

PONTIFÍCIA UNIVERSIDADE CATÓLICA
DO RIO DE JANEIRO



Alexandre Ormiga Galvão Barbosa

**CONTROLE DE UM MANIPULADOR ROBÓTICO ATRAVÉS
DE UMA INTERFACE CÉREBRO MÁQUINA NÃO-INVASIVA
COM APRENDIZAGEM MÚTUA**

Dissertação de Mestrado

Dissertação apresentada como requisito parcial para obtenção do título de Mestre pelo Programa de Pós-Graduação em Engenharia Mecânica da PUC-Rio.

Orientador: Marco Antonio Meggiolaro

Rio de Janeiro, agosto de 2010



Alexandre Ormiga Galvão Barbosa

**CONTROLE DE UM MANIPULADOR ROBÓTICO ATRAVÉS
DE UMA INTERFACE CÉREBRO MÁQUINA NÃO-INVASIVA
COM APRENDIZAGEM MÚTUA**

Dissertação apresentada como requisito parcial para obtenção do título de Mestre pelo Programa de Pós-Graduação em Engenharia Mecânica da PUC-Rio. Aprovada pela Comissão Examinadora abaixo assinada.

Marco Antonio Meggiolaro

Orientador
Departamento de Engenharia Mecânica - PUC-Rio

Marley Maria Bernardes Rebuszi Vellasco

Departamento de Engenharia Elétrica - PUC-Rio

Luciano Luporini Menegaldo

Departamento de Engenharia Mecânica e de Materiais – IME

José Eugenio Leal

Coordenador Setorial do Centro Técnico Científico - PUC-Rio

Rio de Janeiro, 31 de agosto de 2010

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, do autor e do orientador.

Alexandre Ormiga Galvão Barbosa

Graduou-se em Engenharia Elétrica com ênfase em Sistemas Eletrônicos (Universidade Estadual do Rio de Janeiro) em 2008. No mesmo ano iniciou seu mestrado na área de Mecânica Aplicada na Pós-Graduação da PUC-Rio. Participa desde 2007 de projetos de robótica no Laboratório de Engenharia de Controle e Automação (LECA). Suas áreas de interesse abrangem robótica, bioengenharia e inteligência artificial.

Aos meus pais, Conrado e Denise.

Agradecimentos

À FAPERJ, pelo apoio financeiro;

À PUC-Rio, pelo seu excelente corpo acadêmico que me deu as bases para este estudo;

À UERJ pela base acadêmica para ingressar num programa de pós-graduação;

Ao orientador Marco Antonio Meggiolaro, pela oportunidade, incentivo, orientação e amizade, dentro e fora do centro acadêmico;

Ao professor Mauro Speranza Neto, pela oportunidade de conhecer o laboratório de engenharia de controle e automação, e pelo incentivo durante os anos de pesquisa.

Ao meu pai, que contribuiu, desde muito cedo, de forma imensurável para minha formação como engenheiro, e me ensinou a nunca desistir dos meus sonhos, não importando o quanto eles pareçam difíceis.

À minha mãe, por me ensinar a ser humano.

Às minhas irmãs, por todo apoio, incentivo e amor durante minha vida.

À minha namorada Dianna de Paula Renner, por compartilhar meus momentos de alegria e tristeza, me dando forças para nunca desanimar.

Aos alunos de graduação e pós-graduação que diariamente trabalham no laboratório e me ajudaram tanto para a conclusão desse trabalho.

Aos meus amigos, pela descontração e alegria.

Resumo

Barbosa, Alexandre Ormiga Galvão. **Controle de um manipulador robótico através de uma interface cérebro máquina não-invasiva com aprendizagem mútua.** Rio de Janeiro, 2010. Dissertação de Mestrado - Departamento de Engenharia Mecânica, Pontifícia Universidade Católica do Rio de Janeiro.

Esse trabalho apresenta o desenvolvimento de uma interface cérebro-máquina (Brain Machine Interface – BMI) como um meio alternativo de comunicação para uso na robótica. O trabalho engloba o projeto e construção de um eletroencefalógrafo (EEG), assim como o desenvolvimento de todos os algoritmos computacionais e demais técnicas necessárias para o reconhecimento de atividades mentais. A interface cérebro-máquina desenvolvida é utilizada para comandar os movimentos de um manipulador robótico MA2000, associando quatro atividades mentais distintas a quatro movimentos do manipulador. A interface baseia-se na análise de sinais eletroencefalográficos, extraindo desses características que podem ser classificadas como uma atividade mental específica. Primeiramente os sinais EEG são pré-processados, filtrando-se os ruídos indesejados, utilizando filtros espaciais para o aumento da resolução espacial do escalpe, e extraindo-se características relevantes à classificação das atividades mentais. Em seguida, diferentes modelos de classificadores são propostos, avaliados e comparados. Por último, duas implementações dos classificadores são propostas para aumentar o índice de comandos corretos para o manipulador. Em uma das implementações, obtiveram-se taxas de acerto de até 91% dos comandos, enquanto a taxa de comandos incorretos chegou ao mínimo de 1.25% após 400 tentativas de controle do manipulador.

Palavras-chave

Interface Cérebro Máquina; Redes Neurais; Eletro-encefalograma; Manipulador Robótico; Condicionamento operante; Transformada Wavelet; Filtros digitais; Reabilitação.

Abstract

Barbosa, Alexandre Ormiga Galvão. **CONTROL OF A ROBOTIC ARM THROUGH A BRAIN MACHINE INTERFACE WITH MUTUAL LEARNING**. Rio de Janeiro 2010. MSc Dissertation – Mechanical Engineering Department, Pontifical Catholic University of Rio de Janeiro.

This work presents the development of a brain machine interface as an alternative communication channel to be used in Robotics. It encompasses the implementation of an electroencephalograph (EEG), as well as the development of all computational methods and necessary techniques to identify mental activities. The developed brain machine interface (BMI) is applied to activate the movements of a MA2000 robotic arm, associating four different mental activities to robotic arm commands. The interface is based on EEG signal analyses, which extract features that can be classified as specific mental activities. First, a signal preprocessing is performed from the EEG data, filtering noise, using a spatial filter to increase the scalp signal resolution, and extracting relevant features. Then, different classifier models are proposed, evaluated and compared. Finally, two implementations of the developed classifiers are proposed to improve the rate of successful commands to the robotic arm. In one of the implementations, a rate of successful commands up to 91% was obtained, with wrong commands as low as 1.25%, after 400 attempts to control the robotic arm.

Key Words

Brain Machine Interface; Neural Networks; Electroencephalograph; Robotic arm; Operant Conditioning; Wavelet Transform; Digital filters; Rehabilitation.

Sumário

Lista de Símbolos e Abreviações	12
1 Introdução	13
2 Fundamentos Teóricos	18
2.1. Interfaces cérebro máquina	18
2.2. Sinais Eletroencefalográficos.	19
2.3. Condicionamento Operante.	22
2.4. Potenciais Evocados	24
2.5. Implantes Corticais	25
2.6. Artefatos	27
2.7. Redes Neurais Artificiais	28
2.8. Cinemática de um Manipulador Robótico	30
3 Desenvolvimento de um Eletroencefalógrafo	31
3.1. Descrição	31
3.2. Circuito de Proteção	32
3.3. Amplificação	33
3.4. Right-Leg Driver (RLD)	37
3.5. Conversão Analógico-Digital	38
3.6. Construção do Eletroencefalógrafo.	39
4 Pré-Processamento e Extração de Características	41
4.1. Eliminação do Ruído Remanescente	41
4.2. Filtragem Espacial	43
4.3. Extração de Características	44
4.4. Detecção de Artefatos	49
5 Reconhecimento de Padrões	50
5.1. Comitê de Redes Neurais MLP com DPR	51
5.2. Múltiplas Redes Modulares (MRM).	52
5.3. Modelo Hierárquico (MH).	53
5.4. Implementação de Disparo com MRM.	55
5.5. Implementação Estatística com o Modelo Hierárquico	57

6 Aplicação da BMI a um Manipulador Robótico	59
6.1. Controle do Manipulador MA-2000	59
6.2. Protocolo de Treinamento.	63
6.3. Uso da Interface.	65
6.4. Experimentos e Resultados	66
7 Conclusões e Trabalhos Futuros	79
Bibliografia	82
Anexos	87
Anexo I	88
Anexo II	97
Anexo III	99
Anexo IV	101
Anexo V	103
Anexo VI	111

Lista de figuras

Figura 1 - Córtex Cerebral (17).	18
Figura 2 - Aplicações de uma interface cérebro máquina (23-24).	19
Figura 3 - Sinais eletroencefalográficos durante diferentes atividades (26).	20
Figura 4 - 10-20 System of Electrode Placement (29).	20
Figura 5 – Sinal típico associado à Banda Delta em função do tempo (em s).	21
Figura 6 - Sinal típico associado à Banda Theta em função do tempo (em s).	21
Figura 7 - Sinal típico associado à Banda Alpha em função do tempo (em s).	21
Figura 8 - Sinal típico associado à Banda Beta em função do tempo (em s).	22
Figura 9 - Interface cérebro máquina por potenciais evocados	24
Figura 10 - Potencial evocado.	25
Figura 11 - Macaco utilizando uma prótese cortical para se auto-alimentar (47).	26
Figura 12 - Artefatos musculares e oculares em sinais EEG (4).	27
Figura 13 - Estrutura de uma rede neural	28
Figura 14 - Modelo do neurônio artificial.	29
Figura 15 - Cinemática de um manipulador robótico.	30
Figura 16 - Electro-Cap e acessórios.	31
Figura 17 - Diagrama de um canal do eletroencefalógrafo.	32
Figura 18 - Circuito de proteção.	33
Figura 19 - Amplificador instrumental INA114 – Texas Instruments	34
Figura 20 - Segundo estágio de amplificação.	34
Figura 21 - Terceiro estágio de amplificação.	35
Figura 22 - Diagrama de Bode do amplificador.	36
Figura 23 - RLD para o circuito integrado INA114	37
Figura 24 - RLD para vários canais de amplificação.	38
Figura 25 - NI USB-6009.	38
Figura 26 - Renderização da eletrônica do eletroencefalógrafo.	39
Figura 27 - Eletroencefalógrafo com a caixa metálica aberta.	40
Figura 28 - Sinal EEG na posição Cz.	40
Figura 29 - Resposta em frequência do filtro Butterworth.	42
Figura 30 - Resposta em frequência do filtro <i>Notch</i> .	43
Figura 31 - Sinais estimados pelo método de Hjorth (à direita).	44
Figura 32 - Esquemático da transformada wavelet discreta (DWT).	46
Figura 33 - Árvore de decomposição wavelet discreta para 1kHz.	46
Figura 34 - Transformada wavelet discreta de um sinal EEG.	47

