most current BCIs are highly susceptible to emotional states experienced by its users, since emotions indicate what is important and what you care about (Picard, 2010). However, the BCIs have the advantage of direct access to brain activity, being able to provide meaningful information about the user's emotional state. Such information may be used in two forms (Molina et al., 2009): 1) Knowledge of the influence of emotional state in the patterns of brain activity allows the BCI to adapt their recognition algorithms so that the user's intent is still interpreted correctly despite signal changes induced by the emotional state of the user. 2) The ability to correctly recognize emotions in BCIs that can be used to provide the user a more natural and intuitive way to

control the BCI in affective modulation. In the present work, a passive-BCI able to co-work with a specific reactive-BCI, is evaluated in order to improve the performance of the BCI by evaluating emotional components. Experimental results are shown and the proposal seems effective.

1.1 BCI categorization

According to the categorization proposed in (Zander and Kothe, 2011), active-BCIs have outputs derived from brain activity, which is directly and consciously controlled by the user, therefore being independent of external events (Wolpaw et al., 1991); and reactive-BCIs have outputs derived from brain activity arising in reaction to external stimulation, which is indirectly modulated by the user (Muller, Celeste, Bastos and Sarcinelli, 2010). Passive-BCIs have outputs derived from implicit information on the actual user mental state, which arises arbitrarily without the purpose of voluntary control. The first two categories derive their outputs for controlling an application and the last one derive its output to improve human-environment interaction or human-machine interaction.

1.2 Reactive-BCI based on SSVEP

An event related potential (ERP) used in many BCI systems is the visual evoked response (VEP).




Figure 1: Schematic overview of a passive-reactive Hybrid BCI.

This potential, occurring involuntarily in response to a visual stimulus, can be measured over occipital brain areas. Steady-State VEP (SSVEP) is a periodic response elicited by repetitive presentation of a visual stimulus, with the same fundamental frequency as that of the flickering stimulus as well as its harmonics (Middendorf et al., 2000), (Sutter, 1992), (Muller, Bastos and Sarcinelli, 2010). In a typical SSVEP-based BCI system, multiple stimuli flickering at different frequencies are shown to the subject. The increase in the SSVEP amplitude can be detected in the electroencephalographic (EEG) signal, which are further processed, classified and translated into control commands (Wang et al., 2006), (Gao et al., 2003), (Cheng et al., 2002), (Muller-Putz et al., 2005).

1.3 Passive-BCI based on Emotion Components

A Passive-BCI is a recent approach that fuses BCI technology with cognitive monitoring, providing the computer information about the user's intentions, the situational interpretations and mainly the emotional state. Emotions can be defined as a subjective, conscious experience characterized primarily by psycho-physiological expressions, biological reactions, and mental state (Kleinginna and Kleinginna, 1981). Affective computing studies techniques that recognize, interpret, and process human emotions (Picard, 2003). Asymmetry of the frontal lobe, given by the variation of the alpha band power of the EEG signals, is significantly associated with human emotional states; in which, high alpha band power in the right hemisphere is associated to negative emotional states while high power in the left hemisphere is associated with positive emotional states (Davidson, 1992).

1.4 Hybrid BCI

In order to improve the accuracy of BCIs, subjects can perform simultaneous or sequential tasks typically used in two BCI approaches. A hybrid BCI is assembled by a collection of systems that work together to provide a communication pathway between the human brain and a computer (machine). A hybrid BCI based on two different could combines active, reactive, and passive BCIs.

1.5 Assessment

Recently, a new perspective on BCI has emerged (Nijboer et al., 2009), which suggests that not only voluntary self-regulated signals can be used as input, but also involuntary signals might tell us something about the state of the BCI user (e.g. the emotional and cognitive state). It is assumed that relevant features from these involuntary signals (also referred to as passive signals) can be extracted and used to adapt the recognition algorithms of the BCI. In sum, the knowledge of the emotional state influence in brain activity patterns allows the BCI to adapt its recognition algorithms with the aim that the user intentions would be interpreted efficiently.

In the present work, a passive-BCI monitors emotional component of the BCI user with the aim improving a SSVEP-BCI performance is evaluated. The increase of the SSVEP amplitude can be detected in the EEG signals and translated into control commands. However, stimuli flickering could cause a stress-related emotional state or loss of attention, as reported in (Muller, Bastos and Sarcinelli, 2010). In order to accommodate this issue, we propose a system in which passive-BCI co-works with a SSVEP-BCI, whose schematic overview is shown in Figure 1. The SSVEP-BCI detects the elicited evoked potential from EEG signals registered at occipital electrodes. At the same time, the passive-BCI identifies emotional components of user mental state from EEG signals on the frontal brain region. The system is then switched to a "stress mode" when specific component of emotional state, like stress, is detected and consequently the success rate of SSVEP decreases. In this mode, the passive-BCI output modules the reactive-BCI characteristics aiming to maintain the success rate.

EEG signals of one subject were employed. Two flickering stimuli were used to evoke the SSVEP potential. Spectral density of signal is computed using Hilbert Transform. Two ways of become the SSVEP more robust were evaluated: adjusting the amplitude response and adjusting the frequency response. Asymmetry index computed of the alpha band from frontal electrodes were used to evaluate the emotional state of the subject.

2 Methods

2.1 Subjects

Due to the preliminary aspects of this work, the evaluation was performed with only one volunteer with no previous history of neurological or psychiatric disorder. The experiment was taken with the understanding and written consent of the subject, who gave informed consent. This study was approved by the research ethics committee of the Federal University of Espirito Santo (Brazil).

2.2 Stimulus

Two stimuli, emitted by two 5×7 LED arrangements flickering at 5.6 Hz and 6.4 Hz were displayed simultaneously. The subject seated in front of the SSVEP box and was asked to gaze on the target LED for 17 s after a beep tone, then asked to close his eyes for 5 s, ending the trial after a second beep tone. The EEG signal was recorded between seconds 5 and 17 of the trial. Two sessions of 10 trials were performed during the experiment.

2.3 Signal acquisition

BrainNet36 (BNT) was the device used for EEG acquisition with a cap of integrated wet electrodes. EEG signals from 19 electrodes positioned according to the international 10-20 system were registered (Figure 2). The grounding electrode was positioned on the subject forehead and the bi-auricular reference was adopted. The EEG was acquired at a sampling rate of 200 Hz. BNT is a device for clinical purposes that does not export data in on-line mode. Therefore, a TCP-IP based sniffer programmed in ANSI C was developed to export these data, allowing the on-line processing, which was performed on MATLAB.




Figure 2: International 10-20 system for electrode placement.

2.4 Preprocessing

Signals were filtered employing an elliptic band-pass (4 Hz - 50 Hz). Signals from O1 and O2 electrodes were used to verify the SSVEP responses; other channels were employed to perform common

average reference (CAR) spatial filtering, in order to reduce the correlation between channels originated by external noise. CAR filter is given by:

$$\mu_i^{CAR} = \mu_i^{ER} - \frac{1}{n} \sum_{j=1}^n \mu_j^{ER}, \quad (1)$$

where μ_i^{CAR} is the filtered signal and μ_i^{ER} is the potential between the i -th electrode and the reference electrode.

2.5 Spectral density of an analytical signal

In rhythm modulation-based BCIs, the input of a BCI system is the modulated brain rhythms with embedded control intentions. Brain rhythm modulation is realized by executing task-related activities, e.g., attending to one of several visual stimuli. Demodulation of brain rhythms can extract the embedded information, which will be converted into a control signal. The brain rhythm modulations could be sorted into the following three classes: power modulation, frequency modulation, and phase modulation. For a signal $s(t)$, its analytical signal $g(t)$ is a complex function defined as:

$$g(t) = s(t) + j\hat{s}(t), \quad (2)$$

where $\hat{s}(t)$ is the Hilbert transform of $s(t)$, defined as:

$$\hat{s}(t) = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{s(\tau)}{t - \tau} d\tau. \quad (3)$$

Due to the $\hat{s}(t)$ have the same energy as $s(t)$, energy spectral density is given by:

$$P(f) = \frac{1}{4} \hat{G}(f) \hat{G}(f)^*, \quad (4)$$

where $G(f)$ is the Fourier transform of $g(t)$ and $\hat{G}(f)^*$ denotes the complex conjugate of $G(f)$. The analytic signal has no power at negative frequencies.

2.6 Adjusting of Amplitude of the Response

The amplitude of the SSVEP response of the EEG signals depends on the quantity of samples employed to perform the FFT transform. Normalized amplitude spectrum is calculated by:

$$P^{norm}(f) = \frac{P(f)}{\sum P(f)}, \quad (5)$$

where $P(f)$ is spectral energy density of the analytical signal. $\sum (Pf)$ denotes a summation over the total frequency points of a spectrum. The response becomes more robust when more samples are considered.

2.7 Adjusting the Frequency of the Response

The frequency corresponding to amplitude of peaks in the frequency domain is compared with stimuli flickering frequencies to determine which stimulus was chosen by the subject. However, it is common that the frequency of the peak (fundamental or harmonic) is slightly different to the stimulus frequency, or other peaks appear at frequency domain. To solve this problem, Power Spectral Density Analysis (PSDA), which involves processing in the frequency domain, was used to perform automatic recognition of SSVEP responses of the target stimulus.

If there is a peak in the same frequency of the stimulus, the error will be zero. If the error is not zero, the ratio will be small if the amplitude is high, and at different frequencies, the error will be small. In this case, f_k and f_h could be adjusted. The power spectral density analysis around the stimulus frequency is given by:

$$S_k = \frac{mP(f_k)}{\sum_{i=-m/2}^{m/2} P(f_k + if_r)}, \quad (6)$$

usually expressed in dB; m is number of samples around the stimulus frequency, and f_r is the frequency resolution which depends on the Fourier transformation. $P(f_k + if_r)$ is the power density around the stimulus frequency. In this study $m = 60$ was considered.

So, given k -th stimulus frequency f_k , the closer peak response frequency f_h , and the magnitude of the peak frequency $P(f_k)$, the following ratio of proportion was used:

$$Ratio = \frac{|f_k - f_h|}{P(f_k)}. \quad (7)$$

2.8 Asymmetry index

The index of asymmetry of alpha band can be computed by comparing the power of contralateral frontal electrodes, in order to identify component of stress-related emotional states. Frontal cortex asymmetry has provided evidence that greater right frontal activity seems to be more highly related to negative emotional states. This index, that has a value between -1 and 1, can be employed as a switch to shift the system to the "stress mode" (Davidson, 1992). The most commonly reported of the indexes is computed by subtracting the left hemisphere alpha power (P_{lh}) from the right hemisphere alpha power (P_{rh}):

$$Assymetry = \frac{P_{lh} - P_{rh}}{P_{lh} + P_{rh}},$$

where P_{lh} and P_{rh} were estimated by computing the Power Spectral Density.

3 Results

As mentioned above, the subject was asked to choose one specific target between two stimuli flickering at 5.6 Hz and 6.4 Hz. A particular mental state, such as stress, can affect the frequency or the amplitude of this potential. Therefore, a technique based on adjusting the number of samples employed to perform the FFT transform and/or a technique based on the enlarge the ratio of searching of the peak response to compensate the frequency and amplitude of evoked potentials, respectively. Hence, elicited SSVEP potential response and asymmetry index when the subject was stimulated emotionally are presented in this section.

3.1 Elicited SSVEP potential results

Hilbert transform was used to compute the SSVEP spectral responses shown in the Figures 3 and 4.

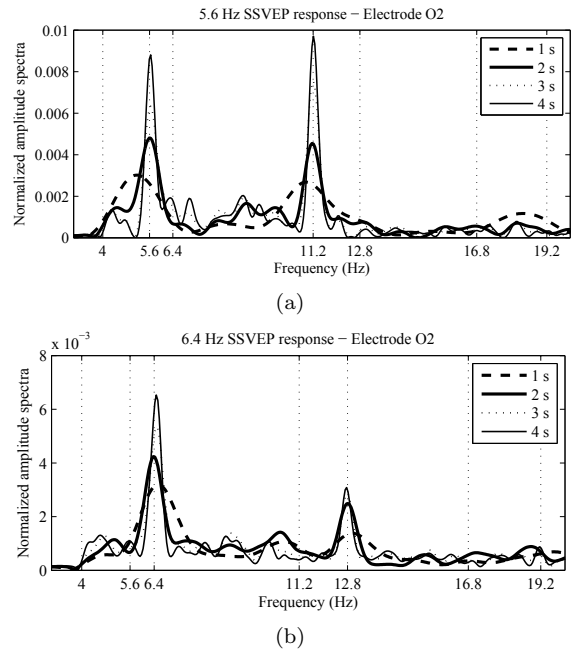


Figure 3: Normalized amplitude spectra corresponding to different length. (a) For the stimulus flickering with 5.6 Hz. (b) For the stimulus flickering with 6.4 Hz.

Figures 3(a) and 3(b) show the normalized amplitude spectra corresponding to four different data lengths. If the data length is $n = 200$ samples, corresponding to 1 s of signal; then, the amplitude of the response is weak. The response becomes more robust when more samples are considered. Thus, SSVEP response peak will be strong when $n = 800$ samples that corresponds to 4 s of signal. Hence, responses that were computed with few data are affected with changes in the subject mental states. In this sense, one way to maintain




Figure 4: Normalized amplitude spectra SSVEP responses of ten trials (gray) and their the average (black). (a) For the stimulus flickering with 5.6 Hz. (b) For the stimulus flickering with 6.4 Hz.

the SSVEP potential amplitude could be achieved through adjusting the data length of each trial. The number of samples increases the data and the processing time, so this assessment maintains the success rate, but reduces the information transfer rate (ITR). In practice, the length of the samples are determined by a window function.

Figures 4(a) and 4(b) show the normalized amplitude spectra of the SSVEP response of the electrode O2 corresponding to ten trials (gray curves) and the average curve (black curve). The response to stimulus flickering with 5.6 Hz presents weaker amplitude than its second harmonic frequency (11.2 Hz); concurrently the peak at 5.6 Hz is wider. In cases like this, the peak detection using a threshold becomes inefficient. Thus, adjusting of frequency of the response method can be a good alternative. On the other hand, for 6.4 Hz the SSVEP response presents peaks at fundamental and second and third harmonic frequencies.

Topographic maps of all position of the subject's scalp is showed in the Figure: The two stimulation frequencies (5.6 Hz and 6.4 Hz) and the second (11.2 Hz and 12.8) and third (16.8 Hz and 19.2 Hz) harmonics of each. Note that these maps present data derived with different frequencies. It is clear from both stimulation frequencies the topographies show occipital activity characteristic of SSVEP. Only the topography of second harmonic presents occipital activity on the right side. Finally, topography of the third harmonic presents slight occipital activity.