Figura 35 - Comitê de redes MLP com DPR.	51
Figura 36 - Classificador baseado em múltiplas redes modulares.	52
Figura 37 - Modelo Hierárquico.	54
Figura 38 - Exemplo de implementação de disparo com MRM.	56
Figura 39 - Exemplo de implementação estatística.	58
Figura 40 - Sistema completo.	59
Figura 41 – Manipulador robótico MA2000.	59
Figura 42 - Modelo esquemático do MA2000.	60
Figura 43 - Eletrônica de controle do manipulador robótico.	61
Figura 44 - Parâmetros de Denavit Hartenberg para os três primeiros elos do MA2000.	61
Figura 45 - Cálculo da cinemática inversa para um manipulador de dois elos.	62
Figura 46 - Esquemático 3D dos três primeiros elos do MA2000.	62
Figura 47 - Correspondência das atividades mentais na ativação de um manipulador robótico.	65
Figura 48 - Confiabilidade x Número de sorteios.	68
Figura 49 - Validação da solução analítica para dois padrões, usando o método de Monte Carlo.	69
Figura 50 - Confiabilidade x Número de tentativas máximo N_{max} ($N_{min} = 5$).	70
Figura 51 - Análise da variação da condição de ocorrência para $N_{max} = 15$.	71
Figura 52 - Confiabilidade de classificação x N_{min} para $N_{max} = 15$.	71
Figura 53 - Número de tentativas médio para obtenção de resultado x N_{min} .	72
Figura 54 - Histograma das classificações obtidas pelo número de tentativas.	73
Figura 55 - Confiabilidade x N_{min} para três padrões.	74
Figura 56 - Experimento com a interface para controle do manipulador.	75
Figura 57 - Experimento com o robô móvel: 1- Eletrodos; 2-Computador; 3- EEG; 4-PCTx Link; 5-Transmissor RF; 6-Robô móvel.	76
Figura 58 - Correspondência das atividades mentais: robô móvel.	77

Lista de Tabelas

Tabela 1 - Comparação da influência de parâmetros escolhidos.	48
Tabela 2 - Matriz de confusão do modelo MRM.	53
Tabela 3 - Matriz de confusão do modelo hierárquico.	54
Tabela 4 - Taxas de acerto dos diferentes classificadores.	55
Tabela 5 - Confiabilidade de classificação.	73
Tabela 6 - Matriz de confusão para três padrões.	74
Tabela 7 - Resultados da aplicação da BMI ao manipulador robótico.	75
Tabela 8 - Resultados da aplicação a um robô móvel.	77

Lista de Símbolos e Abreviações

A/D – Analógico / Digital
BMI – *Brain Machine Interface*
CMRR – *Common mode rejection rate*
DC – *Direct Current*
DOF – *Degree of Freedom*
DPR – *Driven Pattern Replication*
DSP – *Digital Signal Processor*
DWT – *Discrete Wavelet Transform*
EAL – Esclerose Amiotrófica Lateral
EEG – Eletroencefalograma
EMG – Eletromiografia
ICSP – *In Circuit Serial Programming*
MLP – *Multi Layer Perceptron*
RAM – *Random Access Memory*
RLD – *Right Leg Driver*
RSM – Ritmo Sensório Motor
SCD – *Scalp Density Current*
SCP – *Slow Cortical Potential*
SL – *Surface Laplacian*
SMD – *Surface Mounted Device*
SNA – Sistema Nervoso Autônomo
SNC – Sistema Nervoso Central
TTL – *Transistor Transistor Logic*

1 Introdução

A interação entre humanos e máquinas tem sido um campo de pesquisa e desenvolvimento em expansão nos últimos anos. As três últimas décadas testemunharam o aparecimento de interfaces homem-máquina inovadoras que utilizam voz, visão, tato e a combinação desses elementos como base para um sistema de comunicação (1).

Nos últimos 15 anos, teve início o estudo de sistemas de comunicação baseados na análise de sinais elétricos cerebrais, motivado principalmente pelo aumento na qualidade de vida de pessoas portadoras de deficiência física que esses sistemas podem oferecer. Com os avanços recentes em neurociência, processamento de sinais, inteligência artificial, e equipamentos eletrônicos, tornou-se possível o desenvolvimento de uma interface de comunicação direta entre cérebro e máquina (“*Brain Machine Interface*” – BMI) (2). Os usuários desses sistemas podem controlar um dispositivo apenas através de determinadas atividades mentais, que são então associadas a uma ação do dispositivo controlado. Algumas aplicações típicas incluem posicionamento de um cursor, programas para soletrar e o comando de sistemas mecânicos.

No que se diz respeito ao tipo de treinamento utilizado, as BMI's podem ser divididas em dois tipos: as baseadas em potenciais evocados e as baseadas no condicionamento operante. O uso dos potenciais evocados é feito apresentando ao usuário diferentes estímulos visuais simultâneos e intermitentes, que podem variar em frequência e intensidade, e então medindo o potencial evocado, que dependerá da atenção do usuário a um dos estímulos visuais. Já o condicionamento operante depende única e exclusivamente de atividades mentais do usuário que resultem numa variação de potencial elétrico no córtex cerebral como, por exemplo, o movimento imaginário de algum membro do corpo ou outra atividade cognitiva relacionada à fala ou ao raciocínio lógico.

As atividades mentais geram diversos fenômenos e sinais elétricos que podem ser medidos utilizando-se os sensores adequados. Os sensores utilizados por uma BMI a definem como invasiva, no caso de eletrodos implantados diretamente no cérebro, ou não-invasiva, no caso de eletrodos

posicionados no escalpe do usuário, medindo sinais eletroencefalográficos (EEG). Uma vez medidos, esses sinais são então classificados por modelos matemáticos de classificação e convertidos em alguma ação da BMI, o que pode representar um novo recurso de comunicação para pessoas portadoras de deficiência física.

Em particular, pode-se considerar o uso deste sistema para pacientes de Esclerose Amiotrófica Lateral (EAL), uma doença motora progressiva de etiologia desconhecida, que resulta na completa destruição do sistema motor central e periférico. Entretanto, esta doença pouco afeta as funções sensoriais e cognitivas (3). Não há tratamento disponível para EAL, os pacientes são obrigados a aceitar respiração e alimentação artificiais (após a doença destruir a função respiratória e bulbar) para o resto da vida. A doença progride até que o paciente perca o controle da última resposta muscular, que é normalmente dos músculos dos olhos ou do esfíncter externo. A condição resultante dessa doença é a chamada síndrome do encarceramento completa ou, no caso de ainda haver controle de algum músculo, simplesmente de síndrome do encarceramento. Outras doenças que resultam na síndrome do encarceramento são o derrame subcortical (e outras lesões graves do cérebro), a síndrome de Guillain-Barre e, em casos raros, o mal de Parkinson e a esclerose múltipla.

Baseado no grande conhecimento e experiência clínica com SCP (*Slow Cortical Potential*), Birbaumer et al. (4) desenvolveram uma interface cérebro computador para pacientes com EAL. *Slow cortical potentials* são alterações da atividade elétrica cortical, que estão relacionadas ao nível de excitação das regiões corticais subjacentes. SCP's negativas representam alta excitação, enquanto SCP's positivas são reflexo da baixa atividade elétrica cortical ou até mesmo da inibição da mesma. Acredita-se que, em tarefas cognitivas, a amplitude das ondas negativas lentas está relacionada à alocação de recursos neurais (5).

Os pacientes de Birbaumer foram então treinados a produzir SCP's positivos ou negativos de acordo com um estímulo auditivo. Esses pacientes olhavam suas variações no SCP ou, no caso de insuficiência visual, recebiam um retorno auditivo, além de uma recompensa para mudanças de potenciais bem sucedidas (6). Após atingir 70% de controle, letras ou palavras eram apresentadas numa tela de computador ou ditas por um programa de voz. Os pacientes eram capazes então de selecionar uma letra gerando SCP's após a aparição da letra desejada (7).

Wolpaw e colaboradores (8) fizeram uma série de experimentos, a maioria com pessoas saudáveis, utilizando o ritmo sensório motor (RSM) ao invés do SCP como objetivo da resposta do cérebro. Em um grupo de pacientes (dois com graves lesões na medula espinhal), Wolpaw e McFarland (9) demonstraram que o controle multidimensional de um cursor numa tela de computador pode ser aprendido em poucas seções de treinamento. Os pacientes eram capazes de movimentar o cursor em menos de 10 segundos até um dos oito objetivos que apareciam aleatoriamente na tela. A flexibilidade, velocidade e desempenho no aprendizado foram semelhantes aos observados quando métodos invasivos de implantes corticais eram testados em animais. A experiência de Wolpaw e McFarland consistia numa simples cobertura com eletrodos das áreas corticais das mãos e pés com filtros lineares e algoritmos de detecção usados para redução e quantificação dos sinais. A maioria dos usuários empregou a imaginação do movimento das mãos esquerda e direita e dos pés para controlar a interface RSM.

O grupo de pesquisadores de Albany e Tubingen (8) comparou a viabilidade e desempenho das interfaces baseadas em SCP, RSM e P300 (desenvolvido por Farwell e Donchin em 1988) com experimentos em sete pacientes com EAL em fase de pré-encarceramento. Os resultados foram bem conclusivos: todos os pacientes atingiram desempenho satisfatório, com mais de 70% de tentativas bem sucedidas, após 20 seções de treinamento com a interface RSM. Quatro dos sete pacientes conseguiram soletrar palavras com a interface P300, mas nenhum atingiu desempenho satisfatório com a interface SCP, apesar de apresentarem diferenças significativas entre SCP's positivos e negativos. Os pacientes descritos antes por Birbaumer em 1999 obtiveram sucesso com a interface SCP, mas somente após muitas seções de treinamento.

Juntamente com a introdução de experiências clínicas controladas para comparar os diferentes tipos de interface, o grupo de Albany criou o website BCI2000 (10), que fornece gratuitamente programas computacionais modulares para a aplicação em pesquisa e uso clínico de interfaces cérebro máquina. Atualmente, mais de 100 laboratórios utilizam e contribuem com o sítio de internet BCI2000, melhorando os módulos tanto de *hardware* quanto de *software*. O objetivo do projeto BCI2000 é alcançar uma interface cérebro máquina universal, certificada, e de fácil uso que permita o uso de SCP, RSM e P300 como sinais base, numa rede mundial de participantes que contribuam para a melhora contínua das aplicações dessas interfaces (11).

Outro ramo de pesquisas em BMI's se dá na área de implantes corticais invasivos como meio de se obter sinais cerebrais. Kennedy et al. (12) publicaram em 2004 alguns casos de pacientes com EAL em diferentes estágios (nenhum deles com síndrome do encarceramento), com micro eletrodos implantados no córtex cerebral. Alguns pacientes aprenderam a usar o programa para soletrar variando picos de potenciais nos micro eletrodos, numa configuração binária (ativo ou não ativo).

Brunner et al. (13) implantaram eletrodos sub-durais (eletrodos em contato direto com o cérebro) em pacientes e demonstraram que o controle do RSM pode ser alcançado em uma ou mais seções de treinamento. O grupo do brasileiro Miguel Nicolelis (14) demonstrou em macacos, após um extenso treinamento de alcançar e segurar um objetivo, que o padrão de disparo de 32 neurônios é suficiente para controlar diretamente um membro artificial para a execução da tarefa. Atualmente Nicolelis também dirige o Instituto Internacional de Neurociências de Natal.

Limitações típicas de uma BMI não-invasiva, como sinais ruidosos, respostas demoradas, e problemas com a pele e o eletrodo com longos períodos de gravação de sinais, fazem uma interface invasiva parecer uma alternativa tentadora (11). Entretanto, é de extremo valor oferecer às pessoas portadoras de deficiência física (principalmente as que sofrem de síndrome do encarceramento) uma solução com valor inestimável, que seja isenta de riscos cirúrgicos e conseqüentemente que tenha custos reduzidos.

Sendo assim, o objetivo geral deste trabalho é o estudo e desenvolvimento dos elementos envolvidos em uma interface cérebro-máquina não-invasiva baseada na análise das alterações do ritmo sensorio motor (RSM) durante a imaginação de movimentos.

Como objetivos específicos, têm-se o desenvolvimento de um eletroencefalógrafo portátil de baixo custo, o estudo de diferentes técnicas de classificação baseadas em inteligência artificial, o desenvolvimento de uma metodologia de treinamento do usuário, e por fim a sua aplicação em um manipulador robótico.

Esta dissertação está dividida em mais 6 capítulos. No capítulo 2 faz-se uma apresentação dos tópicos teóricos necessário à boa compreensão do trabalho. Inicialmente são apresentados diferentes métodos utilizados na aquisição de sinais biológicos com aplicação em interfaces cérebro-máquina, seguidos da apresentação das diferentes classes dessas interfaces. O capítulo

apresenta também uma breve explicação do processamento de sinais biológicos e da técnica de inteligência artificial envolvida.

O capítulo 3 descreve detalhadamente o circuito eletrônico do eletroencefalógrafo, incluindo os circuitos de proteção, filtragem e amplificação dos sinais, e a aquisição com o conversor analógico digital.

No capítulo 4 são descritas as técnicas de pré-processamento de sinais, utilizadas para extração de características dos sinais cerebrais, bem como a avaliação e comparação entre tais técnicas. A técnica de pré-processamento de sinal escolhida é então utilizada como base para gerar vetores característicos a serem classificados por meio de técnicas de inteligência artificial descritas no capítulo 5.

A aplicação da interface em um manipulador robótico é então descrita no capítulo 6, onde é apresentada a modelagem do manipulador, bem como o *software* e a eletrônica de controle do mesmo. Nesse capítulo relatam-se também os experimentos e simulações realizadas.

No capítulo 7 são feitas as conclusões do trabalho e as propostas de trabalhos futuros.

2 Fundamentos Teóricos

2.1. Interfaces cérebro máquina

Interfaces cérebro-máquina (*“Brain Machine Interface”* – BMI) são sistemas de comunicação que permitem o usuário interagir com o ambiente apenas por meio de sua atividade cerebral, dispensando o uso das comunicações tradicionais com os seus nervos e músculos. Como todo sistema de comunicação, uma BMI possui entradas (sinais eletrofisiológicos resultantes do monitoramento das atividades cerebrais), saídas (ações do dispositivo controlado), elementos que convertem entradas em saídas, e por fim um protocolo que determina a sua operação (15). Essas interfaces requerem a análise em tempo real de estados mentais provenientes do usuário.

Diferentes áreas corticais cerebrais (Figura 1) são ativadas de acordo com diferentes pensamentos ativos. Do córtex cerebral saem os impulsos nervosos que planejam, iniciam e comandam os movimentos voluntários, e com ele estão relacionados os fenômenos psíquicos (16). Dessa forma, é possível que o usuário altere voluntariamente ou não os sinais elétricos emitidos pelo córtex cerebral.

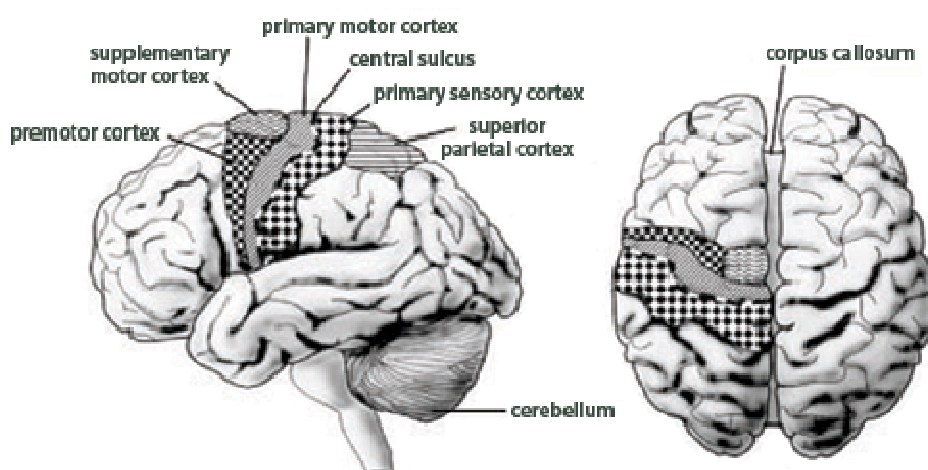


Figura 1 - Córtex Cerebral (17).

As informações desses “estados mentais” podem ser obtidas por diferentes fenômenos eletrofisiológicos e métodos de aquisição, como o implante

cortical e a leitura de sinais EEG, que incluem os fenômenos de potenciais evocados (conhecidos também como potenciais relacionados a evento) e variação do RSM via condicionamento operante. Tanto o potencial evocado quanto o condicionamento operante são métodos normalmente não-invasivos, ou seja, não requerem cirurgia.

Uma vez obtidas as informações dos estados mentais, é necessário um pré-processamento dessas informações para extração de características relevantes que serão então classificadas por meio de algoritmos de reconhecimento, ou processadas de forma a equacionar o modo de operação da interface. Para isso faz-se uso de diversos algoritmos computacionais assim como de inteligência computacional.

As aplicações de uma interface cérebro máquina incluem o controle de elementos de um ambiente virtual, como o posicionamento de um cursor (2), programas para soletrar (18), e controle de dispositivos externos, como um robô móvel (19) ou uma prótese (20). Aplicações recentes de interfaces não-invasivas na área da robótica compreendem o controle de uma cadeira de rodas (21) (22) (23) e o controle de um robô Kepera (24), vide Figura 2.




Figura 2 - Aplicações de uma interface cérebro máquina (23-24).

2.2.Sinais Eletroencefalográficos.

A natureza elétrica do sistema nervoso humano tem sido estudada há mais de um século. É sabido que a variação do potencial elétrico no escalpe humano é reflexo de atividades funcionais emergentes do cérebro (25). Esta variação do potencial pode então ser medida através de um conjunto de eletrodos distribuídos ao longo do escalpe para aferir a diferença de potencial entre dois desses eletrodos, que será filtrada, amplificada e registrada. Os dados

resultantes desse processo são chamados de EEG (Figura 3) e constituem a base do principal tipo de interfaces cérebro máquina não-invasivas.




Figura 3 - Sinais eletroencefalográficos durante diferentes atividades (26).

O posicionamento dos eletrodos em uma aquisição de sinais eletroencefalográficos não é aleatório, e obedece a convenção “10-20 System of Electrode Placement” (Figura 4) (27), que é baseada na relação entre a área do eletrodo e a região cortical situada abaixo da mesma.

A análise de sinais EEG é complexa, devido à grande quantidade de informação contida nos mesmos. Acredita-se que os sinais EEG são resultado de uma sincronização da soma de disparos de potencial elétrico resultantes das atividades sinápticas (28). Dessa forma, para melhor estudo e compreensão, os sinais eletroencefalográficos são classificados de acordo com a frequência em que são emitidos (e algumas características particulares) nas seguintes bandas:




Figura 4 - 10-20 System of Electrode Placement (29).

- **Delta:** é composta pelos sinais com frequência de 0.5Hz até 4Hz (Figura 5), observada em pessoas muito jovens, regiões lesionadas do cérebro, e durante as fases 2 e 3 do sono (sono profundo).




Figura 5 – Sinal típico associado à Banda Delta em função do tempo (em s).

- **Theta:** é composta pelos sinais com frequência de 4Hz até 8Hz, e com amplitude em torno de 20 μ V (Figura 6). Essa banda de frequência está relacionada ao estresse emocional, principalmente desapontamento e frustração, e também à meditação e estado criativo.




Figura 6 - Sinal típico associado à Banda Theta em função do tempo (em s).

- **Alpha:** é composta pelos sinais com frequência de 8Hz até 13Hz e amplitude entre 30 e 50 μ V (Figura 7). Está relacionada ao relaxamento mental, sendo mais atuante durante o fechar dos olhos. Essa banda de frequência pode ser praticamente suprimida com a abertura dos olhos ou com o pensamento ativo.




Figura 7 - Sinal típico associado à Banda Alpha em função do tempo (em s).

- **Beta:** é composta pelos sinais com frequência maiores que 13Hz, e possui baixa amplitude, em torno de 5 a 30 μ V (Figura 8). Essa banda de frequência é observada durante o pensamento ativo, estado de atenção, e durante a solução de problemas concretos.




Figura 8 - Sinal típico associado à Banda Beta em função do tempo (em s).

Além das classificações já mencionadas, os sinais eletroencefalográficos situados na banda de 8-12Hz (mesma faixa de frequência da banda Alpha) e adquiridos sobre o córtex motor cerebral (enquanto os sinais da banda Alpha são adquiridos na região occipital) são chamados de ritmos MU, ou ritmo sensório-motor (RSM). O RSM é observado durante o movimento ou o planejamento do mesmo, sem que haja a necessidade de executar o movimento. Esses sinais são especialmente interessantes em aplicações de interfaces cérebro máquina, pois são mais facilmente controláveis espontaneamente para a maioria das pessoas. Assim sendo, juntamente com um protocolo de treinamento do usuário, a análise do RSM e de algumas das bandas dos sinais EEG possibilita a criação de uma interface baseada no condicionamento operante.