Figure 5: Topographic maps of SSVEP response over six frequencies. (a) 5.6 Hz with their second and third harmonics. (b) 6.4 Hz with their second and third harmonics.

3.2 Asymmetry Index results

The alpha power of the contralateral electrodes F3 and F4 was estimated by computing the Power Spectral Density based on the modified periodogram. The absolute value of Fast Fourier Transformation provides the amount of information contained at a given frequency, and the square of the absolute value is considered the power of the signal. In order to compute the asymmetry of alpha band power at frontal lobe from contralateral electrodes F3 and F4, One-minute signal was considered to the analysis. One-second segments the trial signal were taken into account to perform the analysis; thus, for each trial, the CAR filtering, the wavelet frequency band decomposition, and the frequency band power estimation were performed. Computing the asymmetry was realized when subject was listening to unpleasant sounds while he was asked to gaze at an SSVEP stimulus. Four types of sound stimuli were selected to elicit an emotional state: 1) Nothing, 2) ruler on a bottle, 3) dental drill, and 4) baby laughing. In (Kumar et al., 2012), stimuli (2) and 4) were rated as one of the most unpleasant sounds and the of the least unpleasant sounds, respectively.

The box plot was used to show the distribution of results (See Figure 6). It can be seen that, in all cases the value of the median of the index was negative. However, a clear difference between the sounds 2) and 4) is showed. It is evident that the results shows that the sound 3) has the least index for the subject. It indicates that a stress re-

lated emotional state was elicited on the subject, because high alpha band power in the right hemisphere is associated to negative emotional states while high power in the left hemisphere is associated to positive emotional states. Finally, the effect of the stimulus 4) was the same that the “stimulus nothing”.




Figure 6: boxplot with 90th percentile (10% and 90%) of the results of asymmetry index computing.

4 Conclusion

The method of recognizing the fundamental frequency of an SSVEP elicited response described in Sections 2.6 and 2.7 can maintain the error rate by adjusting two parameters f_k and f_h , that determine the window width around the stimulus frequency. Thus, it can be concluded that the searching limits of evoked potential peaks and the number of samples used to compute the FFT transformation can be adjusted to improve the search of the SSVEP potential’s frequency. Those results are promising because they show that passive-BCIs could improve or maintain the accuracy rate despite of BCI user’s emotional states, such as stress. In the Section 2.8, although the assessment reduces the information transfer rate, it maintains the error rate of the reactive-BCI. Since the asymmetry or energy in alpha band can be used to identify emotional components of the BCI user, the next step in this work will be to integrate the passive-BCI and the reactive-BCI showed in the Figure 1 in order to develop a more robust BCI.

The index is used to modulate the reactive-BCI characteristics by using two adjustable parameters using a specific emotional component such as asymmetry index: 1) the number of samples to compute the FFT Transform and 2) the search range around the stimulus frequency at the spectral domain. Although the ITR decreases because the first adjustment increases the samples and the time between two trials, and the second adjustment increases the SSVEP peak searching

time, this assessment could improve the interaction between the user and the reactive-BCI because it maintains the success rate.

Alpha power has been found to be more reliably related to task performance compared to other frequency bands, when the tasks carefully match on psychometric properties. Alpha power asymmetry may be considered a gradient of power that exists between the two homologous electrodes in the pair, with the slope of the gradient being towards the electrode with the greatest amount of power in this frequency band.

The next step in this research will be to compute the asymmetry index and to propose a linear equation that ties in this index with SSVEP-based BCI parameters. It is well known that BCIs, like SSVEP-based BCIs, are not suitable for all users (Guger et al., 2012). The causes for this inefficiency have not yet been satisfactorily described. Few studies exist that explicitly investigated the predictive value of internal (user related) and external (BCI related) factors on the BCI performance. The accuracy of SSVEP can be monitored by a Reclassifier, which evaluate a number of consecutive results. The Re-classifier is able to activate a switch if the accuracy is not being recovered. In this case, an autonomous interface can be implemented in order to take control of the machine. Commands like “Stop the machine”, “Return to previous stage” or “Return to the starting point” can be sent to a control system, as shown in the Figure 7.

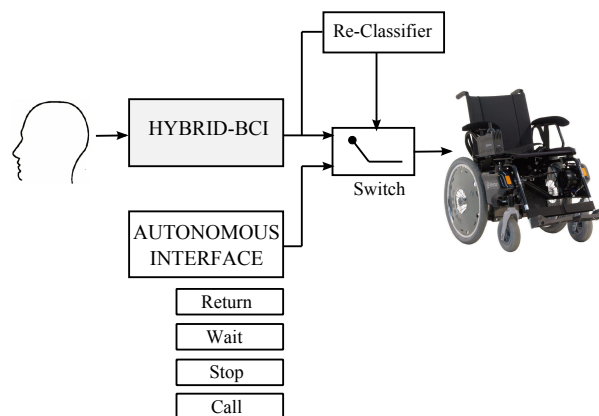


Figure 7: Schematic overview human-machine interface composed by a passive-reactive hybrid BCI and an autonomous interface.

5 Acknowledgment

The authors would like to acknowledge the financial funding from FAPES/CNPq (Process 53666038/2011), and thank CAPES agency for scholarship support.

References

- Cheng, M., Gao, X., Gao, S. and Xu, D. (2002). Design and implementation of a brain-computer interface with high transfer rates, *IEEE Transactions on Biomedical Engineering* **49**.
- Davidson, R. (1992). Anterior cerebral asymmetry and the nature of emotion., *Brain and cognition* **20**(1): 125–151.
- Ferreira, A., Bastos-Filho, T., Sarcinelli-Filho, M., J.L.M., S., Garcia, J. and Quintas, M. (2010). *Improvements of a Brain-Computer Interface Applied to a Robotic Wheelchair*, p. 64.
- Gao, X., Xu, D., Cheng, M. and Gao, S. (2003). A BCI-based environmental controller for the motion-disabled., *IEEE transactions on neural systems and rehabilitation engineering : a publication of the IEEE Engineering in Medicine and Biology Society* **11**(2): 137–140.
- Guger, C., Allison, B., Growindhager, B., Pruckl, R., Hintermuller, C., Kapeller, C., Bruckner, M., Krausz, G. and Edlinger, G. (2012). How many people could use an SSVEP BCI?, *Frontiers in neuroscience* **6**.
- Kleinginna, P. R. and Kleinginna, A. M. (1981). A categorized list of emotion definitions, with suggestions for a consensual definition, *Motivation and Emotion* **5**.
- Kumar, S., von Kriegstein, K., Friston, K. and Griffiths, T. D. (2012). Features versus feelings: Dissociable representations of the acoustic features and valence of aversive sounds, *The Journal of Neuroscience* **32**(41): 14184–14192.
- Middendorf, M., G, M., Calhoun, G. and Jones, K. (2000). Brain-computer interfaces based on the steady-state visual-evoked response., *IEEE transactions on rehabilitation engineering : a publication of the IEEE Engineering in Medicine and Biology Society* **8**(2): 211–214.
- Molina, G. G., Nijholt, A. and Twente, U. (2009). Emotional Brain-Computer Interfaces, *3rd International Conference on Affective Computing and Intelligent Interaction and Workshops, 2009. ACII 2009*.
- Muller-Putz, G., Scherer, R., Brauneis, C. and Pfurtscheller, G. (2005). Steady-state visual evoked potential (SSVEP)-based communication: impact of harmonic frequency components., *Journal of neural engineering* **2**(4): 123–130.
- Muller, S. M. T., Bastos, T. F. and Sarcinelli, M. (2010). Incremental ssvep analysis for bci implementation, *32nd Annual International Conference of the IEEE EMBS*, pp. 3333–3336.
- Muller, S. M. T., Celeste, W. C., Bastos, T. F. and Sarcinelli, M. (2010). Brain-computer interface based on visual evoked potentials to command autonomous robotic wheelchair, *Journal of Medical and Biological Engineering* **30**(6): 407–415.
- Nijboer, F., Carmien, S., Leon, E., Morin, F., Koene, R. and Hoffmann, U. (2009). Affective brain-computer interfaces: Psychophysiological markers of emotion in healthy persons and in persons with amyotrophic lateral sclerosis, *Affective Computing and Intelligent Interaction and Workshops, 2009. ACII 2009. 3rd International Conference on*, pp. 1–11.
- Picard, R. (2010). Affective computing: From laughter to IEEE, *Affective Computing, IEEE Transactions on* **1**(1): 11–17.
- Picard, R. W. (2003). Affective computing: challenges, *International Journal of Human-Computer Studies* **59**.
- Sutter, E. E. (1992). The brain response interface: communication through visually-induced electrical brain responses, *Journal of Microcomputer Applications* **15**.
- Wang, Y., Wang, R., Gao, X., Hong, B. and Gao, S. (2006). A practical VEP-based brain-computer interface., *IEEE transactions on neural systems and rehabilitation engineering : a publication of the IEEE Engineering in Medicine and Biology Society* **14**(2): 234–239.
- Wolpaw, J., Birbaumer, N., Dennis, M., Pfurtscheller, G. and Vaughan, T. (2002). Brain-computer interfaces for communication and control., *Clinical neurophysiology : official journal of the International Federation of Clinical Neurophysiology* **113**(6): 767–791.
- Wolpaw, J., D, M., Neat, G. and Forneris, C. (1991). An EEG-based brain-computer interface for cursor control., *Electroencephalography and clinical neurophysiology* **78**(3): 252–259.
- Zander, T. and Kothe, C. (2011). Towards passive brain-computer interfaces: applying brain-computer interface technology to human-machine systems in general., *Journal of neural engineering* **8**(2).

Towards an Architecture of a Hybrid BCI Based on SSVEP-BCI and Passive-BCI

Anibal Cotrina¹, Alessandro Benevides¹, Andre Ferreira¹, Teodiano Bastos¹, Javier Castillo²,
Maria Luiza Menezes³, and Carlos Pereira³

Abstract—Recent decades have seen BCI applications as a novel and promising new channel of communication, control and entertainment for disabled and healthy people. However, BCI technology can be prone to errors due to the basic emotional state of the user: the performance of reactive and active BCIs decrease when user becomes stressed or bored, for example. Passive-BCI is a recent approach that fuses BCI technology with cognitive monitoring, providing valuable information about the user’s intentions, the situational interpretations and mainly the emotional state. In this work, an architecture composed by passive-BCI co-working with SSVEP-BCI is proposed, with the aim of improving the performance of the reactive-BCI. The possibility of adjusting recognition characteristics of SSVEP-BCIs using a passive-BCI output is evaluated. In this sense, two ways to recover the accuracy of SSVEP are presented in this paper: 1) Adjusting of Amplitude of the SSVEP and 2) Adjusting of Frequency of the SSVEP response. The results are promising, because accuracy of SSVEP-BCI can be recovered in the case that it was reduced by the BCI user’s emotional state.

I. INTRODUCTION

A Brain-Computer Interface (BCI) provides a direct connection between the user’s brain signals and a computer, generating an alternative channel of communication that does not involve the traditional way as muscles and nerves [1]. According to the categorization proposed in [2], active-BCIs have outputs derived from brain activity, which is directly and consciously controlled by the user, therefore being independent of external events [3]; and reactive-BCIs have outputs derived from brain activity arising in reaction to external stimulation, which is indirectly modulated by the user [4]. On the other hand, passive-BCIs have outputs derived from implicit information on the actual user mental state, which arises arbitrarily without the purpose of voluntary control. The first two categories derive their outputs for controlling an application and the last one derive its output to improve human-environment interaction or human-machine interaction.

A Passive-BCI is a recent approach that fuses BCI technology with cognitive monitoring, providing to the computer valuable information about the user’s intentions, the

situational interpretations and mainly the emotional state. Emotions can be defined as a subjective, conscious experience characterized primarily by psychophysiological expressions, biological reactions, and mental state [5]. But, how can a computer recognize human emotional states? Affective computing studies and develops systems that recognize, interpret, and process human emotions [6]. Currently, many affective computing techniques are being developed to recognize human emotions based on face expressions [7], physiological reactions like skin conductance [8] or electroencephalography (EEG) [9], [10], [11]. In the case of EEG signals, the asymmetry of the frontal lobe, given by the variation of the alpha band power, is significantly associated with human emotional states; in which, high alpha band power in the right hemisphere is associated to negative emotional states while high power in the left hemisphere is associated with positive emotional states [12], [13].

It is well known that BCIs, like SSVEP-based BCIs, are not suitable for all users [14], [15], [16]. The causes for this inefficiency have not yet been satisfactorily described. Few studies exist that explicitly investigated the predictive value of internal (user related) and external (BCI related) factors on the BCI performance. An integration of the existing knowledge about factors that influence a BCI performance into a model of BCI-control was presented in [17]. Four different aspects that contribute for BCI-control were suggested: 1) individual characteristics of the BCI user which include physiological, neurological and psychological factors; 2) characteristics of the BCI that comprises hardware and software components; 3) type of feedback and instruction, including feedback modality, presentation within each modality and instruction that is provided prior to the training; and 4) the BCI-controlled application, which can range from simple two-choice to multiple-choice paradigms for communication, neuro-prosthetic control, and clinical applications. Recently, a new perspective on BCI has emerged [18], which suggests that not only voluntary self-regulated signals can be used as input, but also involuntary signals might tell us something about the state of the BCI user (e.g. the emotional and cognitive state). It is assumed that relevant features from these involuntary signals (also referred to as passive signals) can be extracted and used to adapt the recognition algorithms of the BCI. In sum, the knowledge of the emotional state influences brain activity patterns allowing the BCI system to adapt its recognition algorithms with aiming the efficient interpretation of the user’s intentions.

In the present work, an architecture composed by passive-

¹A. Cotrina, A. Ferreira, A. Benevides, J. Castillo and Teodiano Bastos are with the Electrical Engineering Graduate School of Federal University of Espirito Santo, 514 Fernando Ferrari Ave. Vitoria, ES, Brazil. anibal.atencio@ufes.br

²J. Castillo is with the Electrical Engineering Graduate School, University of the Valle, 13 Paso Ancho Ave, Cali, Colombia.

³M. L. Menezes and C. Pereira are with the Electrical Engineering Graduate School of Federal University of Rio Grande do Sul, Porto Alegre, RS, Brazil.