2.3. Condicionamento Operante.

O condicionamento operante está relacionado a métodos de comportamento na psicologia (30) (31). De acordo com esses métodos, uma pessoa consegue obter habilidades de controle através de um reforço de aprendizado adequado.

Tentativas de obtenção de controle através do condicionamento operante por reforços de aprendizado começaram na década de 1950, quando alguns clínicos usaram o então chamado *neurofeedback* para tratar pessoas que sofriam de déficit de atenção, hiperatividade, depressão, e até mesmo epilepsia.

Entre as décadas de 1960 e 1970, Neal E. Miller e colaboradores (32) se opuseram ao tradicional conhecimento do sistema nervoso autônomo (SNA) como sendo autônomo e independente do controle voluntário do sistema nervoso central (SNC). Miller contestou a visão de que controle voluntário é obtido por condicionamento operante, enquanto que a alteração das funções involuntárias do SNA é aprendida pelo método clássico de condicionamento (Pavlov), uma visão enfatizada por Skinner em 1953 (33).

Miller apresentou evidências experimentais em ratos curarizados¹ e ventilados artificialmente que mostraram que, mesmo após um longo tempo de curarização de algumas semanas, os animais aprenderam a aumentar e diminuir sua frequência cardíaca, fluxo de sangue, e a dilatar e contrair artérias periféricas, através de um paradigma de condicionamento operante, recompensando os animais pelo aumento e diminuição dessas funções fisiológicas.

Os resultados mais significativos e populares no campo do condicionamento operante foram relativos à auto-regulação dos sinais cerebrais (34). O aumento e a diminuição dos sinais EEG na banda Alpha foram estudados para criar um estado meditativo com muitos benefícios físicos e comportamentais. A variação das ondas Theta apresentou efeitos significativos no estado de alerta e atenção (35). Stermán (36) foi o primeiro a propor o autocontrole de crises epiléticas através do aumento do ritmo sensório-motor (RSM). O RSM em seres-humanos é obtido exclusivamente sobre as áreas sensório-motoras, com frequências entre 10 e 20 Hz e amplitudes variáveis. Pfurtscheller e colaboradores (37) localizaram a origem do RSM em humanos nas regiões sensório-motoras. A imaginação do movimento das mãos, por exemplo, abole o RSM na região relativa às mãos. O movimento imaginário ou real das pernas bloqueia o RSM nos sulcos inter-hemisféricos. Pfurtscheller chamou esses fenômenos de sincronização de “sincronização relacionada a evento”.

Os resultados do controle do RSM em animais e pacientes aparentavam demonstrar que a manipulação dos membros motores não era necessária para o controle do RSM, pois durante a imaginação do movimento nenhuma alteração era observada nos sinais eletromiográficos (EMG) dos músculos dos braços, enquanto era presente a de sincronização relacionada a evento. O sucesso no controle do RSM em pacientes completamente paralisados confirmou, então, a independência do RSM em relação à ação do sistema nervoso central, mostrando não haver a necessidade de qualquer movimento real para se alterar o RSM, i.e., movimentos imaginados poderiam ser detectados (11).

A imaginação do movimento pode ser vista como um ensaio mental de uma atividade motora sem que a mesma seja executada. É amplamente aceito

¹ Sob a influência do curare para fins terapêuticos. Curare é uma composição de alcalóides extraídos de vários arbustos da família das Loganiáceas, principalmente das espécies *Strychnos castelnaui*, *S. crevauxiana* e *S. toxifera*, hoje usada em anestesia, para redução de espasmos no tétano e para produção de relaxamento muscular na terapêutica de choque.

que esse ensaio envolve regiões e funções do cérebro que são similares às envolvidas no planejamento e preparação da atividade motora em questão (38). Somadas à imaginação do movimento, outras atividades mentais que demonstraram alteração dos sinais eletroencefalográficos e, além disso, especializações hemisféricas, foram: imaginação de um objeto geométrico em três dimensões e a rotação de tal objeto (39), atividade mental relacionada à fala e.g. composição mental de uma carta (40), e atividade mental aritmética, como efetuar contas de subtração e multiplicação “de cabeça” (41). Essas atividades, no entanto, são pouco utilizadas em interfaces cérebro-máquina, por serem pouco intuitivas na maioria das aplicações.

2.4.Potenciais Evocados

Potenciais evocados, ou potenciais relacionados a evento, são potenciais cerebrais resultantes da ocorrência de um estímulo sensorial. Eles são geralmente obtidos aferindo-se curtos segmentos de sinais EEG durante um estímulo externo. Numa interface cérebro máquina, os potenciais evocados podem propiciar controle do sistema quando a interface fornece os estímulos apropriados.

O controle de uma interface cérebro máquina por potenciais evocados possui a vantagem de quase não precisar de treinamento, oferecer um controle discreto para praticamente qualquer usuário (uma vez que o potencial evocado é uma resposta inerente à função cerebral) mas, em contrapartida, os usuários devem esperar a apresentação de um estímulo relevante.



Figura 9 - Interface cérebro máquina por potenciais evocados

Os potenciais cerebrais influenciados por estímulos físicos geralmente ocorrem nos primeiros 200ms após o estímulo. Esses potenciais são formados por uma onda com um potencial negativo com duração em torno de 100ms

seguido de um potencial positivo. Sutter utiliza pequenas fontes de estímulos visuais e, pelo potencial evocado para qual das fontes o usuário está olhando (**Erro! Fonte de referência não encontrada.**), e então associa essa fonte a um comando da interface (42).

Na década de 1960, Chapman e Bragdon (43), assim como Sutton et al. (44), descobriram uma onda cerebral com pico a cerca de 300ms após o estímulo relevante. Esse componente é conhecido desde então como P3, e é mostrado na Figura 10, onde a linha tracejada representa o comportamento normal do sinal sem a presença do estímulo. Apesar do P3 ser evocado por vários tipos de paradigmas, o de maior influência é o de frequência do estímulo (estímulos menos frequentes resultam em uma maior resposta) e o da relevância da tarefa relacionada.

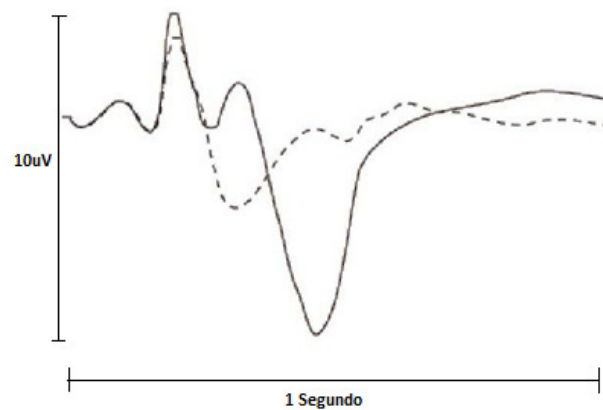


Figura 10 - Potencial evocado.

Farwell e Donchin, da Universidade de Illinois, EUA, mostraram que esse sinal pode ser utilizado em uma interface cérebro máquina (45). Desde então, diversas interfaces cérebro máquina são baseadas no potencial evocado P3. As mais comuns apresentam diferentes estímulos e monitoram o sinal para determinar se o usuário estava olhando ou não para a fonte do estímulo visual associado a um dos comandos da interface.

2.5.Implantes Corticais

Outra base para o desenvolvimento de interfaces cérebro máquina são os implantes corticais. Esse método apresenta uma grande melhoria da relação sinal-ruído, e também na resolução espacial do córtex cerebral, ao custo de ser um procedimento invasivo, necessitando assim que o usuário seja submetido a uma cirurgia. Assim sendo, esse método apresenta grande potencial no

desenvolvimento de interfaces cérebro máquina, principalmente as aplicadas ao controle de próteses.

O controle de próteses utilizando sinais corticais é baseado em três elementos: conjuntos de micro eletrodos, algoritmos de extração de características e atuadores prostéticos. Conjuntos de micro eletrodos são permanentemente implantados no córtex cerebral, e devem constantemente gravar a atividade de populações de neurônios. Informações sobre o posicionamento e velocidade desejados para a prótese controlada devem ser extraídas continuamente em tempo real da atividade gravada. Por fim a prótese em questão deve possuir a agilidade e configuração das partes a serem substituídas (46).

Recentemente o professor da Universidade de Pittsburgh Andrew Shwartz publicou seu trabalho na área de prótese cortical (47), onde um macaco utiliza a interface para controlar uma prótese para se auto-alimentar (Figura 11).

O grupo do brasileiro Miguel Nicolelis, na Universidade de Duke (14), obteve grande sucesso no treinamento de um macaco para perseguir e agarrar objetos (representados visualmente em uma tela de computador) com um braço mecânico, através de sinais cerebrais gravados por um número consideravelmente baixo de implantes corticais. Ao longo dos testes, o macaco, por si só, percebeu que o movimento do seu braço não era necessário para que o braço mecânico realizasse a tarefa.




Figura 11 - Macaco utilizando uma prótese cortical para se auto-alimentar (47).

Apesar da grande capacidade oferecida pelas próteses corticais, esse método é menos estudado em humanos devido às aplicações de segurança e ética. Sendo assim, a maioria dos estudos é feita em interfaces cérebro máquina não-invasivas.

2.6.Artefatos

O sinal EEG comumente está na faixa de 10 a 300 μ V, e é afetado por diversos ruídos de origem fisiológica e elétrica. Eletrodos não diferenciam atividade elétrica gerada pelo córtex cerebral de outras geradas por fontes extra-cerebrais. Potenciais gerados por movimentos dos olhos, língua, face ou músculos do pescoço, ou mudanças na condutância da pele, que possam contaminar a atividade cortical são chamados de artefatos. Filtros “passa alta” e “passa baixa” minimizam a maioria dos artefatos gerados por músculos, mudanças na condutância da pele, e batimentos cardíacos, mas o problema do artefato ocular permanece (48).

O piscar de olhos pode durar de 200 a 400ms e pode produzir amplitudes elétricas de até 10 vezes a amplitude de sinais corticais. Um dos primeiros métodos de remoção de artefato ocular era baseado no uso de potenciômetros para balancear o efeito dos movimentos dos olhos na vertical e na horizontal. Ajustes eram feitos observando o EEG, e eram subjetivos.

Alguns artefatos possuem características visíveis no sinal eletroencefalográfico. Os artefatos oculares, por exemplo, possuem maior amplitude, produzem alterações nos sinais EEG principalmente na banda Theta, e concentram-se nos eletrodos frontais, como Fp1 e Fp2 do Sistema Internacional 10-20.