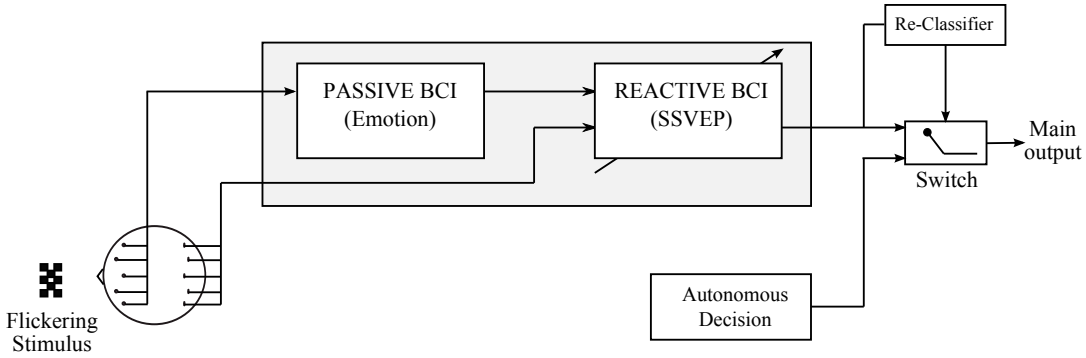


Fig. 1. Architecture of Hybrid BCI composed by passive-BCI co-working with reactive-BCI based on SSVEP.

BCI co-working with a reactive-BCI (SSVEP-based BCI) is proposed. In a typical SSVEP-based BCI system, multiple stimuli flickering at different frequencies are shown to the subject [19], [20], [21]. The increase of the SSVEP amplitude can be detected in the EEG signals and translated into control commands. However, stimuli flickering could cause a stress-related emotional state or loss of attention, as reported in [22]. In this architecture, which is shown in the Figure 1 the SSVEP-based BCI detects and translates the elicited evoked potential from EEG signals registered at occipital electrodes into a command. At the same time, the passive-BCI provides to the computer information about the emotional state by monitoring EEG signals on the frontal brain region. The system is then switched to a "passive mode" when the success rate of SSVEP decreases caused by the emergence of an specific component of emotional state, like stress. In this mode, the passive-BCI output is able to adjust some parameters of SSVEP-BCI with the aim of recovering the accuracy. The accuracy of SSVEP is monitored by a Re-classifier, which evaluate a number of consecutive results. The Re-classifier is able to activate a switch if the accuracy is not being recovered. In this case, an autonomous control system will take control of the machine. Commands like "stop the machine", "return to previous stage", or "call for help" can be sent by the autonomous decision making to control the system.

Two ways to recover the accuracy of SSVEP are presented in this paper: 1) Adjusting the Amplitude of the SSVEP and 2) Adjusting the Frequency of the SSVEP response.

II. MATERIALS AND METHODS

A. Subject

One healthy subject without any experience with BCI experiments was initially considered in the study. The experiment was taken with the understanding and written consent of the subject, who gave informed consent. This study was approved by the research ethics committee of the Federal University of Espirito Santo (Brazil).

B. Stimulus

Two flicker stimuli was displayed simultaneously on two 5×7 LED arranges. Stimuli frequency of 5.6 Hz and 6.4 Hz were generated by analog signal generators. The subject

seated in front of the SSVEP box and asked to focus on the target LED for 17 s after a beep tone, then asked to close his eyes for 5 s, ending the trial after a second beep tone. The EEG signal was recorded between seconds 5 and 17 of the trial. Two sessions of 10 trials were performed during the experiment.

C. Signal acquisition

BrainNet36 (BNT) was the device used for EEG acquisition with a cap of integrated electrodes from Electro-cap company. EEG signals from 19 electrodes (Fp1, Fp2, F7, F3, Fz, F4, F8, T7, C3, Cz, C4, T8, P7, P3, Pz, P4, P8, O1 and O2) positioned according to the international 10-20 system were registered. The grounding electrode was positioned on the user forehead and the bi-auricular reference was adopted. The EEG was acquired at a sampling rate of 200 Hz. Signals were filtered employing elliptic band-pass (4 Hz - 50 Hz). Signals from O1 and O2 electrodes were used to verify the SSVEP responses; other channels were employed to perform common average reference (CAR) spatial filtering, in order to reduce the correlation between channels originated by external noise.

III. PROPOSED ARCHITECTURE

As mentioned above, the user was asked to choose one specific target between two stimuli flickering at 5.6 Hz and 6.4 Hz. Results corresponding to SSVEP potential response elicited by 6.4 Hz are presented and analyzed in this section. A particular mental state, such as stress, can affect the frequency or the amplitude of this potential. Therefore, a technique based on adjusting the number of samples and a technique based on the range of search were evaluated to compensate the frequency and amplitude of evoked potentials, respectively.

A. Adjusting the Amplitude of the Response

The amplitude of the SSVEP response of the EEG signals depends on the quantity of samples employed to perform the FFT transform. Figure 2(a) shows four different ways to take a sample for computing the spectra. 2(b) shows the normalized amplitude spectra corresponding to these different ways. If $n = 200$ samples (corresponding to 1 s of data length) are considered, then the amplitude of the response is weak. So,

this kind of response will be more affected with changes in the user mental states. The response becomes more robust when more samples are considered. Thus, SSVEP response peak will be strong when 800 samples (corresponding to 4 s) are employed. In this sense, one way to maintain the SSVEP potential amplitude could be achieved through adjusting the data length of each trial.

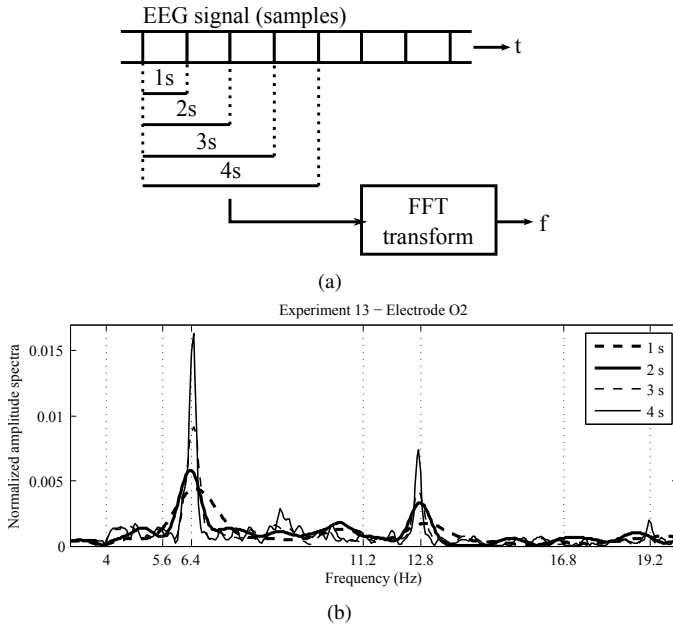


Fig. 2. (a) Length of FFT transformation window; (b) Normalized amplitude spectra corresponding to different data lengths for one subject.

The number of samples increases the data and the processing time, so this assessment maintains the success rate, but reduces the ITR. In practice, the EEG amplitude spectra was calculated by using a FFT-based Periodogram with Hamming windowing.

B. Adjusting the Frequency of the Response

Figure 3 shows the normalized amplitude spectra corresponding to the average of responses of ten trials of one subject SSVEP (gray) and the average of this trials for electrodes O1 and O2 when the user was stimulated with 6.4 Hz flickering frequency (black). Electrode O1 presents this potential at the fundamental frequency of 6.4 Hz without any other representative peak in the second or third harmonics (12.8 and 19.2 Hz), while O2 on the other hand, presents strong responses in the fundamental frequency and in the second harmonic and a weak potential in the third harmonic.

The frequency corresponding to peaks of amplitude in frequency domain is compared with stimuli flickering frequencies to determine which stimulus was chosen by the user. However, it is common that the frequency of the peak (fundamental or harmonic) is slightly different of stimulus frequency, or other peaks appear at frequency domain. To solve this problem, Power Spectral Density Analysis (PSDA), which involves processing in the frequency domain, was used to perform automatic recognition of SSVEP responses of the target stimulus.




Fig. 3. Normalized amplitude spectra SSVEP responses corresponding ten trials (gray) and the average (black) of this trials for electrodes O1 and O2.

So, given k -th stimulus frequency f_k , the closer peak response frequency f_h , and the magnitude of the peak frequency $P(f_k)$, the following ratio of proportion was used:

$$Ratio = \frac{|f_k - f_h|}{P(f_k)}. \quad (1)$$

So, if there is a peak in the same frequency of the stimulus, the error will be zero. If the error is not zero, the ratio will be small if the amplitude is high, and at different frequencies, the error will be small. In this case, f_k and f_h could be adjusted. The power spectral density analysis around the stimulus frequency is given by:

$$S_k = \frac{mP(f_k)}{\sum_{i=-m/2}^{m/2} P(f_k + if_r)}, \quad (2)$$

usually expressed in dB; m is number of samples around the stimulus frequency, and f_r is the frequency resolution which depends on the Fourier transformation. $P(f_k + if_r)$ is the power density around the stimulus frequency. In this study $m = 60$ was considered.

IV. DISCUSSION

Alpha power has been found to be more reliably related to task performance compared to other frequency bands, when the tasks compared carefully match on psychometric properties. Since the alpha power is inversely related to activation, blocking of or decreases in alpha are seen when underlying cortical systems engage in active processing. Thus the alpha power asymmetry may be considered a gradient of power that exists between the two homologous electrodes in the pair, with the slope of the gradient being towards the electrode with the greatest amount of power in this frequency band [12], [13]. The most commonly reported of the indexes is computed using the frontal electrodes by subtracting the left hemisphere alpha power (P_{lh}) of channel F3 from the right hemisphere alpha power (P_{rh}) of channel F4, as given by,

$$Asymmetry = \frac{P_{lh} - P_{rh}}{P_{lh} + P_{rh}}. \quad (3)$$

This approach results in an unidimensional scale representing the relative activity of the right and left hemispheres, with the middle point of the scale equaling zero or symmetrical activity. Interpreting this scale, high scores indicate relative greater left frontal activity whereas lower scores indicate relatively greater right frontal activity. Since asymmetry index is the output of a passive-BCI, it can scale by multiplying parameters such as the closer peak response frequency f_h (See equation 2) and window length n (See Section III-A) of a reactive-BCI to maintain the success rate. Regarding the computation of the alpha band asymmetry, our preliminary results shown in [23] indicates that asymmetry in the frontal lobe is significantly associated with human emotion reactivity [12]. The next step in this research will be to compute the asymmetry index and to propose a linear equation that relates this index with SSVEP-based BCI parameters.

V. CONCLUSION

The method of recognizing the fundamental frequency of an SSVEP elicited response described in the Section III-B can maintain the error rate by adjusting two parameters f_k and f_h , that determine the window width around the stimulus frequency. Thus, it can be concluded that the limits of the search range of frequency of the evoked potential and the number of samples used to compute the FFT transformation can be adjusted to improve the search of the SSVEP potential's frequency. Those results are promising because this show that passive-BCIs could improve or maintain the accuracy rate despite of BCI user's emotional states, such as stress. In the Section III-A, although the assessment reduces the information transfer rate, it maintains the error rate of the reactive-BCI. Since the asymmetry or energy in alpha band can be used to identify emotional components of the BCI user, the next step in this work will be to integrate all components of the architecture proposed given by the passive-BCI, the SSVEP-BCI, the Re-classifier and the Autonomous decision making showed in the Figure 1 in order to develop a more robust BCI.

ACKNOWLEDGMENT

The authors would like to acknowledge the financial funding from FAPES/CNPq (Process 53666038/2011), and thank CAPES agency for scholarship support.

REFERENCES

- [1] J. Wolpaw, N. Birbaumer, M. Dennis, G. Pfurtscheller, and T. Vaughan, "Brain-computer interfaces for communication and control." *Clinical neurophysiology : official journal of the International Federation of Clinical Neurophysiology*, vol. 113, no. 6, pp. 767–791, 2002.
- [2] T. Zander and C. Kothe, "Towards passive brain-computer interfaces: applying brain-computer interface technology to human-machine systems in general." *Journal of neural engineering*, vol. 8, no. 2, 2011.
- [3] J. Wolpaw, M. D. Neat, and C. Forneris, "An EEG-based brain-computer interface for cursor control." *Electroencephalography and clinical neurophysiology*, vol. 78, no. 3, pp. 252–259, 1991. [Online]. Available: [http://dx.doi.org/10.1016/0013-4694\(91\)90040-B](http://dx.doi.org/10.1016/0013-4694(91)90040-B)
- [4] S. M. T. Muller, W. C. Celeste, B. T. Freire, and S. Mário, "Brain-computer interface based on visual evoked potentials to command autonomous robotic wheelchair." *Journal of Medical and Biological Engineering*, vol. 30, no. 6, pp. 407–415, 2010.
- [5] P. R. Kleinginna and A. M. Kleinginna, "A categorized list of emotion definitions, with suggestions for a consensual definition." *Motivation and Emotion*, vol. 5, 1981.
- [6] R. W. Picard, "Affective computing: challenges," *International Journal of Human-Computer Studies*, vol. 59, 2003.
- [7] J. Bassili, "Emotion recognition: the role of facial movement and the relative importance of upper and lower areas of the face." *Journal of personality and social psychology*, vol. 37, no. 11, pp. 2049–2058, 1979.
- [8] R. Picard, E. Vyzas, and J. Healey, "Toward machine emotional intelligence: analysis of affective physiological state." *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 23, 2001.
- [9] T. Bastos-Filho, A. Ferreira, A. Atencio, S. Arjunan, and D. Kumar, "Evaluation of feature extraction techniques in emotional state recognition," in *Intelligent Human Computer Interaction (IHCI), 2012 4th International Conference on*, Dec 2012, pp. 1–6.
- [10] A. C. Atencio, A. B. Benevides, A. Ferreira, and T. Bastos, "EEG evaluation during emotional state elicited by unpleasant sounds to be applied in bci," in *Proceedings of the Fifth International Brain-Computer Interface Meeting 2013: Defining the Future*. Graz University of Technology, 2013, pp. 166–167.
- [11] A. C. Atencio, A. Ferreira, T. F. Bastos, M. L. R. Menezes, and C. E. Pereira, "Reconhecimento de componentes emocionais no electroencefalograma para aplicacoes em interfaces cerebro-computador," in *Congresso Brasileiro de Automatica*, 2012, pp. 519–526.
- [12] R. Davidson, "Anterior cerebral asymmetry and the nature of emotion." *Brain and cognition*, vol. 20, no. 1, pp. 125–151, 1992.
- [13] R. J. Davidson, "Cerebral asymmetry and emotion: Conceptual and methodological conundrums," *Cognition & Emotion*, vol. 7, 1993.
- [14] C. Guger, B. Allison, C. Hintermuller, R. Prueckl, B. Grosswindhager, C. Kapeller, and G. Edlinger, "Poor performance in SSVEP BCIs: are worse subjects just slower?" in *Proceedings of the Annual International Conference of the IEEE EMBS*, 2012, pp. 3833–3836.
- [15] C. Guger, B. Allison, B. Grosswindhager, R. Prueckl, C. Hintermuller, C. Kapeller, M. Bruckner, G. Krausz, and G. Edlinger, "How many people could use an SSVEP BCI?" *Frontiers in neuroscience*, vol. 6, 2012.
- [16] B. Allison, T. Luth, D. Valbuena, A. Teymourian, I. Volosyak, and A. Graser, "Bci demographics: How many (and what kinds of) people can use an ssvep bci?" *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, vol. 18, no. 2, pp. 107–116, April 2010.
- [17] A. Kubler, B. Blankertz, K. R. Muller, and C. Neuper, "A model of bci-control," in *5th International BCI conference*, 2011.
- [18] F. Nijboer, S. Carmien, E. Leon, F. Morin, R. Koene, and U. Hoffmann, "Affective brain-computer interfaces: Psychophysiological markers of emotion in healthy persons and in persons with amyotrophic lateral sclerosis," in *Affective Computing and Intelligent Interaction and Workshops, 2009. ACII 2009. 3rd International Conference on*, Sept 2009, pp. 1–11.
- [19] X. Gao, D. Xu, M. Cheng, and S. Gao, "A bci-based environmental controller for the motion-disabled," *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, vol. 11, no. 2, pp. 137–140, June 2003.
- [20] Y. Wang, R. Wang, X. Gao, B. Hong, and S. Gao, "A practical vep-based brain-computer interface," *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, vol. 14, no. 2, pp. 234–240, June 2006.
- [21] M. Cheng, X. Gao, S. Gao, and D. Xu, "Design and implementation of a brain-computer interface with high transfer rates," *IEEE Transactions on Biomedical Engineering*, vol. 49, 2002.
- [22] S. M. T. Muller, T. F. Bastos, and M. Sarcinelli, "Incremental ssvep analysis for bci implementation," in *32nd Annual International Conference of the IEEE EMBS*, 2010, pp. 3333–3336.
- [23] A. C. Atencio, J. Castillo, A. B. Benevides, A. Ferreira, A. Pomer-Escher, M. D. P. Souza, and T. F. Bastos, "Computing stress-related emotional state via frontal cortex asymmetry to be applied in passive-bci," in *Proceedings of the 5th IEEE Biosignals and Biorobotics conference (ISSNIP)*, 2014, pp. 1–6.

RECONHECIMENTO DE COMPONENTES EMOCIONAIS NO ELETROENCEFALOGRAMA PARA APLICAÇÕES EM INTERFACES CÉREBRO-COMPUTADOR

ANIBAL COTRINA-ATENCIO*, ANDRÉ FERREIRA*, TEODIANO FREIRE BASTOS-FILHO*, MARIA LUIZA RECENA MENEZES†, CARLOS EDUARDO PEREIRA†

*Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal do Espírito Santo - UFES
Av. Fernando Ferrari, 514 — 29075-910 Vitória-ES, Brasil

†Departamento de Engenharia Elétrica, Universidade Federal do Rio Grande do Sul - UFRGS
Av. Osvaldo Aranha, 103 — 90035-190 Porto Alegre-RS, Brasil

Emails: anibal.atencio@ufes.br, andrefer@ele.ufes.br, tfbastos@ele.ufes.br,
luiza.menezes@ufrgs.br, cpereira@ece.ufrgs.br

Abstract— The Affective Computing studies and develops systems that can recognize, interpret, process, and even simulate human emotions. The benefits extend from advances in Neuroscience up to help expand the experience of human-computer interaction by creating machines that could effectively generate empathy. This article presents the emotional components recognizing present in the brain signals for application in brain-computer interfaces (BCI) in order to make them more robust, intuitive and greater use of emotional charge contained in the signal generated by the user of this technology. Thus, the goal of this work is to evaluate the computer's ability to recognize human affective state through processing and analysis of electroencephalogram signals (EEG) using computational tools for feature extraction and pattern recognition. Two emotional states (calm/stress) were evaluated from pre-processed signals from DEAP database of F_{p1} , F_{p2} , F_3 , e F_4 channels located in the frontal lobe of the brain. Statistical characteristics and features based on the PSD coefficients were extracted and classified using KNN and SVM. The best result achieved was 70.1% when using KNN classifier with PSD characteristics.

Keywords— Affective computing, BCI, EEG, Stress, PSD, Statistical characteristics, Pattern classification, SVM, K-NN.

Resumo— A Computação Afetiva estuda e desenvolve sistemas que possam reconhecer, interpretar, processar e até simular emoções humanas, cujos benefícios se estendem desde auxiliar avanços na Neurociência até expandir a experiência de interação humano-computador criando máquinas passíveis de efetivamente gerar empatia. O que se apresenta neste artigo é o reconhecimento de componentes emocionais existentes em sinais cerebrais com vistas à aplicação em Interfaces Cérebro-Computador (ICCs), de modo a torná-las mais robustas, intuitivas e com maior aproveitamento da carga emocional contida no sinal gerado pelo usuário desta tecnologia. Para tal fim propõe-se avaliar a capacidade do computador de reconhecer o estado afetivo humano através do processamento e análise de Eletroencefalograma (EEG) usando ferramentas computacionais de extração de características e reconhecimento de padrões. Foi avaliado o reconhecimento de dois estados emocionais (Calma/Estresse), em modo *off-line* a partir de sinais pré-processados da base de dados DEAP dos canais F_{p1} , F_{p2} , F_3 , e F_4 do lobo frontal do cérebro. Foram extraídas características estatísticas e características baseadas em coeficientes relativos à PSD e classificadas usando K-NN e SVM. O melhor resultado alcançado foi de 70,1% quando utilizado o classificador KNN com características PSD.

Palavras-chave— Computação afetiva, ICC, EEG, Estresse, PSD, Características estatísticas, Reconhecimento de padrões, SVM, K-NN.

1 Introdução

Como saber o que é interessante e o que realmente importa para uma pessoa ou usuário de uma tecnologia? O sistema emocional auxilia os humanos a tratarem situações complexas e imprevisíveis, sinalizado o que é importante e com o que você se preocupa (Picard, 2010). Estando diretamente envolvidas em tomadas de decisão racionais e na escolha de ações apropriadas, a emoção tem papel determinante não somente na percepção, mas também na memória, na atenção e na interação homem-máquina e é neste ponto em que este artigo se insere. Uma Interface Cérebro-Computador (ICC), como apresentada na Figura 1, propicia uma conexão direta entre os sinais cerebrais do usuário desta tecnologia e um computador, gerando um canal alternativo

de comunicação que não envolve as vias tradicionais como músculos e nervos periféricos (Wolpaw et al., 2002). Assim, distintas tarefas ou estados mentais podem ser associados a diferentes ações físicas, como por exemplo, o usuário pode enviar o comando “virar à direita” para uma cadeira de rodas robotizada apenas imaginando o movimento de sua mão direita (Ferreira et al., 2010).

Embora apresentem inúmeras vantagens, a maioria das ICCs atuais são altamente suscetíveis aos diferentes estados emocionais vivenciados por seus usuários. Por outro lado, as ICCs possuem a vantagem do acesso direto à atividade cerebral, fornecendo informação significativa a respeito do estado emocional do usuário. Tal informação pode ser utilizada de duas formas (Molina et al., 2009): 1) O conhecimento da influência do estado emocional nos padrões de atividade cerebral permite à

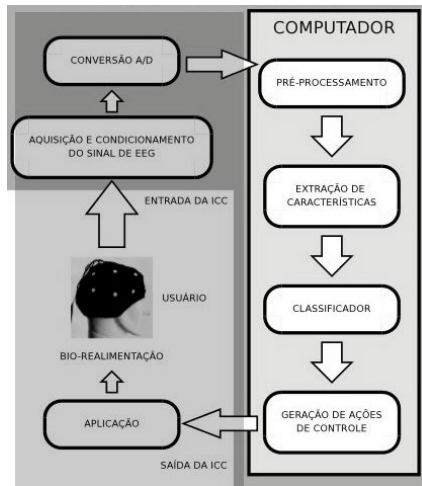


Figura 1: Estrutura básica de uma ICC.

ICC adaptar seus algoritmos de reconhecimento, de modo que a intenção do usuário ainda seja corretamente interpretada apesar das alterações de sinal induzidas pelo estado emocional do usuário. 2) A habilidade de reconhecer corretamente as emoções pode ser usada nas ICCs para prover ao usuário uma maneira mais natural e intuitiva de controlar a ICC através de modulação afetiva. Uma lembrança agradável pode ser suficiente para enviar comandos à ICC e, inclusive, aumentar a taxa de envio de comandos. Dentre algumas aplicações de ICCs baseadas no emocional humano, podem ser citadas: substituição de tabuleiros pictográficos para pessoas com deficiência, auxílio à navegação de cadeiras de rodas (Ferrez and Millán, 2008), detecção de estresse (alterar pesos em um sistema de controle compartilhado homem-máquina), entretenimento e jogos, avaliação de aspectos ergonômicos por estresse/cansaço e interação com robôs humanoides.

Assim, o que se apresenta neste trabalho é o reconhecimento de componentes emocionais presentes em sinais cerebrais com vistas à aplicação em ICCs, de modo a torná-las mais robustas, intuitivas e com maior aproveitamento da carga emocional contida no sinal gerado pelo usuário desta tecnologia. A capacidade do computador de reconhecer o estado afetivo humano é avaliado através do processamento e análise de eletroencefalograma (EEG) usando ferramentas computacionais de extração de características e reconhecimento de padrões. Foi avaliado o reconhecimento em modo *off-line* dos estados emocionais Calma e Estresse a partir dos sinais de EEG registrados no lobo frontal do cérebro. Empregou-se a base de dados DEAP (*Database for emotion analysis using physiological signals*) que fornece um conjunto de dados para a análise de estados afetivos. Foram avaliados o classificador baseado em K -NN (K -Nearest Neighbours) e o classificador SVM (*Support Vector Machine*) empregando caracterís-


ticas estatísticas dos sinais temporais e características baseadas em coeficientes relativos à PSD (*Power Spectral Density*).

A seguir, na Seção 2 mostram-se os passos e critérios que foram utilizados na escolha dos canais dos eletrodos EEG e a seleção de amostras do banco de dados do DEAP. Nas Seções 3 e 4 são descritas as técnicas de extração de características e classificação dos sinais EEG respectivamente. Os resultados dos experimentos realizados são mostrados na Seção 5. Finalmente, na Seção 6 são apresentadas as conclusões e algumas propostas para prosseguimento do trabalho.

2 Sinais EEG e Estado Emocional

Para definir os estados de Calma e Estresse usaram-se regras baseadas em níveis de excitação e prazer a partir de sinais EEG registradas nas posições F_{p1} , F_{p2} , F_3 , e F_4 ¹ do lobo frontal do cérebro (veja Figura 2), de acordo com estudos que relacionam o córtex pré-frontal do cérebro com as bases neurais da emoção (Davidson et al., 2000). Tais posições também têm sido adotadas em trabalhos de reconhecimento de emoções baseado em EEG (Petrantonakis and Hadjileontiadis, 2011), (Hadjileontiadis and Petrantonakis, 2010) e (Petrantonakis and Hadjileontiadis, 2009). Em (Lin et al., 2010) faz-se o reconhecimento de emoções relacionadas a músicas baseado em EEG usando eletrodos em 30 posições incluindo F_{p1} , F_{p2} , F_3 , e F_4 ; em (Utama et al., 2009) se apresenta uma tentativa de encontrar uma relação entre a localização de eletrodos e aspectos específicos de emoções faciais fazendo uso de quatro posições incluindo F_{p1} e F_{p2} . Em (Schaaff and Schultz, 2009) foram utilizadas quatro posições incluindo F_{p1} e F_{p2} para se desenvolver um método que facilite o reconhecimento de emoções em robôs humanoides e em (Hosseini, 2010) foi proposto um sistema de reconhecimento de estresse emocional usando bio-sinais multimodais com eletrodos EEG em cinco posições incluindo F_{p1} e F_{p2} .

¹Sistema internacional 10-20

Figura 2: Posições F_{p1} , F_{p2} , F_3 , e F_4 no Sistema internacional 10-20.

2.1 Estados emocionais (Calma/Estresse)

Em (Morris, 1995) foi proposto um sistema de avaliação afetiva chamado de Escalas de SAM (*Self Assessment Manikins*), no qual uma figura gráfica representa reações emocionais, tais como excitação (*Arousal*), prazer (*Valence*) e domínio (*Dominance*), ao longo de uma escala de nove níveis. Na Figura 3 são apresentadas as escalas para *arousal* e *valence*, sendo que a intensidade aumenta da esquerda para a direita.




Figura 3: Escalas SAM para os níveis de *arousal* (acima) e *valence* (abaixo).

Baseado nas escalas de *arousal* e *valence*, em (Hosseini, 2010) foi proposto um sistema de reconhecimento emocional de estresse na qual foram estabelecidas duas regras, mostradas nas expressões (1) e (2), para definir os estados emocionais de Calma e Estresse, respectivamente:

$$(arousal < 4) \cap (4 < valence < 6), \quad (1)$$

$$(arousal > 5) \cap (valence < 3). \quad (2)$$

Tais expressões são coerentes com a classificação de imagens da base de dados IAPS (*International Affective Picture System*), sendo esta (Lang et al., 2008) uma base de dados muito usada em trabalhos de reconhecimento de emoções, como por exemplo (Aris et al., 2011), (Schaaff and Schultz, 2009) e (Petranonakis and Hadjileontiadis, 2011).

2.2 Base de dados DEAP

A base de dados DEAP (Koelstra et al., 2011) fornece um conjunto de dados multimodais para a análise de estados afetivos dos seres humanos na qual foram registrados sinais fisiológicos que incluem sinais de EEG com eletrodos em 32 posições (F_{p1} , AF_3 , F_3 , F_7 , FC_5 , FC_1 , C_3 , T_7 , CP_5 , CP_1 , P_3 , P_7 , PO_3 , O_1 , O_Z , P_Z , FP_2 , AF_4 , F_Z , F_4 , F_8 , FC_6 , FC_2 , C_Z , C_4 , T_8 , CP_6 , CP_2 , P_4 , P_8 , PO_4 e O_2) e 8 sinais fisiológicos periféricos tais como eletroculograma, eletromiograma e temperatura.