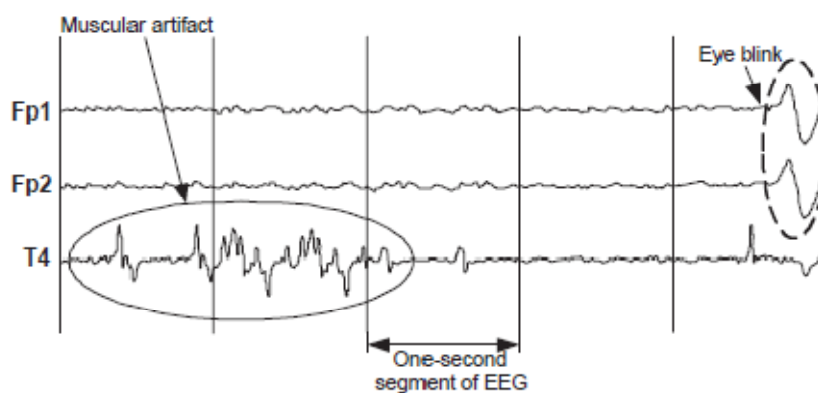


Figura 12 - Artefatos musculares e oculares em sinais EEG (4).

Artefatos musculares possuem amplitudes na ordem dos sinais EEG, mas seu espectro de frequência concentra-se principalmente na banda Beta. Esses artefatos são mais percebidos nos eletrodos centrais, temporais e parietais (49).

Outras técnicas para reduzir artefatos fisiológicos incluem instruir o paciente a paradas para descanso. Pacientes podem ser instruídos a tentar reduzir o número de piscadas do olho, especialmente durante eventos críticos. Cadeiras confortáveis e paradas para descanso reduzem artefatos musculares e oculares (50).

A próxima seção apresenta o conceito de Redes Neurais Artificiais, utilizado nesta dissertação na elaboração da BMI.

2.7.Redes Neurais Artificiais

Redes Neurais são modelos inspirados na estrutura do cérebro, com o objetivo de apresentar características similares ao comportamento humano, tais como: aprendizado, associação, generalização e abstração. As Redes Neurais são compostas por diversos elementos processadores (neurônios artificiais) altamente interconectados, que efetuam operações simples, transmitindo seus resultados aos processadores vizinhos (Figura 13). Devido à sua estrutura, as Redes Neurais são bastante efetivas no aprendizado de padrões a partir de dados não-lineares, incompletos, com ruídos, e até compostos de exemplos contraditórios. Exemplos de aplicações típicas são: reconhecimento de padrões (imagens, texto, voz, etc.), previsão de séries temporais, e classificação.




Figura 13 - Estrutura de uma rede neural

Um neurônio é uma unidade de processamento de informação que é fundamental para a operação de uma rede neural. O diagrama de blocos da Figura 14 mostra o modelo de um neurônio. Nele é possível identificar três elementos básicos. O primeiro é o conjunto de sinapses, onde cada uma representa um peso ou força de ligação. Mais especificamente, um sinal de

entrada X_i na entrada de uma sinapse j ligada a um neurônio k , é multiplicado pelo peso sináptico W_i . O segundo elemento básico é um somador, que é responsável por somar os sinais de entrada previamente multiplicados pelos respectivos pesos sinápticos. Por último, uma função de ativação constitui o terceiro elemento básico de um neurônio, e é responsável por limitar e determinar a amplitude do sinal de saída de um neurônio dado o seu valor de entrada. O modelo do neurônio inclui também um termo de *bias* que tem a função de aumentar ou diminuir o valor do sinal de entrada agindo como um termo independente. Matematicamente, o neurônio pode ser então representado pela equação 1.




Figura 14 - Modelo do neurônio artificial.

$$\omega = S(\sum X_i * W_i + \theta) \quad (1)$$

O tamanho de uma rede neural deve atender ao compromisso entre convergência e generalização. Entende-se por convergência a capacidade da rede neural de aprender todos os padrões de treinamento. Ou seja, se a rede for pequena, não será capaz de armazenar os padrões necessários. Por outro lado, se o tamanho da rede for muito grande (muitos pesos), a mesma não possuirá boa generalização, não respondendo de forma eficiente aos padrões nunca vistos (51).

Para a área de interfaces cérebro máquina, a modelagem de redes neurais como eficientes classificadores de padrões é particularmente interessante. O treinamento da rede neural é feito apresentando-se diversos padrões às entradas (valores que caracterizam uma atividade mental), e indicando à rede a saída correta para cada padrão (comando a ser executado pela interface). Assim, durante o processo de treinamento, os pesos sinápticos são atualizados de forma que, dada uma entrada, a saída seja a desejada.

A BMI desenvolvida nessa dissertação se baseia em Redes Neurais Artificiais. Sua validação será feita com o auxílio de um manipulador robótico, cujas equações cinemáticas precisam ser conhecidas, como descrito a seguir.

2.8. Cinemática de um Manipulador Robótico

A cinemática de um manipulador é o estudo do conjunto de relações entre as posições, velocidades e acelerações de seus elos. Essa se divide em dois ramos: localização da extremidade do manipulador a partir do posicionamento de suas juntas (cinemática direta), e a determinação da posição das juntas a partir do conhecimento da posição em que se deseja posicionar a extremidade do manipulador (cinemática inversa). Observando a Figura 15, que representa um manipulador plano de dois graus de liberdade, pode-se observar que as cinemáticas direta e inversa podem ser obtidas através de uma análise geométrica conforme mostrado a seguir, onde θ_1 e θ_2 representam a posição das juntas, e x e y representam as coordenadas horizontal e vertical da extremidade do manipulador robótico.

Cinemática Direta	Cinemática Inversa
$\theta_1, \theta_2 \rightarrow x, y, \Phi$ $x = l_1 \cos(\theta_1) + l_2 \cos(\theta_1 + \theta_2)$ $y = l_1 \sin(\theta_1) + l_2 \sin(\theta_1 + \theta_2)$ $\Phi = \theta_1 + \theta_2$	$x, y \rightarrow \theta_1, \theta_2$ $\left\{ \begin{array}{l} \tan \alpha = \frac{y}{x} \\ x^2 + y^2 = l_1^2 + l_2^2 + 2l_1 l_2 \cos \theta_2 \\ l_2^2 = l_1^2 + x^2 + y^2 - 2l_1 \sqrt{x^2 + y^2} \cos \gamma \end{array} \right.$




Figura 15 - Cinemática de um manipulador robótico.

3 Desenvolvimento de um Eletroencefalógrafo

3.1.Descrição

Um sinal eletroencefalográfico é normalmente medido usando-se eletrodos revestidos por cloreto de prata, embora outros materiais também sejam utilizados, como prata, estanho, aço e ouro. Neste trabalho, foi utilizada uma touca produzida pela empresa Electro-Cap International, Inc., contendo 20 eletrodos de prata revestidos por cloreto de prata (Ag/AgCl), e posicionados de acordo com o Sistema Internacional 10-20. Para maior contato com o escalpe, isentando o usuário da remoção do cabelo, um gel médico fabricado pela mesma empresa é também utilizado, aplicando-o com uma seringa no centro do eletrodo. O sistema pode ser visto na Figura 16.



Figura 16 - Electro-Cap e acessórios.

A amplitude do sinal EEG é de apenas alguns micro-volts. O sinal precisa ser amplificado milhares de vezes antes de ser digitalizado. Por ser muito fraco, o sinal está sujeito a ruídos, em especial o ruído da rede elétrica (50/60Hz), que é transmitido por meio de campo elétrico.

Para lidar com isso, o sinal é primeiramente amplificado por um amplificador instrumental de alta qualidade (INA114), que mede a diferença de potencial entre dois eletrodos. Isso garante que grande parte dos principais

ruídos não entre no sistema, pois o ruído nos dois canais é basicamente o mesmo. Após passar pelo amplificador diferencial, o sinal é amplificado novamente em duas etapas e passa por um filtro passa-baixa que minimiza a distorção que pode ocorrer quando o sinal é digitalizado em baixa frequência (efeito de *aliasing*).

Para este objetivo, neste trabalho foi construído um eletroencefalógrafo de oito canais baseado no projeto OpenEEG (52), onde cada canal possui as características descritas acima e são referenciados ao sinal do eletrodo de referência posicionado no lóbulo da orelha esquerda. Um canal do equipamento pode ser representado pelo diagrama da Figura 17. A figura mostra também o circuito chamado de *Right-leg driver*, que será explicado posteriormente.

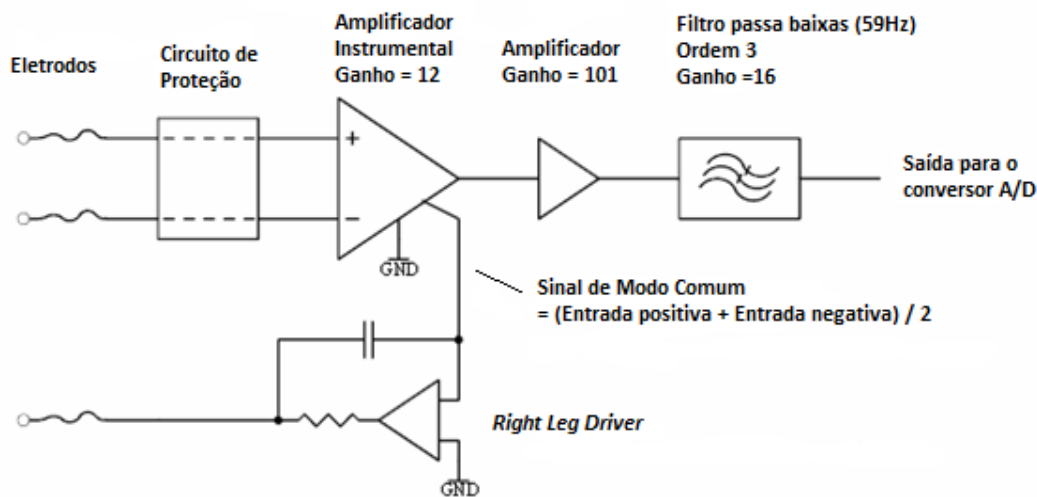


Figura 17 - Diagrama de um canal do eletroencefalógrafo.

3.2.Circuito de Proteção

Os eletrodos são conectados a um circuito de proteção, que é a primeira parada para o sinal EEG ao entrar no equipamento. Cada canal possui dois sinais diferenciais que entram no circuito de proteção através de um par de resistores de 2,2K e três capacitores (10pF, 100pF, 100pF). Esta fase inicial suprime sinais de radiofrequência (RF) que possam entrar no sistema através dos cabos dos eletrodos.