Na coleta de dados foram considerados 32 voluntários saudáveis (50% mulheres) com idades entre 19 e 37 (idade média de 26,9). Os participantes

assistiram trechos de um minuto de duração de 40 clipes de vídeos musicais e autoavaliaram o estado emocional usando os níveis de excitação (*arousal*) e prazer (*valence*) causado por cada vídeo fazendo uso das escalas de SAM descritos na Seção 2.1, resultando em 1280 (32×40) amostras na base de dados.

Neste trabalho foi feita a seleção e a rotulação das amostras em função destes níveis, de acordo com as equações (1) e (2). Dessa forma, foram rotuladas 141 amostras com o estado emocional de Calma e 129 amostras com o estado emocional de Estresse; restando 1010 amostras que não corresponderam a nenhum dos estados emocionais em questão. Na Figura 4 são mostradas, no plano bidimensional *arousal/valence*, as 40 amostras correspondentes aos níveis de autoavaliação de excitação e prazer do voluntário 2, e as regiões de Calma e Estresse; onde os pontos vermelhos correspondem ao estado emocional Estresse e os pontos verdes ao estado de Calma.

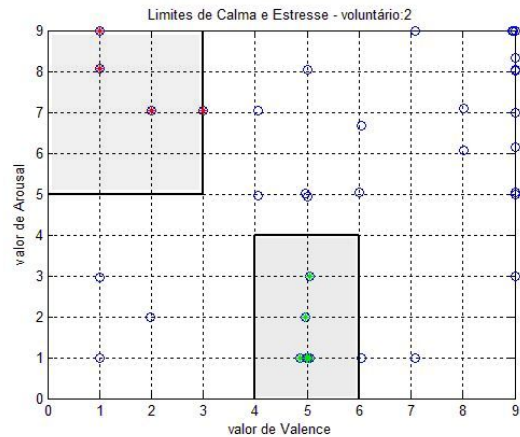


Figura 4: Amostras de Calma/Estresse rotuladas no plano bidimensional *arousal/valence*.

3 Extração de Características

Depois de rotular as amostras, os sinais dos canais F_{p1} , F_{p2} , F_3 , e F_4 são caracterizados por estatística do sinal temporal e coeficientes da PSD. Não foi preciso fazer o pré-processamento dos sinais visto que a base de dados fornece tanto dados sem tratamento quanto dados pré-processados. Os dados pré-processados do DEAP foram subamostrados a 128Hz, filtrados com um filtro passa-banda de 4,0-45,0Hz e calculada a média com referência comum usando MATLAB®. Os dados também foram segmentados em: um segmento de ensaio de 60 segundos e outro de pré-ensaio de 3 segundos, que foi removido, juntamente com os artefatos do eletroculograma (Koelstra et al., 2011).

3.1 Características Estatísticas

Foram extraídas as características estatísticas do sinal pré-processado, como proposto em (Picard and Vyzas, 2001), e usado em trabalhos como (Schaaff and Schultz, 2009), (Hadjileontiadis and Petrantonakis, 2010) e (Mampusti et al., 2011). Tais características vêm dadas pela média do sinal pré-processado:

$$\mu_X = \frac{1}{N} \sum_{n=1}^N X(n), \quad (3)$$

pelo desvio padrão do sinal pré-processado:

$$\sigma_X = \sqrt{\frac{1}{N} \sum_{n=1}^N (X(n) - \mu_X)^2}, \quad (4)$$

pela média do valor absoluto da primeira diferença do sinal pré-processado:

$$\delta_X = \frac{1}{N} \sum_{n=1}^{N-1} |X(n+1) - X(n)|, \quad (5)$$

pela média do valor absoluto da primeira diferença normalizada do sinal pré-processado:

$$\tilde{\delta}_X = \frac{1}{N} \sum_{n=1}^{N-1} |\tilde{X}(n+1) - \tilde{X}(n)|, \quad (6)$$

pela média do valor absoluto da segunda diferença do sinal pré-processado:

$$\gamma_X = \frac{1}{N} \sum_{n=1}^{N-2} |X(n+2) - X(n)|, \quad (7)$$

e pela média do valor absoluto da segunda diferença normalizada do sinal pré-processado:

$$\tilde{\gamma}_X = \frac{1}{N} \sum_{n=1}^{N-2} |\tilde{X}(n+2) - \tilde{X}(n)|; \quad (8)$$

em que $\tilde{X}(n) = (X(n) - \mu_X)/\sigma_X$ é o sinal padrão e as características de cada canal são representadas pelo vetor $[\mu_X, \sigma_X, \delta_X, \tilde{\delta}_X, \gamma_X, \tilde{\gamma}_X]$. Cada um dos quatro canais utilizados possui seis características e formam um vetor de características resultante de 24 elementos.

3.2 Densidade Espectral de Potência

A PSD está entre os métodos mais aplicados na caracterização de padrões de atividade cerebral presentes no sinal de EEG e já está sendo usada em trabalhos de reconhecimento de emoções (Lin et al., 2010). Como os ritmos eletroencefalográficos estão definidos principalmente no domínio da frequência, e a análise da PSD do sinal de EEG

expressa o nível de atividade em cada banda de interesse (delta, teta, alfa, mu, beta e gama), isto permite que as componentes de potência possam ser interpretadas diretamente como ritmos cerebrais. Considerando uma abordagem baseada em Fourier, a PSD é estimada aqui pelo método de Welch.

Nos gráficos da Figura 5 são mostradas as características PSD dos sinais EEG dos canais F_{p1} , F_{p2} , F_3 , e F_4 de uma amostra rotulada com o estado emocional de Estresse do voluntário 1. Em todos os casos, as seis primeiras características ($f_1 \dots f_6$) representam a energia média em cada intervalo de 3,2 Hz a partir de 4,0 Hz, e a sétima característica (f_7) é dada pela potência média do sinal em toda a banda. As características baseadas em PSD são extraídas para cada um dos quatro canais utilizados, resultando em um vetor de 28 elementos.

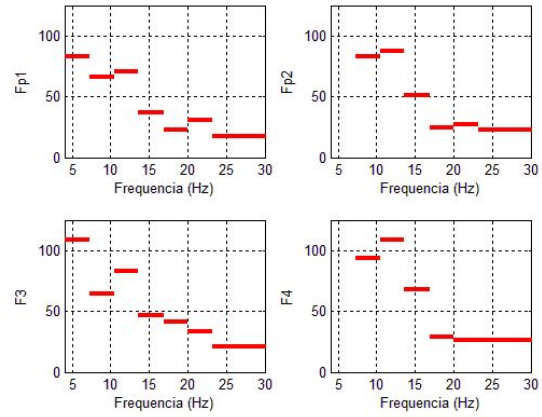


Figura 5: Características espectrais baseadas em PSD dos sinais EEG dos canais F_{p1} , F_{p2} , F_3 , e F_4 .

Após a extração de todas as características, elas são concatenadas para formar um vetor característico de alta dimensão onde cada elemento do vetor é normalizado segundo a seguinte equação:

$$x_i^{norm} = \frac{x_i - \mu_x}{\sigma_x}, \quad (9)$$

em que μ_x é a média sobre todas as amostras e σ_x é o desvio padrão. Os vetores de característica normalizados são usados posteriormente para treinamento e teste de classificação.

4 Classificação

Neste trabalho foram testadas duas técnicas de reconhecimento de padrões que vêm sendo amplamente utilizadas em trabalhos envolvidos com tarefas de reconhecimento afetivo: o K -NN, utilizado em trabalhos como (Hadjileontiadis and Petrantonakis, 2010) e (Petrantonakis and Hadjileontiadis, 2011); e o SVM, utilizado em traba-

lhos como (Lin et al., 2010), (Schaaff and Schultz, 2009), (Mampusti et al., 2011) e (Hosseini, 2010).

No algoritmo K -NN todos os vetores de características correspondem a pontos no espaço n -dimensional, no qual os vizinhos mais próximos de um vetor de características (F_V) são definidos em termos da distância padrão. Dessa forma, dado $F_V = [f_1 f_2 \dots f_n]$, a distância entre dois vetores de características pode ser expressa por $d(F_{V1}, F_{V2})$. Assim, definido o conjunto de F_V 's de treinamento mede-se a distância de um vetor de teste F_{Vt} e obtém-se os K vizinhos ($F_{V1}, F_{V2} \dots F_{VK}$) mais próximos do vetor de teste. O algoritmo retorna a classe na qual estão a maioria dos vizinhos mais próximos. Para mais detalhes sobre o algoritmo veja (Duda et al., 2001).

Os algoritmos mais comuns para medir a distância na classificação via K -NN são a distância Euclidiana, que foi usada em nosso trabalho, e a distância de Hamming.

Por outro lado, o classificador SVM é capaz de separar dados altamente dimensionais, reconhecendo dados de duas classes mediante a construção de um hiperplano entre os vetores de característica n -dimensionais de ambas as classes. O algoritmo procura o hiperplano que separa as duas classes com maior margem, onde pontos mais próximos ao hiperplano de separação são chamados vetores suporte. Mesmo o SVM só procurando um hiperplano de separação, o algoritmo é capaz de encontrar divisões muito complexas entre duas classes. O poder deste método reside no fato de que os dados podem ser transformados em um espaço de alta dimensionalidade, utilizando uma função chamada *kernel*, com a ideia de permitir que as operações sejam executadas no espaço de entrada, ao invés de no espaço de características; para mais detalhe sobre o algoritmo veja (Bishop, 2006). Alguns *kernels* comuns incluem funções linear, polinomial ou RBF (*Radial Basis Function*).

Nos testes realizados com o SVM foram usadas a função linear $k_{linear}(x, y) = x^T y + c$, a função quadrática $k_{quad}(x, y) = (x^T y)^2$, e a função RBF Gaussiana $k_{rbf}(x, y) = \exp(-1/(2\sigma^2)||x - y||^2)$ com um fator de escala padrão (σ) de 1.

5 Resultados

Nos testes de classificação foi utilizada a Precisão, que é obtida dividindo o número de amostras classificadas corretamente pelo número total de amostras, como métrica para avaliar o desempenho da classificação. Além disso, com o fim de reduzir a possibilidade de desvios nos resultados devido à especialização do treinamento só com os dados de treino e para garantir que o teste fosse com amostras diferentes, os resultados da classificação foram avaliados utilizando a validação cruzada com o método (k -folds) em 10 iterações. Este método divide os dados de treinamento em dez partes, das

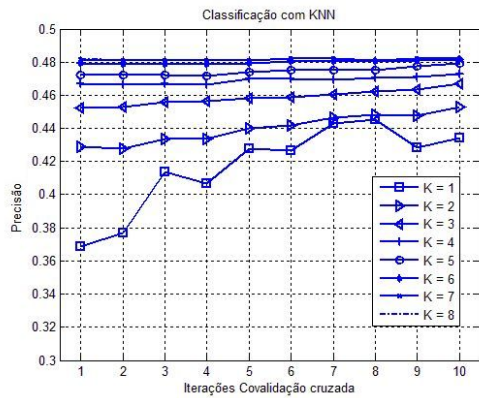
quais nove são usadas para treino e uma é usada para o teste. Neste método, o processo é repetido dez vezes, de tal forma que cada uma das dez partes fosse usada para o teste de classificação. Foram realizados dois testes, segundo a quantidade de estados emocionais a classificar; assim, foram avaliadas a Classificação de três estados emocionais e a Classificação de dois estados emocionais.

Nesta classificação as amostras da base de dados foram rotuladas segundo as regras das equações (1) e (2) como Calma/Estresse/Outro (sendo "Outro" um estado emocional distinto dos anteriores), sendo testada a classificação destes três estados emocionais usando o classificador K -NN. Em respeito ao número de amostras para a classificação, conforme mencionado na Seção 2, rotularam-se 141 amostras com o estado emocional de Calma, 129 com o estado emocional de Estresse e 1010 amostras como outros estados. Então, para a avaliação da classificação com três classes foram considerados 129 amostras por classe; em classes que apresentaram um número maior, foram tomadas 129 amostras aleatoriamente. Nas Figuras 6(a) e 6(b) são mostrados os resultados da classificação dos três estados emocionais acima mencionados quando foram consideradas as características estatísticas dos sinais temporais e as características baseadas em PSD, respectivamente.


5.1 Classificação de três estados emocionais

Em ambas as figuras têm-se oito curvas que são o resultado de variar o número de vizinhos K com valores entre 1 e 8; cada curva tem dez pontos que correspondem à precisão alcançada em cada iteração da validação cruzada 10-folds. Então, pode-se observar que no caso de avaliar com características estatísticas os maiores valores da precisão foram de 48,16% \pm 0,72% e obtidos com $K = 8$ vizinhos; já no caso da avaliação com características PSD obtiveram-se valores de precisão ligeiramente maiores, de 49,53 \pm 1,2% com $K = 8$. Pelos resultados alcançados acredita-se que com valores de K acima de 9, apesar da maior demanda computacional, não se melhora significativamente os resultados.


Devido às condições específicas deste trabalho, tais como a pequena quantidade de canais de sinais EEG usados, o uso de uma base de dados ao invés de coletar dados diretamente, e o uso de técnicas de extração de características e classificação diferentes, consideram-se estes resultados aceitáveis se comparados com os de outros trabalhos. Como podemos ver em (Schaaff and Schultz, 2009) o qual, na classificação de três emoções, alcançou uma taxa média de reconhecimento de 47,11% apesar do treinamento e da classificação serem realizados separadamente para cada voluntário.




(a)



(a)



(b)



(b)

Figura 6: Precisão na classificação de três estados emocionais usando o algoritmo K -NN com (a) Características estatísticas e (b) Características baseadas em PSD.


Figura 7: Precisão na classificação de dois estados emocionais usando K -NN com (a) Características estatísticas e (b) Características baseadas em PSD.

5.2 Classificação de dois estados emocionais


Devido a que o conhecimento da influência do estado emocional nos padrões de atividade cerebral permite à ICC adaptar seus algoritmos de reconhecimento induzidas pelo estado emocional do usuário, como o estresse, foi considerado um segundo experimento no qual foram considerados só dois estados emocionais (Calma/Estresse). Neste experimento, foi avaliada a classificação destes dois estados emocionais usando os classificadores K -NN e SVM.

Nas Figuras 7(a) e 7(b) são mostrados os resultados da classificação dos três estados emocionais acima mencionados considerando as características estatísticas dos sinais temporais e as características baseadas em PSD, respectivamente. É evidente que os resultados obtidos com características baseadas em PSD foram melhores do que os obtidos com características estatísticas; assim, no caso da classificação com características estatísticas alcançou-se uma precisão na classificação de $66,25\% \pm 0,6\%$. Já no caso da classificação com características PSD obteve-se uma precisão de $70,1\% \pm 0,45\%$.

Com referência à classificação de dois estados emocionais com SVM, nas Figuras 8(a) e 8(b) são mostrados os resultados alcançados quando foram consideradas as características estatísticas e características baseada em PSD respectivamente. Em ambas as figuras tem-se três curvas que correspondem, como mencionado na Seção 4, aos três tipos de funções de *kernel*: Linear, Quadrática e RBF Gaussiana, utilizados no treinamento; com dez pontos cada que correspondem à precisão alcançada em cada iteração da validação cruzada 10-*folds*. Os resultados obtidos neste experimento foram próximos aos obtidos no experimento anterior, porém ligeiramente menores. No caso da classificação com características estatísticas, observa-se que foram alcançados valores de precisão de $66,24\% \pm 0,81\%$ quando foi usado a função RBF Gaussiano no *kernel*; no entanto, no caso das características baseadas em PSD obtiveram-se melhores resultados, de $69,85\% \pm 3,5\%$, com a função quadrática. De forma semelhante ao experimento anterior, neste experimento ainda que foram distintas funções *kernel* do classificador SVM, pode-se ver que foram obtidos melhores resultados de classificação com características PSD.



(a)



(b)

Figura 8: Precisão na classificação de três estados emocionais usando SVM considerando três tipos de funções no *kernel* com (a) Características estatísticas e (b) Características baseadas em PSD.

Comparando os resultados, tanto no caso de três quanto de dois estados emocionais, a precisão alcançada com as características baseadas em PSD foi maior; o qual, ainda não se tenha aprofundado no estudo das bandas espectrais de interesse (delta, teta, alfa, mu, beta e gama), é coerente visto que os ritmos eletroencefalográficos estão definidos principalmente no domínio da frequência e que análise da PSD do sinal de EEG expressa o nível de atividade em cada banda.

Apesar das condições distintas que se podem encontrar na área de pesquisa de reconhecimento de estados emocionais, nossos resultados podem ser considerados aceitáveis se comparados com os obtidos em trabalhos recentes (após 2009), como por exemplo (Hosseini, 2010), o qual alcançou uma precisão de 79,2% na classificação de três estados emocionais usando um número maior de canais EEG e um processo de rotulação de dados baseado não apenas na autoavaliação de cada voluntário, mas também na análise qualitativa e na análise quantitativa de sinais psicofisiológicos. Em (Mampusti et al., 2011) obteve-se as precisões de 54,09%, 46,86% e 40,72% com *K*-NN, SVM e MLP (perceptron multicamada) respecti-

vamente na classificação de quatro estados emocionais. Sendo assim, é difícil comparar a precisão de cada um dos estados emocionais obtidos neste trabalho com a literatura atual, pois o número de estados emocionais varia de estudo para estudo. No entanto, deve-se salientar trabalhos cujos resultados são muito relevantes, tais como (Petranonakis and Hadjileontiadis, 2009) no qual foi obtido 83,33% de taxa média de classificação na diferenciação de seis emoções. No trabalho de (Lin et al., 2010) a melhor precisão média usando quatro estados emocionais foi de 86,15%, embora não tenham utilizado estados emocionais relativos ao estresse.

6 Conclusões

Neste trabalho apresentou-se uma abordagem de reconhecimento de componentes emocionais presentes em sinais cerebrais com vista à aplicação em ICCs. Para tal fim foi avaliada a capacidade do computador de reconhecer o estado afetivo humano através do processamento de sinais EEG e usando algoritmos de extração de características e classificação comumente utilizados nas áreas de computação e reconhecimento de padrões.

Foram realizados experimentos para classificar dois estados emocionais: Calma/Estresse, e para classificar três estados emocionais: Calma/Estresse/Outro, sendo “Outro” um estado emocional distinto aos dois anteriores. Os melhores resultados foram alcançados na classificação de dois estados emocionais (70,1%) com características PSD e com o classificador *K*-NN. O rotulado das emoções foi baseado nos níveis de *arousal/valence* dos sinais EEG pré-processados do banco de dados DEAP, e na classificação foi realizada com sinais dos canais F_{p1} , F_{p2} , F_3 e F_4 do lobo frontal do cérebro em modo *off-line*.

A partir dos resultados obtidos neste estudo, pode-se concluir que é possível implementar um sistema de reconhecimento de emoções a partir de sinais EEG de apenas quatro canais. No entanto, para fazer possível a construção de uma ICC emocional que possa se adaptar às variações de estados emocionais do ser humano tem que se melhorar a precisão na classificação, avaliando o desempenho de outras técnicas de extração de características que vêm demonstrando melhores resultados tais como HOC (*High Order Crossings*), e afinando a classificação com SVM, além de realizar a implementação de um protocolo de captura de sinais EEG e montar uma base de dados própria.

Agradecimentos

Os autores agradecem à CAPES e à FAPES/CNPq (Processo 53666038, PPP-02/2011) pelo suporte financeiro a esta pesquisa.

Referências

- Aris, S. A. M., Taib, M. N., Lias, S. and Sulaiman, N. (2011). Feature Extraction of EEG Signals and Classification Using FCM, *2011 Uksim 13th International Conference on Computer Modelling and Simulation* pp. 54–58.
- Bishop, C. M. (2006). *Pattern recognition and machine learning*, Springer.
- Davidson, R. J., Jackson, D. C. and Kalin, N. H. (2000). Emotion, plasticity, context, and regulation: perspectives from affective neuroscience., *Psychological bulletin* **126**(6): 890–909.
- Duda, R. O., Hart, P. E. and Stork, D. G. (2001). *Pattern Classification*, 2 edn, Wiley-Interscience.
- Ferreira, A., Bastos-Filho, T., Sarcinelli-Filho, M., J.L.M., S., Garcia, J. and Quintas, M. (2010). *Improvements of a Brain-Computer Interface Applied to a Robotic Wheelchair*, p. 64.
- Ferrez, P. W. and Millán, J. d. R. (2008). Error-related eeg potentials generated during simulated brain-computer interaction, *IEEE Trans. on Biomedical Engineering* **55**(3).
- Hadjileontiadis, P. C. and Petrantonakis, L. J. (2010). Emotion Recognition From EEG Using Higher Order Crossings, *IEEE Transactions on Information Technology in Biomedicine* **14**(2): 186–197.
- Hosseini, S A; Khalilzadeh, M. A. (2010). Emotional stress recognition system using eeg and psychophysiological signals., *Biomedical Engineering and Computer Science (ICBECS), 2010 International Conference on*, pp. 1 – 6.
- Koelstra, S., Muhl, C. and Soleymani, M. (2011). DEAP: A database for emotion analysis using physiological signals, *Affective Computing* pp. 1–15.
- Lang, J. P., Bradley, M. M. and Cuthbert, B. N. (2008). International Affective Picture System (IAPS): Technical Manual and Affective Ratings, *Technical report*, University of Florida, Gainesville, FL.
- Lin, Y., Wang, C.-H., Jung, T. and Wu, T. (2010). EEG-based emotion recognition in music listening, *IEEE Transactions on Biomedical Engineering* **57**(7): 1798–806.
- Mampusti, E. T., Ng, J. S., Quinto, J. J. I., Teng, G. L., Suarez, M. T. C. and Trogo, R. S. (2011). Measuring Academic Affective States of Students via Brainwave Signals, *Knowledge and Systems Engineering, 2011 Third International Conference on* pp. 226–231.
- Molina, G. G., Nijholt, A. and Twente, U. (2009). Emotional Brain-Computer Interfaces, *3rd International Conference on Affective Computing and Intelligent Interaction and Workshops, 2009. ACII 2009.* .
- Morris, J. D. (1995). SAM : The Self-Assessment Manikin An Efficient Cross-Cultural Measurement Of Emotional Response, Observations., *Journal of Advertising Research* **8**(December).
- Petrantonakis, P. C. and Hadjileontiadis, L. J. (2009). Eeg-based emotion recognition using hybrid filtering and higher order crossings, *Affective Computing and Intelligent Interaction and Workshops, 2009. ACII 2009. 3rd International Conference on*, pp. 1–6.
- Petrantonakis, P. and Hadjileontiadis, L. (2011). A Novel Emotion Elicitation Index Using Frontal Brain Asymmetry for Enhanced EEG-Based Emotion Recognition., *IEEE Transactions on Information Technology in Biomedicine* **15**(5): 737–46.
- Picard, R. (2010). Affective computing: From laughter to IEEE, *Affective Computing, IEEE Transactions on* **1**(1): 11–17.
- Picard, R. and Vyzas, E. (2001). Toward machine emotional intelligence: Analysis of affective physiological state, *IEEE Transactions on Pattern Analysis and Machine Intelligence* **23**(10): 1175–1191.
- Schaaff, K. and Schultz, T. (2009). Towards an EEG-based Emotion Recognizer for Humanoid Robots, *The 18th IEEE International Symposium on Robot and Human Interactive Communication*, pp. 792–796.
- Utama, N. P., Takemoto, A., Nakamura, K. and Koike, Y. (2009). Single-trial EEG data to classify type and intensity of facial emotion from P100 and N170, *International Joint Conference on Neural Networks*, pp. 3156–3163.
- Wolpaw, J. R., Birbaumer, N., McFarland, D. J., Pfurtscheller, G. and Vaughan, T. M. (2002). Brain-computer interfaces for communication and control, *Clinical Neurophysiology* **113**(6): 767–791.

AVALIAÇÃO DE TÉCNICAS DE EXTRAÇÃO DE CARACTERÍSTICAS BASEADAS EM PSD (*POWER SPECTRAL DENSITY*), HOC (*HIGH ORDER CROSSINGS*) E CARACTERÍSTICAS ESTATÍSTICAS NO RECONHECIMENTO DE ESTADOS EMOCIONAIS

Anibal Cotrina-Atencio*, André Ferreira*, Teodiano Freire Bastos Filho*,
Maria Luiza Recena Menezes**, Carlos Eduardo Pereira**

*PPGEE/Universidade Federal do Espírito Santo, Vitória, Brasil.

**PPGEE/Universidade Federal do Rio Grande do Sul, Porto Alegre, Brasil.

anibal.atencio@ufes.br

Abstract: Affective Computing studies and develops systems that can recognize, interpret, process, and even simulate human emotions. Its benefits extend from stimulating advances in neuroscience to help expand the experience of the interaction between human and computer by creating, for example, machines effectively capable of generating empathy on the user. Aiming application in brain-computer interfaces, we present in this paper a study of the three EEG signals feature extraction techniques. These techniques have been widely employed in works of emotional states recognition: statistical characteristics, features based on PSD (Power Spectral Density) and features based on HOC (High Order Crossings). The validation was performed via the classification of emotional states of *calm* and *stress* using the K-NN based classifier (K-Nearest Neighbors) in off line mode. The best results were 70.1%, using the PSD based technique, and 69.59% using the HOC based technique.

Palavras-chave: Computação Afetiva, EEG, Características Estatísticas, HOC, PSD.

Introdução

Uma Interface Cérebro-Computador (ICC), como apresentada na Figura 1, propicia uma conexão direta entre os sinais cerebrais do usuário desta tecnologia e um computador, gerando um canal alternativo de comunicação que não envolve as vias tradicionais como músculos e nervos periféricos [1]. Distintos estados mentais podem ser associados a ações físicas, como por exemplo, o usuário pode enviar o comando “virar à direita” para uma cadeira de rodas robotizada apenas imaginando o movimento de sua mão direita [2].

Embora apresentem inúmeras vantagens, a maioria das ICCs atuais são altamente suscetíveis aos estados emocionais vivenciados por seus usuários, já que as emoções sinalizam o que é importante e com o que você

se preocupa [3], ao mesmo tempo em que estão diretamente envolvidas em tomadas de decisão racionais e na escolha de ações apropriadas. No entanto, as ICCs possuem a vantagem do acesso direto à atividade cerebral, podendo fornecer informação significativa a respeito do estado emocional do usuário. Tal informação pode ser utilizada de duas formas [4]: 1) no conhecimento da influência do estado emocional nos padrões de atividade cerebral, permitindo à ICC adaptar seus algoritmos de reconhecimento de modo que a intenção do usuário ainda seja corretamente interpretada apesar das alterações de sinal induzidas pelo estado emocional do usuário; 2) na habilidade de reconhecer corretamente as emoções, para prover ao usuário uma maneira mais natural e intuitiva de controlar a ICC através de modulação afetiva.

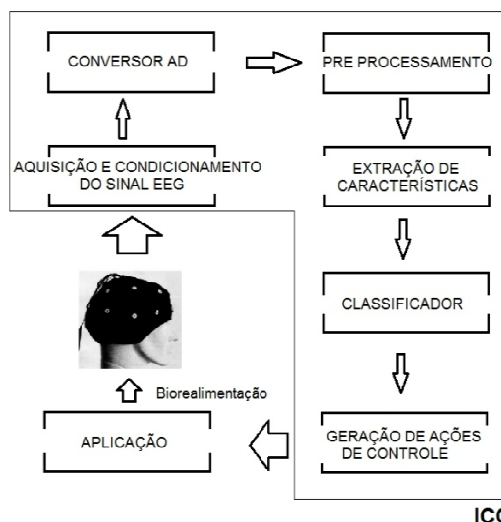


Fig. 1: Estrutura básica de uma ICC.

Dentre algumas aplicações de ICCs baseadas no emocional humano, podem ser citadas: substituição de tabuleiros pictográficos para pessoas com deficiência, auxílio à navegação de cadeiras de rodas [5], avaliação

de aspectos ergonômicos por estresse/cansaço, interação com robôs humanoides, entretenimento e jogos.

A capacidade do computador de reconhecer o estado afetivo humano é avaliado através do processamento e análise de eletroencefalograma (EEG) usando ferramentas computacionais de processamento de sinais, de extração de características e de reconhecimento de padrões. Assim, com vistas à aplicação em ICCs, o que se apresenta neste trabalho é o estudo de três técnicas de extração de características que são empregadas em trabalhos de reconhecimento de estados emocionais: características estatísticas [6-9]; características baseadas em PSD (*Power Spectral Density*) [10]; e características baseadas em HOC (*High Order Crossings*) [11,12]. A avaliação se realizou via classificação dos estados emocionais de *calma* e *estresse* usando o classificador baseado em K-NN (*K-Nearest Neighbours*) em modo *off-line* usando sinais EEG registrados nas posições F_{p1} , F_{p2} , F_3 , e F_4 (Sistema internacional 10-20).