Após essa etapa, mas antes da fase de instrumentação, cada sinal diferencial pode ser observado individualmente. Os sinais individuais, em seguida, passam por um circuito ceifador. O circuito ceifador é essencialmente um par de transistores NPN/PNP que entram em condução caso a tensão de entrada seja superior a cerca de 0,58V em módulo. Sob tensões acima deste nível, os transistores agem como circuitos abertos, e drenam todas as correntes

prejudiciais para a linha de terra. Isso protege tanto o usuário quanto o eletroencefalógrafo. Após o circuito ceifador, o sinal passa por mais dois resistores de 2,2K, a fim de fazer o casamento de impedância com os eletrodos, evitando assim a distorção dos sinais (53). Concluído o circuito de proteção (Figura 18), o sinal vai para a etapa de amplificação.

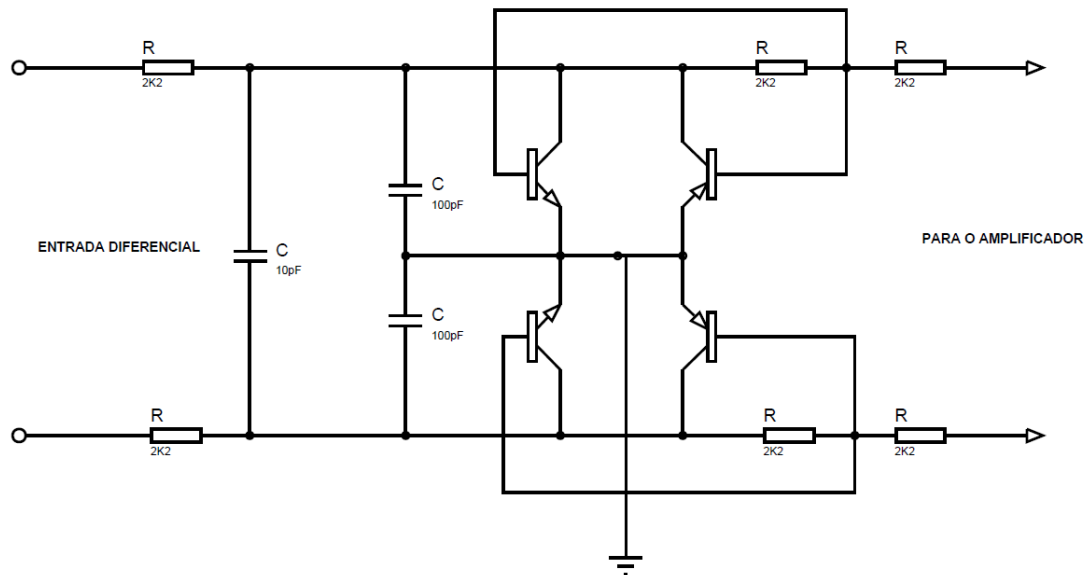


Figura 18 - Circuito de proteção.

3.3. Amplificação

O circuito de amplificação é dividido em três estágios contendo, entre eles, alguns filtros para condicionar o sinal. O primeiro estágio de amplificação consiste no uso de um amplificador instrumental, enquanto os outros dois são implementados com amplificadores operacionais, sendo o último um filtro ativo do tipo Bessel.

Amplificadores instrumentais são fundamentais para combinar os sinais diferenciais na fase de amplificação. Embora existam muitas aplicações e tipos de amplificadores instrumentais, o sistema de baixa potência provou ser o método mais adequado para aquisição de sinais EEG (53).

O amplificador instrumental pode ser considerado o componente mais importante do eletroencefalógrafo. É esse componente que controla a combinação dos sinais diferenciais e configura a taxa de rejeição de modo comum para todo o equipamento. O amplificador instrumental é também responsável por lidar com o ruído dos sinais de entrada pois, além de amplificar o sinal diferencial, ele abaixa a impedância do sistema, resultando numa menor sensibilidade a ruídos.

Para esse projeto, o amplificador instrumental INA114 (Figura 19), fabricado pela *Texas Instruments*, foi escolhido por possuir qualidade superior aos seus equivalentes, além de contar com circuitos de proteção contra sobre-tensão e uma entrada referencial para eliminação de níveis DC em relação à referência do resto do circuito.

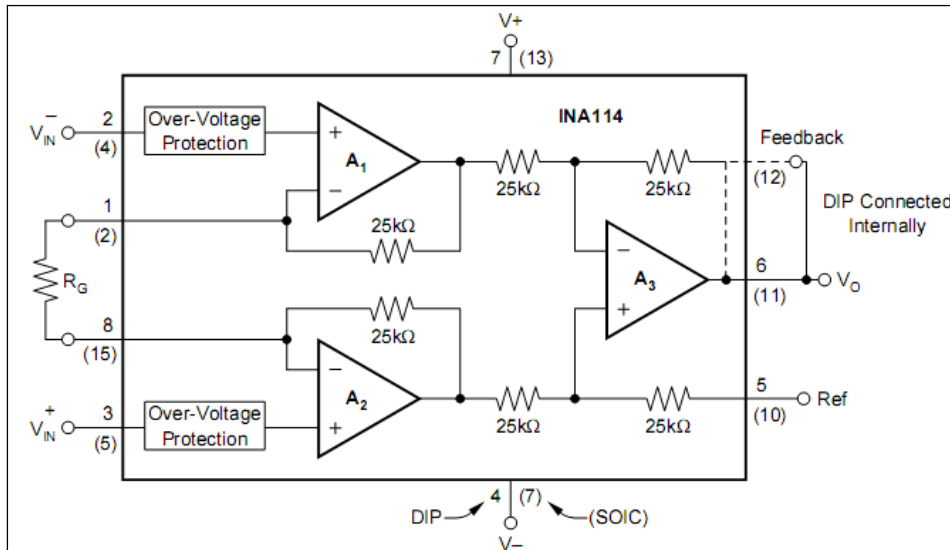


Figura 19 - Amplificador instrumental INA114 – Texas Instruments

Este amplificador possui ganho na amplificação do sinal diferencial que pode variar de 1 a 10.000 vezes, dependendo da escolha do resistor externo R_G , de acordo com

$$G = 1 + \frac{50K\Omega}{R_G} = 1 + \frac{50K\Omega}{4.4K\Omega} = 12.36 \quad (2)$$




Figura 20 - Segundo estágio de amplificação.

Em seguida, o sinal passa por um filtro passa-alta com frequência de corte centrada em 0.16 Hz (valor resultante dos valores de componentes comerciais encontrados no mercado que mais se adequam à remoção do nível DC), usado como redundância para remover qualquer nível de corrente contínua remanescente. Uma vez filtrado, o sinal se encaminha para o segundo estágio de amplificação (Figura 20), que é responsável pelo ajuste fino do ganho do circuito como um todo.

O ganho do amplificador é facilmente calculado pela equação de um amplificador com realimentação negativa em configuração não inversora. Sendo assim, a frequência de corte e o ganho de amplificação podem ser calculados respectivamente por

$$f_c = \frac{1}{2\pi RC} = \frac{1}{2\pi * 10^6 * 10^{-6}} = \mathbf{0.1591 \text{ Hz}} \quad (3)$$

$$G = 1 + \frac{R_8}{R_7} = 1 + \mathbf{100} = \mathbf{101} \quad (4)$$

O terceiro estágio de amplificação (Figura 21) é precedido também por mais um filtro passa-alta, com as mesmas propriedades do filtro anterior. Diferentemente do segundo, o terceiro estágio de amplificação implementa também um filtro passa-baixa do tipo Bessel de terceira ordem, com frequência de corte centrada em 59Hz (para redução de 60Hz). Este filtro elimina ruídos de alta frequência, amenizando também o ruído da rede elétrica, sendo importante também para evitar o efeito de *aliasing*, caso seja feita uma conversão em baixa frequência. O ganho desse estágio na banda passante é igual a 16.




Figura 21 - Terceiro estágio de amplificação.

Estando os três estágios de amplificação em série, o ganho total do amplificador é de aproximadamente $2 \cdot 10^4$ na banda passante o que, multiplicado pelo sinal eletroencefalográfico (máximo de $50\mu\text{V}$ nos sinais de interesse), resulta num sinal com amplitude em torno de 1V para leitura do conversor A/D. A Figura 22 mostra o diagrama de Bode do circuito, englobando todos os estágios de amplificação e filtragem. A curva superior corresponde à magnitude e a inferior à fase do circuito.




Figura 22 - Diagrama de Bode do amplificador.

Pode-se observar que a curva da magnitude permanece quase plana até a frequência de 30Hz, que é o limite da região de interesse das bandas dos sinais eletroencefalográficos. Na mesma faixa verifica-se também que não há inversão de fase, resultando assim em uma amplificação homogênea das bandas de interesse.

Para que não haja a necessidade do uso de uma fonte simétrica para os amplificadores operacionais e instrumentais, foi criado um terra virtual com tensão de referência de 2,5V, uma vez que a tensão de alimentação do circuito é de 5V. Sendo assim, todo o circuito está referenciado ao terra virtual, sendo o terra real (0V) usado para excursionar sinais negativos. O terra virtual é gerado através do circuito integrado TLE-2425 da *Texas Instruments*, produzido justamente para essa finalidade.

3.4.Right-Leg Driver (RLD)

O circuito RLD, comumente utilizado em sinais de baixa potência (54), é usado para aumentar a rejeição de modo comum do circuito (*Common-Mode Rejection Rate* – CMRR). A idéia deste circuito consiste, basicamente, na estimativa dos sinais comuns às entradas diferenciais do amplificador e na seguinte inversão e atuação deste sinal de volta para o usuário, na tentativa de eliminar qualquer variação do potencial de modo comum.

O amplificador instrumental escolhido (INA114) prevê o uso do RLD (Figura 23) em suas especificações (55), utilizando dois resistores em série e de mesmos valores, no lugar do resistor R_{G2} , estimando assim o ruído de modo comum.




Figura 23 - RLD para o circuito integrado INA114

Este circuito é implementado em duas etapas. Na primeira, é feito um somatório dos sinais de modo comum de todos os amplificadores do eletroencefalógrafo e, na segunda, é feita a inversão e amplificação do sinal para que, através de um eletrodo, seja atuado no usuário.

Cada canal possui um amplificador operacional em configuração não inversora e com ganho unitário para evitar que possíveis correntes retornem às entradas dos amplificadores instrumentais. Os sinais amplificados são unidos através de resistores de 10KΩ à linha chamada de COMM (Figura 24), que representa a soma dos sinais de todos os canais. A linha COMM é então invertida e amplificada, para que consiga atuar no potencial do corpo humano e cancelar flutuações da referência do mesmo. Dessa forma, aumenta-se a rejeição de modo comum para o amplificador instrumental. Nesse trabalho, o eletrodo do RLD é conectado ao lóbulo da orelha direita.