Materiais e Métodos

Foram escolhidos os sinais EEG registrados nas posições F_3 e F_4 localizados na região frontal do cérebro e nas posições F_{p1} e F_{p2} localizados na região frontal polar; baseando-se nos estudos que relacionam o córtex pré-frontal do cérebro com as bases neurais da emoção [13]; assim, tais posições foram adotadas em trabalhos de reconhecimento de emoções [11, 12, 14]. Há outros trabalhos que empregam, além de outras posições, F_{p1} e F_{p2} . Em [15] foi apresentada uma tentativa de achar uma relação entre a localização de eletrodos e aspectos específicos de emoções faciais, em [8] desenvolveu-se um método que facilite o reconhecimento de emoções em robôs humanoides e em [16] foi proposto um sistema de reconhecimento de estresse emocional usando biosinais multimodais.

Neste trabalho utilizamos a base de dados DEAP (*Database for Emotion Analysis using Physiological Signals*) [17] que fornece um conjunto de dados para a análise de estados afetivos dos seres humanos, na qual foram registrados sinais de EEG de 32 posições, incluindo as posições F_{p1} , F_{p2} , F_3 , e F_4 , e sinais fisiológicos periféricos tais como eletroculograma, eletromiograma e temperatura. Tem-se 1280 (32×40) amostras correspondentes a 32 voluntários saudáveis (50% mulheres) com idades entre 19 e 37 (idade média de 26,9), os quais assistiram trechos de um minuto de 40 cliques de vídeos musicais e que autoavaliaram o estado emocional causado por cada vídeo fazendo uso das escalas de SAM (*Self Assessment Manikins*).

No método de autoavaliação de estados emocionais chamado Escalas de SAM [18] as intensidades das reações emocionais de excitação (*arousal*) e prazer (*valence*) são representadas usando figuras gráficas que expressam nove níveis, como mostrados na Figura 2. No banco de dados do IAPS [19] (*International Affective Picture System*), frequentemente usada em trabalhos de reconhecimento de emoções, [8,14], as imagens foram organizadas com base nas escalas de *arousal* e *valence*.




Fig. 2: Escalas SAM para os níveis de *arousal* (acima) e *valence* (abaixo).

Neste trabalho se emprega a definição de *estresse* e *calma* estabelecida em [16], na qual considera-se que o voluntário apresenta o estado emocional de estresse quando o nível de *arousal* fica abaixo de 4 e o nível de *valence* fica entre 4 e 6, ou seja,

$$(\text{arousal} < 4) \cap (4 < \text{valence} < 6), \quad (1)$$

e o estado calmo quando o nível de *arousal* fica acima de 5 e o nível de *valence* fica abaixo de 3, ou seja,

$$(\text{arousal} > 5) \cap (\text{valence} < 3). \quad (2)$$

Na Figura 3 são mostradas as regiões dos estados Estresse e Calmo, no plano *Arousal/Valence*, e as amostras correspondentes aos níveis de autoavaliação dos 40 cliques de um voluntário da base de dados. Pode-se ver que 6 amostras ficaram na região do estado Estresse, 7 ficaram na região do estado Calmo e 27 em nenhuma das regiões. Em geral, em toda a base de dados, das 1280 amostras se rotularam 141 com o estado Calmo, 129 com o estado Estresse e 1010 amostras não corresponderam a nenhum deles.




Fig. 3: Amostras de *Calma/Estresse* rotuladas no plano bidimensional *Arousal/Valence*.

Extração de Características

A base de dados DEAP fornece, além dos dados em bruto, dados pré-processados subamostrados a 128Hz e filtrados por um passa-banda de 4,0-45,0Hz. Destes, extraímos a média com referência comum usando

MATLAB e segmentamos em dois grupos: um de ensaios de 60 segundos, e outro de pré-ensaios de 3 segundos, cujos artefatos do eletroculograma foram removidos [17]. Na continuação são descritas as técnicas de extração de características avaliadas a partir dos sinais pré-processados. Nos três casos, após o cálculo do vetor de características, cada elemento do vetor é normalizado segundo a equação seguinte:

$$x_i^{norm} = \frac{x_i - \mu_x}{\sigma_x}, \quad (3)$$

onde μ_x é a média sobre todas as amostras e σ_x o desvio padrão. Os vetores de característica normalizados são usados posteriormente para o treinamento e para o teste de classificação.

A. Características Estatísticas

Na técnica proposta em [6], os tipos de características são simples de extrair; porém requerem alto custo computacional. Tais características vêm dadas pela média:

$$\mu_x = \frac{1}{N} \sum_{n=1}^N X(n); \quad (4)$$

pelo desvio padrão:

$$\sigma_x = \sqrt{\frac{1}{N} \sum_{n=1}^N (X(n) - \mu_x)^2}; \quad (5)$$

pela média do valor absoluto da primeira diferença:

$$\delta_x = \frac{1}{N} \sum_{n=1}^{N-1} |X(n+1) - X(n)|; \quad (6)$$

pela média do valor absoluto da primeira diferença normalizada:

$$\tilde{\delta}_x = \frac{1}{N} \sum_{n=1}^{N-1} |\tilde{X}(n+1) - \tilde{X}(n)|; \quad (7)$$

pela média do valor absoluto da segunda diferença:

$$\gamma_x = \frac{1}{N} \sum_{n=1}^{N-2} |X(n+2) - X(n)|; \quad (8)$$

e pela média do valor absoluto da segunda diferença normalizada:

$$\tilde{\gamma}_x = \frac{1}{N} \sum_{n=1}^{N-2} |\tilde{X}(n+2) - \tilde{X}(n)|; \quad (9)$$

Onde $\tilde{X}(n) = (X(n) - \mu_x) / \sigma_x$ e $X(n)$ vem dado pelo sinal pré-processado. Assim, o vetor de características estatísticas do sinal é representado por:

$$FV_{CarEst} = [\mu_x, \sigma_x, \delta_x, \tilde{\delta}_x, \gamma_x, \tilde{\gamma}_x]. \quad (10)$$

B. Densidade Espectral de Potência

A PSD está entre os métodos mais aplicados na caracterização de padrões de atividade cerebral presentes no sinal de EEG e já é usada em trabalhos de

reconhecimento de emoções [10]. Como os ritmos eletroencefalográficos estão definidos principalmente no domínio da frequência e a análise da PSD do sinal de EEG expressa o nível de atividade em cada banda de interesse (delta, teta, alfa, mu, beta e gama), isto permite que as componentes de potência possam ser interpretadas diretamente como ritmos cerebrais. Considerando uma abordagem baseada em Fourier, a PSD é estimada aqui pelo método de Welch. Nos gráficos da Figura 4 são mostradas as características PSD dos sinais EEG das derivações F_{p1} , F_{p2} , F_3 , e F_4 de uma amostra rotulada com o estado emocional de Estresse de um voluntário.

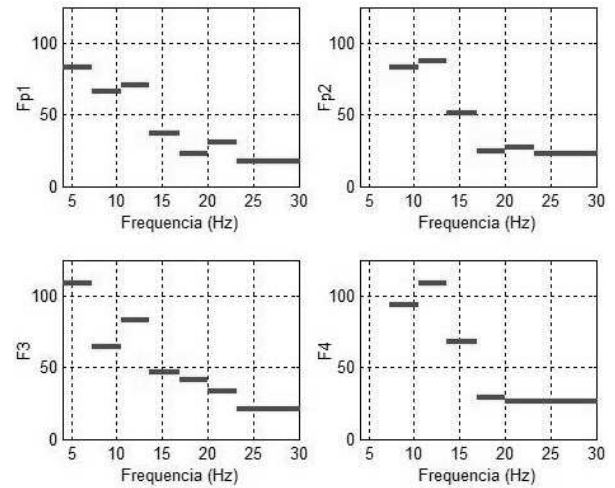


Fig. 4: Características espectrais baseadas em PSD dos sinais EEG das derivações F_{p1} , F_{p2} , F_3 , e F_4 .

Em todos os casos, as seis primeiras características (f_1 a f_6) representam a energia média em cada intervalo de 3,2 Hz a partir de 4,0 Hz, e a sétima característica (f_7) é dada pela potência média do sinal em toda a banda. O vetor de característica é dado por:

$$FV_{PSD} = [f_1, f_2, f_3, f_4, f_5, f_6, f_7] \quad (11)$$

C. Cruzamentos de Alta Ordem: HOC

Nesta técnica, o sinal EEG é interpretado como uma série temporal finita. É possível caracterizar uma série finita ($\{Z_t\}$, tal que $t = 1, \dots, N$), oscilante sobre o zero através do número de cruzamentos por este nível. Tal quantidade de cruzamentos pode ser alterada com a aplicação de um filtro para alterar a oscilação da série. Sob essa perspectiva é possível assumir o procedimento de filtragem-contagem aplicando-se um filtro à série e realizando a contagem de cruzamentos por zero [20]. A sequência de cruzamentos de alta ordem (HOC) é obtida depois de se aplicar uma sequência específica de filtros.

Considerando-se o operador diferença (∇) dado por $\nabla Z_t \equiv Z_t - Z_{t-1}$ como um filtro passa alto, define-se uma sequência de filtros da forma $\nabla^k \equiv \nabla_{k-1}$ para $k = 1, 2, 3, \dots$ ($\nabla_1 \equiv \nabla_0$) a fim de estimar a sequência D_k de cruzamentos HOC:

$$D_k = NCZ\{\mathfrak{S}_k(Z_t)\}, \quad k = 1, 2, 3, \dots; \quad t = 1, \dots, N \quad (12)$$

$NCZ\{\}$ indica a estimativa do número de cruzamentos por zero de cada filtro, na qual

$$\mathfrak{S}_k(Z_t) = \nabla^{k-1} Z_t = \sum_{j=1}^k \binom{k-1}{j-1} (-1)^{j-1} Z_{t-j+1} \quad (13)$$

Para calcular o número de passagens por zero, inicialmente é construída uma série temporal binária dada por:

$$X_t(k) = \begin{cases} 1, & \mathfrak{S}_k(Z_t) \geq 0 \\ 0, & \mathfrak{S}_k(Z_t) < 0 \end{cases}, \quad k = 1, 2, 3, \dots; \quad t = 1, \dots, N$$

e logo é realizada a contagem de mudanças de símbolo em $X_1(k), \dots, X_N(k)$, ou seja,

$$D_k = \sum_{t=2}^N [X_t(k) - X_{t-1}(k)]^2 \quad (14)$$

Neste trabalho a sequência HOC é utilizada para construir o vetor de características dos sinais EEG, formado como segue:

$$FV_{HOC} = [D_1, D_2, \dots, D_L] \quad (15)$$

Resultados

Foi utilizado o classificador baseado em K-NN para avaliar e comparar os resultados das três técnicas de extração de características descritas na seção anterior. No algoritmo K-NN todos os vetores de características correspondem a pontos no espaço n -dimensional, no qual os vizinhos mais próximos de um vetor de características (FV) são definidos em termos da distância euclidiana $d(FV_1, FV_2)$. Dessa forma, definido o conjunto de FV 's de treinamento mede-se a distância de um vetor de teste (FV_t) e se obtém os K vizinhos (FV_1, FV_2, \dots, FV_K) mais próximos de FV_t . Como resultado, o algoritmo retorna a classe na qual estão a maioria dos vizinhos mais próximos. Para mais detalhes sobre o algoritmo veja [21]. Foi utilizada a taxa de acerto (dada pela razão entre o número de amostras classificadas corretamente e o número total de amostras) como métrica para avaliar o desempenho da classificação. Para reduzir a possibilidade de desvios nos resultados devido à especialização do treinamento, utilizou-se a validação cruzada com o método (k -folds) em 10 iterações.

Nas Figuras 5(a), 5(b) e 5(c) são mostrados os resultados da classificação obtidos quando usada a técnica de extração de características estatísticas, PSD e HOC respectivamente. São mostrados os resultados de teste obtida em cada iteração da covalidação cruzada para $K = \{1, \dots, 8\}$ vizinhos no classificador K-NN. Os resultados obtidos com características estatísticas alcançaram uma taxa de acerto de $66,25\% \pm 0,6\%$, de $70,1\% \pm 0,45\%$ com com características baseadas em PSD e de $69,49\% \pm 0,53\%$ com características baseadas em HOC.




Fig. 5: Taxa de acerto na classificação de dois estados emocionais usando o algoritmo K-NN com: (a) Características estatísticas; (b) Características baseadas em PSD e (c) Características HOC.

Na tabela 1 é mostrada a matriz de confusão de uma iteração da covalidação cruzada quando consideradas as características HOC. Se considerando o estado Calmo como a classe positiva, pode-se ver que a taxa de falsos positivos, neste caso, foi dada por $37/(37+92)=0,2913$.

	Classe verdadeira		Total
	Estresse	Calmo	
Estresse	92	45	
Calmo	37	96	
Total de amostras	129	141	270

Tabela 1. Matriz de confusão de uma iteração com características HOC.

Conclusões

Comparando-se os resultados é possível ver que as técnicas baseadas em PSD e HOC alcançaram melhores resultados do que as baseadas em característica estatísticas do sinal temporal. Assim mesmo, estes resultados indicam que os dois estados emocionais, *estresse* e *calmo*, podem ser distinguidos a partir de sinais EEG capturadas nas posições F_{p1} , F_{p2} , F_3 , e F_4 já que os resultados obtidos com as três técnicas ficaram acima de 50%, descartando a aleatoriedade da informação. Por isso, os seguintes passos no andamento desta pesquisa seriam o teste e desenvolvimento de outras técnicas de classificação mais sofisticadas, assim como o estabelecimento de um protocolo de captura de sinais EEG, a fim de implementar uma base de dados especializada que permita alcançar resultados que sejam comparáveis com os resultados de trabalhos recentes. Na Tabela 2 são mostrados os resultados de pesquisas que usaram técnicas semelhantes às avaliadas neste trabalho. Os mesmos têm coerência com os resultados obtidos, visto que os trabalhos baseados nas técnicas de PSD [10] e HOC ([11] e [14]) obtiveram melhores resultados do que os que empregaram características estatísticas ([8] e [7]); no entanto, o trabalho [9] alcançou bons resultados considerando cinco estados emocionais e usando o perceptron multicamada.

	Ano	Técnica	Emoções	Precisão
Schaff et al [8]	2009	Est	3	47,11
Mampusti et al [7]	2011	Est	4	54,09
Chai et al [9]	2011	Est	5	95,00
Petrantonalis et al [11]	2009	HOC	6	83,30
Petrantonalis et al [14]	2011	HOC	6	84,72
Lin et al [10]	2010	PSD	5	82,29
Houseini et al [16]	2010	Wav	2	79,20

Tabela 2. Resultados alcançados em trabalhos recentes relacionados com reconhecimento de emoções.

Foi pertinente mencionar o resultado alcançado em [16], que utiliza características baseadas em *wavelets*, pois alcançou a precisão de 79,2% na classificação dos mesmos estados emocionais avaliados neste trabalho (*calma* e *estresse*), mas usando um número maior de canais EEG e um processo de rotulação de dados baseado não apenas na autoavaliação de cada voluntário, mas também na análise qualitativa e quantitativa de sinais psicofisiológicos. Sendo assim, ainda é difícil comparar os resultados alcançados em trabalhos de reconhecimento de emoções, pois a quantidade de estados emocionais varia de um estudo para outro, além das condições distintas no desenvolvimento de pesquisas nesta área, como por exemplo, o protocolo de captura de sinais EEG ou o modo de estimular as emoções dos voluntários. No entanto, é importante salientar trabalhos cujos resultados são muito relevantes na área de computação afetiva.

Agradecimentos

Os autores agradecem a CAPES e a CNPq/ FAPES (Processo 53666038, PPP-02/2011) pelo suporte financeiro a esta pesquisa.

Referências

- [1] Wolpaw J. R., Birbaumer N., McFarland D. J., Pfurtscheller G., Vaughan T. M.. Brain-computer interfaces for communication and control *Clinical Neurophysiology*. 2002;113:767-791.
- [2] Ferreira A., Bastos-Filho T.F., Sarcinelli-Filho M., J.L.M. Sanchez, Garcia J.C.G., Quintas M.M.. Improvements of a Brain-Computer Interface Applied to a Robotic Wheelchair:64 . 2010.
- [3] Picard R.W.. Affective computing: From laughter to IEEE. *Affective Computing, IEEE Transactions on*. 2010;1:11–17.
- [4] Molina Gary Garcia, Nijholt Anton, Twente Universiteit. Emotional Brain-Computer Interfaces 3rd International Conference on Affective Computing and Intelligent Interaction and Workshops, 2009. ACII 2009.. 2009.
- [5] Ferrez Pierre W., Millán José del R.. Error-Related EEG Potentials Generated during Simulated Brain-Computer Interaction *IEEE Trans. on Biomedical Engineering*. 2008;55.
- [6] Picard R.W., Vyzas Elias. Toward machine emotional intelligence: Analysis of affective physiological state *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2001;23:1175–1191.
- [7] Mampusti Ella T., Ng Jose S., Quinto Jarren James I., Teng Grizelda L., Suarez Merlin Teodosia C., Trogo Rhia S.. Measuring Academic Affective States of Students via Brainwave Signals Knowledge and Systems Engineering, 2011 Third International Conference on. 2011:226–231.
- [8] Schaaff Kristina, Schultz Tanja. Towards an EEG-based Emotion Recognizer for Humanoid Robots in The 18th IEEE International Symposium on Robot and Human Interactive Communication.;792–796 2009.
- [9] Yuen Chai Tong, San Woo San, Rizon Mohamed, Seong Tang Ching. Classification of Human Emotions from EEG signals using Statistical Features and Neural Network *International Journal of Integrated Engineering*. 2011.
- [10] Lin YP, Wang Chi-Hong, Jung TP, Wu TL. EEG-based emotion recognition in music listening *IEEE Transactions on Biomedical Engineering*. 2010;57:1798–806.
- [11] Petrantonakis Panagiotis C, Hadjileontiadis Leontios J. EEG-Based Emotion Recognition Using Hybrid Filtering and Higher Order Crossings in Affective Computing and Intelligent Interaction and Workshops, 2009. ACII 2009. 3rd International Conference on:1-6 2009.
- [12] Hadjileontiadis Panagiotis C., Petrantonakis Leontios J. Emotion Recognition From EEG Using Higher Order Crossings *IEEE Transactions on Information Technology in Biomedicine*. 2010;14:186–197.
- [13] Davidson R J, Jackson D C, Kalin N H. Emotion, plasticity, context, and regulation: perspectives from affective neuroscience. *Psychological bulletin*. 2000;126:890–909.
- [14] Petrantonakis P., Hadjileontiadis L.. A Novel Emotion Elicitation Index Using Frontal Brain Asymmetry for Enhanced EEG-Based Emotion Recognition. *IEEE Transactions on Information Technology in Biomedicine*. 2011;15:737–46.
- [15] Utama Nugraha P, Takemoto Atsushi, Nakamura Katsuki, Koike Yasuharu. Single-trial EEG data to classify type and intensity of facial emotion from P100 and N170 in International Joint Conference on Neural Networks:3156–3163 2009.
- [16] Hosseini M A. Emotional stress recognition system using EEG and psychophysiological signals: in *Biomedical Engineering and Computer Science (ICBECS)*, 2010 International Conference on: 1 – 6 2010.
- [17] Koelstra Sander, Muhl C, Soleymani M. DEAP: A database for emotion analysis using physiological signals *Affective Computing*. 2011:1–15.
- [18] Morris Jon D. SAM : The Self-Assessment Manikin An Efficient Cross-Cultural Measurement Of Emotional Response, *Observations: Journal of Advertising Research*. 1995;8.
- [19] Aris Siti Armiza Mohd, Taib Mohd Nasir, Lias Sahrim, Sulaiman Norizam. Feature Extraction of EEG Signals and Classification Using FCM 2011 *UkSim 13th International Conference on Computer Modelling and Simulation*. 2011:54–58.
- [20] Kedem B.. Spectral analysis and discrimination by zero-crossings *Proceedings of the IEEE*. 1986;74:1477 – 1493.
- [21] Duda R. O., Hart P. E., Stork D. G.. *Pattern Classification*. Wiley-Interscience2 ed. 2001.

154 - AVALIAÇÃO DE CARACTERÍSTICAS ESTATÍSTICAS E HOC DE SINAIS EEG NO RECONHECIMENTO DE ESTADOS EMOCIONAIS

Atencio AC, Ferreira A, Benevides A, Bastos TF, Menezes MLR, Pereira CE

PPGEE, UFES, Vitória/ES, Brasil, PPGEE, UFRGS, Porto Alegre/RS, Brasil

Objetivos: O que se apresenta neste trabalho é uma abordagem de reconhecimento de componentes emocionais presentes em sinais cerebrais com vistas à aplicação em ICCs (Interfaces Cérebro Computador) com o objetivo de avaliar a capacidade do computador de reconhecer o estado emocional do ser humano através do processamento e análise de eletroencefalograma (EEG) usando ferramentas computacionais de extração de características e reconhecimento de padrões. Para tal fim avalia-se foram avaliadas as duas técnicas de extração de características: 1) técnica baseada nas Características Estatísticas do sinal temporal consolidada dentro do estado da arte de reconhecimento de estados emocionais e 2) técnica baseada em coeficientes HOC (High Order Crossings) adotada recentemente em trabalhos de pesquisa da computação afetiva. **Métodos e resultados:** Foram usados sinais EEG da base de dados DEAP (Database for Emotion Analysis using Physiological Signals) registrados nas posições Fp1, Fp2, F3, e F4 como conjunto de dados para a análise de estados afetivos. Tal base de dados possui 1280 (32x40) amostras correspondentes a 32 voluntários saudáveis (50% mulheres) com idades entre 19 e 37 (com idade média de 26, 9), que assistiram trechos de um minuto de duração de 40 cliques de vídeos musicais e autoavaliaram seu estado emocional usando as escalas de SAM (Self Assessment Manikins). No método de SAM cada voluntário pode distinguir nove níveis de intensidade das reações emocionais de excitação (Arousal) e prazer (Valence). A partir destes resultados, a) rotula-se as amostras com Estresse quando 'Arousal pertence ao intervalo (4, 9) e ao mesmo tempo Valence pertence ao intervalo (4, 6)', e, b) rotula-se com o estado Calmo quando 'Arousal pertence ao intervalo (5, 9) e Valence pertence ao intervalo (1, 3)'. A avaliação das três técnicas de extração de características empregadas foi realizada na classificação de tais estados emocionais utilizando o classificador baseado em K-NN (K-Nearest Neighbours) em modo off-line. Como métrica para avaliar o desempenho da classificação foi utilizada a medida Precisão (que é obtida dividindo o número de amostras classificadas corretamente pelo número total de amostras); e com o fim de reduzir a possibilidade de desvios nos resultados devido à especialização do treinamento, utilizou-se a validação cruzada com o método (k-folds) em 10 iterações. Os resultados obtidos com características estatísticas alcançaram uma precisão na classificação de 66, 25% \pm 0, 6%. Já no caso da classificação com características baseada em coeficientes HOC obteve-se 69, 3% \pm 0, 3%, quando considerados filtros de sétimo ordem. **Conclusão:** Neste trabalho apresentou-se a avaliação de duas técnicas de extração de características sobre a abordagem de reconhecimento de componentes emocionais presentes em sinais cerebrais com vista à aplicação em ICCs. Comparando-se os resultados é possível notar que as técnicas baseadas em HOC alcançaram melhores resultados do que as baseadas em característica estatísticas do sinal temporal. Visto que os resultados ficaram acima do 50% é possível se afirmar que é possível distinguir entre os estados emocionais de Estresse e Calmo a partir de sinais EEG capturadas apenas nas posições Fp1, Fp2, F3, e F4, do lobo frontal do cérebro, que resultados próximos a 50 % indicariam que as características estão distribuídas aleatoriamente. **Apoio Financeiro:** CAPES e FAPES/CNPq (Processo 53666038, PPP-02/2011).

155 - DESEMPENHO DE IDOSOS BRASILEIROS NO TESTE CÓDIGOS DA BATERIA WECHSLER DE INTELIGÊNCIA PARA ADULTOS (WAIS-III)

Memória CM, Braz NG Gomes SCC, Gomes GC, Caramelli P

Instituto de Psiquiatria da USP, IPq, São Paulo/SP, Brasil, Programa de Pós-Graduação em Neurociências, UFMG, Belo Horizonte/MG, Brasil, Departamento de Fisioterapia da UFMG, FIT, Belo Horizonte/MG, Brasil

Objetivos: Códigos é um teste do WAIS-III que investiga a velocidade psicomotora e a capacidade de associar números a símbolos. No envelhecimento normal há diminuição da velocidade de processamento; entretanto, uma redução maior que a esperada, pode ser indicio de declínio cognitivo. Dessa forma, o teste Códigos mostra-se parâmetro útil para discriminação de idosos saudáveis daqueles com algum tipo de comprometimento. Em nosso país, o manual de correção do teste Códigos considera os idosos numa única faixa etária (65 a 89 anos), sem diferenciação quanto à escolaridade. O objetivo desse trabalho é propor novas normas de interpretação dos resultados, considerando o nível educacional, e de propor faixas de escolaridade mais estreitas para sua correção. **Métodos e resultados:** Noventa idosos participantes de pesquisas em duas instituições (Departamento de Fisioterapia da UFMG e Instituto de Psiquiatria da USP) foram submetidos ao teste Códigos. Os idosos foram classificados como cognitivamente preservados baseados na pontuação no MEEM. Os grupos diagnósticos foram comparados quanto à idade, escolaridade e desempenho no Códigos através de Análises de Variância (ANOVA). Para gênero foi utilizado teste de qui-quadrado. Correlações de Pearson foram utilizadas para testar as associações entre a pontuação no teste Códigos com escolaridade e idade. Não foi observada diferença em relação ao gênero ($p=0, 16$). O teste sofreu influência significativa da escolaridade ($r=0, 57$; $p=0, 0001$) e tendência à influência da idade ($r=0, 16$ e $p=0, 14$). As médias para escolaridade de 3 a 8 anos e acima de 8 anos foram, respectivamente, 30, 43 \pm 10, 79 e 44, 95 \pm 15, 32. As médias de acordo com a idade foram: 65-69 anos = 38, 88 \pm 13, 31; 70-74 anos = 47, 73 \pm 16, 05; 75-79 anos = 33, 33 \pm 14, 60 e acima dos 80 anos = 33, 17 \pm 11, 44. **Conclusão:** A escolaridade é potencialmente um viés na interpretação de resultados, sendo importante também a utilização de faixas etárias na correção do teste Códigos.

156 - ATIVIDADES AVANÇADAS DE VIDA DIÁRIA EM IDOSOS COM COMPROMETIMENTO LEVE: ADAPTAÇÃO CULTURAL E VALIDAÇÃO DE QUESTIONÁRIO PARA USO NO BRASIL

Almeida FCM, Cintra MTG, Cunha LCM, Silva MC, Bertola L, Bocardi M, Vieira R, Dornelas JM, Drumond T, Moraes EN, Malloy-Diniz LF, Bicalho MAC

Instituto Jenny de Andrade Faria de Saúde do Idoso e da Mulher, Jenny Faria, Belo Horizonte/MG, Brasil, Programa de Pós-graduação em Neurociências, Belo Horizonte/MG, Brasil

Objetivos: Traduzir e adaptar culturalmente para o Brasil o Questionário ADCS que avalia o desempenho das atividades de vida diária (AVD's) de idosos com comprometimento cognitivo leve (CCL), incluindo AVD's avançadas. **Métodos e resultados:** O processo de adaptação cultural foi realizado de acordo com protocolo aceito internacionalmente: duas traduções, seguida de uma síntese, retrotradução, julgamento por comissão de especialista e pré-teste. Até o momento, o questionário foi aplicado a uma amostra composta por 37 idosos (21 com CCL, 0 cognitivamente normal e 11 com demência de Alzheimer (DA) inicial), selecionados no Centro mais Vida/BH. A maioria foi constituída por homens 62, 5%, com média de idade de 73, 35 anos e média de escolaridade de 5, 21 anos. O questionário foi capaz de diferenciar os grupos CCL e DA com $P=0, 003$ e pontuação média de 63, 95 e 53, 67, respectivamente. **Conclusão:** O CCL tem sido considerado como um estágio pré-demencial. Há controvérsias quanto ao seu diagnóstico. O Questionário ADCS avalia atividades avançadas de vida diária mostrou-se eficiente na diferenciação de indivíduos acometidos por demência de Alzheimer e CCL. **Apoio Financeiro:** FAPEMIG