Figura 24 - RLD para vários canais de amplificação.

3.5. Conversão Analógico-Digital

Após a etapa de amplificação, quando o sinal eletroencefalográfico possui maior amplitude e redução dos sinais indesejados, é necessária a digitalização dos sinais. Para isso foi utilizado o conversor analógico-digital NI USB-6009 produzido pela *National Instruments* (56).



Figura 25 - NI USB-6009.

Esse conversor possui resolução de 14 bits, com frequência máxima de aquisição de 48 KHz. O conversor foi utilizado no modo *single-ended* (todos os canais referenciados a um único potencial), e sua referência ligada à referência do circuito (terra virtual).

Os dados convertidos podem ser obtidos por um computador pessoal via conexão USB. O computador pessoal utilizado é um *notebook Toshiba Satellite*, com processador Intel Core 2 Duo – 2.2GHz, e com memória RAM de 3Gb.

3.6. Construção do Eletroencefalógrafo.

Com o projeto finalizado, algumas considerações acerca da montagem do equipamento foram feitas. A primeira delas foi a escolha dos componentes eletrônicos utilizados. Nesse projeto optou-se pela utilização de componentes SMD (*Surface Mounted Device*), por serem menores, reduzindo o tamanho total da placa de circuito impresso, e por serem menos suscetíveis a ruídos em rádio frequência. A tolerância de todos os resistores e capacitores utilizados foi limitada a 1%, garantindo a fidelidade e desempenho dos filtros projetados.

O desenho esquemático da eletrônica foi feito utilizando o *software* Proteus-VSM desenvolvido pela ©Labcenter Electronics, e a placa de circuito impresso desenhada utilizando o *software* ARES, do mesmo fabricante. No desenho da placa de circuito impresso (Figura 26) alguns cuidados como dimensionamento e geometria das trilhas foram tomados.




Figura 26 - Renderização da eletrônica do eletroencefalógrafo.

Para maior aproveitamento de espaço e conseqüente redução das dimensões da placa de circuito impresso, as duas faces da mesma foram utilizadas, alocando-se quatro canais em cada lado. A placa foi projetada também com um conector DB-25 para conexão direta com a touca de eletrodos.

Para reduzir possíveis ruídos por indução, a eletrônica foi encapsulada em uma caixa de metal e devidamente aterrada à mesma. A malha de terra utilizada está conectada à referência do circuito (terra virtual - VGND) e aos furos de fixação mecânica da placa que, por sua vez, estão conectados à caixa metálica.

Visando uma maior segurança do equipamento, a alimentação do circuito, bem como do computador pessoal, foi feita através de baterias, evitando assim qualquer conexão com a rede elétrica. As baterias, assim como a eletrônica e o módulo de conversão analógico-digital, estão encapsuladas dentro da mesma caixa metálica.




Figura 27 - Eletroencefalógrafo com a caixa metálica aberta.

O eletroencefalógrafo, mostrado na Figura 27, atingiu a dimensão final de 11cm x 10cm x 7cm. Dessa forma o equipamento está pronto para fornecer sinais EEG digitalizados ao computador pessoal. A Figura 28 apresenta a gravação de 4 segundos na posição Cz (central zero). Para verificação das propriedades foi pedido que o usuário piscasse e em seguida rangesse os dentes, gerando sinais compatíveis com os esperados. No próximo capítulo, os sinais capturados serão pré-processados e suas características extraídas.




Figura 28 - Sinal EEG na posição Cz.

4 Pré-Processamento e Extração de Características

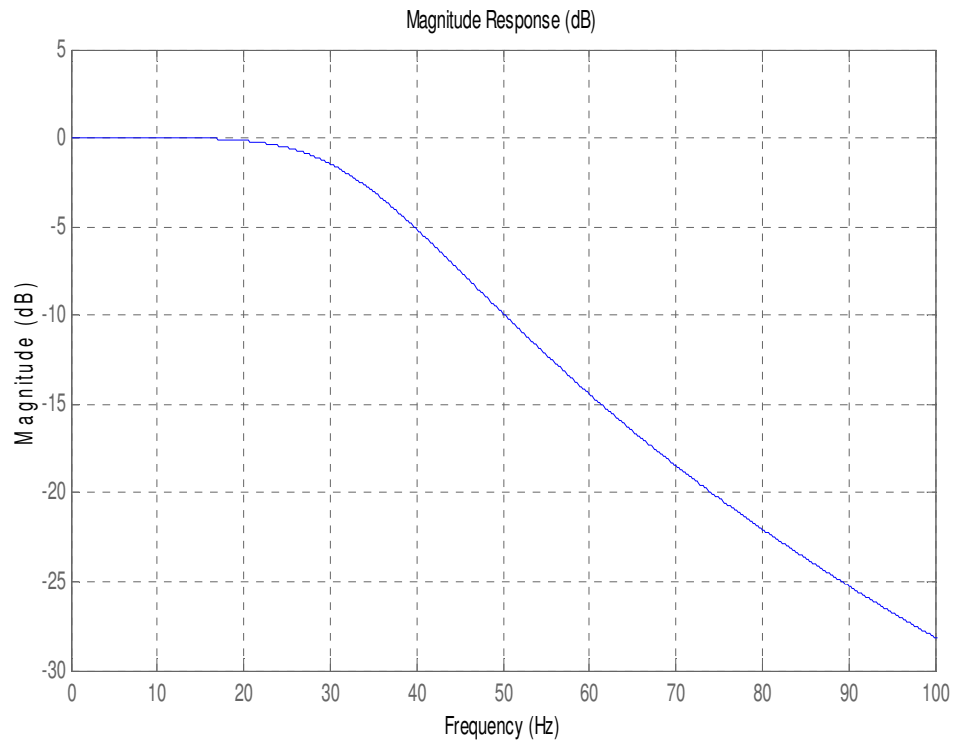
Uma vez digitalizados, os sinais EEG precisam ser pré-processados, o que é feito basicamente em quatro etapas: eliminação de ruídos remanescentes, filtragem espacial para aumento da resolução sobre o escalpe, extração de características, e a detecção e remoção de artefatos oculares (piscar dos olhos).

4.1. Eliminação do Ruído Remanescente


A maioria dos ruídos externos pode ser evitada controlando o ambiente em que é realizada a medição. Mas nem todas as interferências podem ser eliminadas dessa forma. Mesmo que o *hardware* eletrônico possua circuitos de filtragem e esteja encapsulado em uma caixa de metal devidamente aterrada, os sinais eletroencefalográficos não estão totalmente imunes a ruídos da rede elétrica, entre outros.

Para eliminar o ruído remanescente é utilizado então um filtro digital. O filtro projetado foi um filtro Butterworth passa baixas com frequência de corte em 35Hz. A escolha do filtro foi feita visando uma resposta da magnitude o mais plana possível da banda passante, bem como uma resposta em fase mais linear do que a oferecida por outros tipos de filtro. A resposta em frequência da magnitude e da fase do filtro projetado pode ser vista na Figura 29. A frequência de corte foi escolhida para deixar apenas as frequências de interesse (bandas de frequência dos sinais eletroencefalográficos) na banda passante.

A maior fonte externa de ruídos é a rede elétrica instalada no local da aquisição. Apesar de ser grande em amplitude, esse ruído se concentra na frequência de oscilação da rede (60Hz para o Brasil). Dessa forma, sua eliminação torna-se relativamente fácil. Para isso, então, foi projetado um filtro *Notch* centrado em 60Hz, cuja resposta em frequência encontra-se na Figura 30.



(a)



(b)

Figura 29 - Resposta em frequência do filtro Butterworth.




Figura 30 - Resposta em frequência do filtro *Notch*.

4.2. Filtragem Espacial

Leituras convencionais de sinais eletroencefalográficos possuem pouca resolução espacial, devido à superposição das atividades elétricas originadas nas diferentes áreas do cérebro. A distribuição dos potenciais sobre o escalpe pode ser vista como uma cópia “borrada” da distribuição dos potenciais corticais (57). A resolução espacial sem tratamento está na faixa de 6 a 10 cm, podendo ser melhorada para 2 a 3 cm com métodos de aumento de resolução (58).

Uma técnica conhecida para aumento da resolução espacial consiste na estimativa da Superfície Laplaciana (*Surface Laplacian* – SL). Assumindo o escalpe como sendo isotrópico, pode-se demonstrar que a SL é proporcional à componente radial do gradiente da densidade de corrente do escalpe (*Scalp Current Density* - SCD). A SL independe do eletrodo de referência e, atuando como um filtro espacial, elimina o efeito da difusão dos potenciais pelo escalpe, que é altamente resistivo (59).

Um método para se estimar a SL diretamente em locais selecionados (caracterizando o método como local) é o de Hjorth (60). O método assume que cada eletrodo é cercado por outros três que formam um triângulo equilátero de forma que tal eletrodo esteja no centro desse triângulo (61). Assim sendo, o método de Hjorth pode ser representado pela equação 5:

$$Vsl = \left\{ \frac{4}{3} [3Vn - (Va + Vb + Vc)] \right\} * \frac{1}{d^2} \quad (5)$$

onde Vsl é o potencial estimado da superfície laplaciana, Vn é o potencial obtido no eletrodo central, Va, Vb e Vc são os potenciais dos eletrodos vizinhos (vértices do triângulo equilátero), e “d” é a distância do eletrodo central para os seus vizinhos. A Figura 31 apresenta os sinais eletroencefalográficos obtidos pelo método de Hjorth.

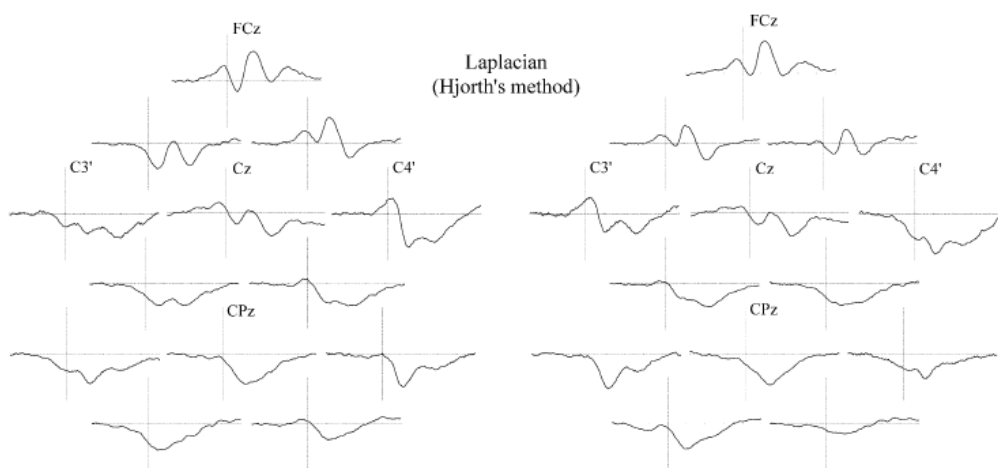


Figura 31 - Sinais estimados pelo método de Hjorth (à direita).

4.3.Extração de Características

Como visto no capítulo 2, existe uma estreita relação entre o tamanho da rede neural com sua convergência e generalização. A chave para um bom desempenho está então na seleção de variáveis, que formarão as entradas da rede neural e, através de algumas métricas, determinarão o tamanho da mesma.

Em um problema de classificação (como no caso de uma interface cérebro máquina), as variáveis escolhidas devem representar os padrões a serem classificados, além de serem relevantes na distinção entre os mesmos. Neste trabalho, um padrão cerebral corresponde ao período de 1 segundo de leitura de sinais eletroencefalográficos. Assim sendo, um método de extração de características deve ser aplicado aos sinais eletroencefalográficos provenientes

dos eletrodos posicionados sobre o escalpe. Esta seção apresenta então algumas métricas analisadas na caracterização dos padrões cerebrais.

O primeiro passo na extração de características de um sinal eletroencefalográfico é sua decomposição em bandas de frequência. Conforme dito anteriormente, um sinal EEG possui relações entre determinadas faixas de frequência e as atividades desempenhadas pelo paciente/usuário. Essas bandas de frequência estão compreendidas entre 0 e 32Hz. Para uma análise em frequência desses sinais, foi utilizada a Transformada *Wavelet* Discreta (*Discrete Wavelet Transform – DWT*).

Transformadas *Wavelet* são utilizadas em diversas áreas, como em telecomunicações e biologia. Devido à sua eficácia na análise de sinais não estacionários (que mudam suas propriedades estatísticas ao longo do tempo), se tornaram uma poderosa alternativa aos métodos de Fourier em aplicações médicas, onde esse tipo de sinal é mais frequente.

A Transformada de Fourier (TF) expande sinais no domínio do tempo em funções de bases ortogonais (ondas senoidais e co-senoidais), revelando assim as componentes de frequência dos sinais. Porém, esse método não é capaz de localizar no tempo as componentes de frequência. Por isso, esse método é melhor utilizado na análise de sinais estacionários.

Entretanto, a maioria dos sinais biomédicos tende a ser não-estacionária e, ao contrário dos sinais apropriados para a TF, tipicamente possuem componentes em alta frequência espaçadas em curtos períodos de tempo seguidas por componentes de baixa frequência com longo tempo de duração e próximas no domínio da frequência. A Transformada *Wavelet* apresenta tanto uma boa resolução no tempo para altas frequências como uma boa resolução em frequência para baixas frequências (62).

A DWT consiste em decompor o sinal $s[n]$ inúmeras vezes em componentes de resolução inferior. Este algoritmo é implementado por meio de um banco de filtros digitais composto por um filtro passa-baixas $h_0[n]$ e outro passa-altas $h_1[n]$. A Figura 32 mostra um exemplo da DWT com três níveis de decomposição. A saída de todos os filtros é sub-amostrada por um fator de 2. O resultado obtido pela filtragem passa-alta representa os coeficientes de detalhe, enquanto o resultado da filtragem passa-baixa representa os coeficientes de aproximação.

Na DWT os coeficientes resultantes da filtragem passa-baixa podem ser novamente processados como dados de entrada para um banco de filtros subsequente, gerando assim outro conjunto de coeficientes de aproximação e detalhe com um nível de resolução inferior (63).




Figura 32 - Esquemático da transformada wavelet discreta (DWT).

Os sinais eletroencefalográficos são adquiridos, nesse trabalho, com uma frequência de 1.000Hz. Dessa forma, a sua decomposição deve ser feita em 7 níveis (como mostra a Figura 33) para que se isolem as faixas de frequência que mais se aproximam das bandas de interesse.




Figura 33 - Árvore de decomposição wavelet discreta para 1kHz.

Aplicando-se a árvore de decomposição apresentada, é possível decompor o sinal nas bandas Beta, Alpha, Theta e Delta, como mostra a Figura 34.




Figura 34 - Transformada wavelet discreta de um sinal EEG.

Após a decomposição em frequência do sinal EEG, é preciso extrair algumas informações sobre os sinais resultantes para compor um vetor característico de entrada, que será apresentado à rede neural classificadora. Esse vetor deve incluir a escolha dos eletrodos a serem processados, de acordo com seu posicionamento, e de algumas características dos sinais decompostos (para cada banda de frequência), como energia, amplitude, média, *zero-crossing* e valor máximo.

Os eletrodos foram escolhidos de acordo com o seu posicionamento nas áreas do escalpe que estão sobre o córtex motor e pré-motor. São eles: F3, F4, Fz, C3, C4, Cz, P3 e P4, totalizando oito eletrodos, que cobrem o lobo frontal (abrangendo o córtex pré-motor), central (sobre o córtex motor) e parietal (Figura 4, pg 20). As bandas de frequência escolhidas foram a Alpha e Beta, por estarem associadas aos ritmos sensoriais motores (RSM), além da banda de 0 a 32Hz, por compreender todo o espectro EEG. Dessa forma, assumindo um parâmetro extraído de cada uma das três bandas para cada um dos oito eletrodos, chegamos a um vetor característico de 24 elementos.

Para avaliar e comparar a influência dos parâmetros escolhidos para o vetor característico, uma rede neural *Multi Layer Perceptron* (MLP) foi modelada para classificar entre 4 grupos, correspondentes a 4 atividades cerebrais tendo,

como entradas, diferentes combinações e parâmetros extraídos dos sinais cerebrais. Um banco de dados contendo 700 atividades mentais (cada uma correspondendo a 1 segundo de leitura de sinais EEG) foi utilizado, sendo 400 padrões usados para treinamento da rede, 200 para validação e 100 para testes, sempre divididos igualmente entre quatro padrões a serem classificados. O treinamento da rede é feito utilizando parada antecipada, permitindo-se que o erro do conjunto de validação aumente por até 80 épocas. A topologia utilizada possui 24 processadores de entrada, 32 na camada escondida (valor obtido experimentalmente avaliando o resultado obtido por diferentes configurações), e 4 na camada de saída.

Após a avaliação da influência dos parâmetros com a rede neural, chegou-se à conclusão de que a escolha da energia dos sinais decompostos nas bandas escolhidas resultou em uma maior separabilidade dos padrões, como mostra a Tabela 1.

Tabela 1 - Comparação da influência de parâmetros escolhidos.

Parâmetro	Classificações Corretas (%)
Média	55
<i>Zero-Crossing</i>	51
Energia	58
Amplitude	57

A definição de energia encontra-se na equação 6, onde n é o comprimento do vetor V_{DWT} obtido pela DWT, e $V_{DWT,i}$ é o i -ésimo elemento deste vetor.

$$E = \frac{\sum_{i=1}^n V_{DWT,i}^2}{n} \quad (6)$$

Através desse método de extração de características, chega-se ao objetivo de representar uma atividade mental (1 segundo de leitura de sinais EEG) com um vetor de 24 elementos, de forma a apresentar boa caracterização e separabilidade no processo de classificação.

4.4. Detecção de Artefatos

Neste trabalho, não foram estudados métodos elaborados para remoção de artefatos. No entanto, algumas medidas foram tomadas para evitá-los, e um método foi utilizado para remoção de artefatos oculares relativos ao piscar dos olhos.

Artefatos podem ser considerados eventos singulares no domínio do tempo e da frequência, que podem aparecer aleatoriamente nos sinais EEG. O piscar de olhos, por exemplo, pode durar de 200 a 400ms e pode produzir amplitudes elétricas de até 10 vezes a amplitude de sinais corticais. No sinal eletroencefalográfico, são mais observados na banda Theta, e produzem maiores alterações nos eletrodos frontais. Sendo assim, uma abordagem estatística pode ser feita.

Como visto na seção anterior, o vetor característico que representa a atividade mental no período de um segundo é composto pelas energias das bandas Alpha e Beta, além da energia do espectro EEG (0-32Hz), que inclui também a banda Theta, para os oito eletrodos selecionados. Devido às características dos artefatos oculares provenientes do piscar dos olhos, já mencionadas, o elemento do vetor correspondente à energia do espectro EEG (o que inclui a banda Theta) sofrerá considerável aumento em seu valor na presença de tais artefatos.

O interesse da remoção de artefatos neste trabalho se dá no momento em que é feito o treinamento dos classificadores de atividades mentais, evitando assim que o classificador seja treinado com padrões que não representem as atividades mentais correspondentes. Assim sendo, as atividades mentais que estão contaminadas com artefatos oculares são localizadas no conjunto de padrões de treinamento como possuindo a energia da banda Theta maior que a média desse parâmetro (ao longo do conjunto de treinamento) acrescida de três vezes o desvio padrão do conjunto, para qualquer um dos três eletrodos frontais (F3, F4 e Fz). Uma vez detectados, os padrões contaminados são então removidos do conjunto de treinamento.

Em suma, este capítulo demonstrou as etapas necessárias para a obtenção de um vetor característico de 24 elementos que represente uma atividade mental do usuário durante um segundo, contendo informações que garantam sua boa caracterização e separabilidade. No próximo capítulo, as técnicas utilizadas na classificação de tais atividades mentais serão descritas.

5 Reconhecimento de Padrões

Neste trabalho, a interface cérebro máquina é baseada no condicionamento operante. Sendo assim, quatro atividades mentais distintas e comprovadamente relacionadas a alterações do RSM foram utilizadas. São elas: movimento imaginário do braço esquerdo, braço direito, língua, e pés. Essas atividades foram respectivamente chamadas de LM (*Left Movement*), RM (*Right Movement*), UM (*Up Movement*) e DM (*Down Movement*), de acordo com as funções a que são associadas durante a aplicação da interface.

A fim de se classificar as atividades mentais, classificadores baseados em Redes Neurais foram propostos e utilizados. Todos os modelos foram treinados e avaliados com as mesmas bases de dados. A topologia de cada rede foi obtida através de uma rotina de avaliação do resultado quando variados o número de processadores na camada escondida, momentum e taxa de aprendizado. Durante a rotina, a mesma base de dados é utilizada para treinar e avaliar o resultado de diferentes topologias. O número de processadores na camada escondida foi variado de 5 a 60, o termo de momentum de 0 a 1 com passo de 0,1, e a taxa de aprendizado de 0,2 a 1 com passo de 0,01. Cada topologia passou pela fase de treinamento e teste apenas uma vez. Ao final da rotina, uma tabela com os resultados foi gerada, e a topologia escolhida foi a que apresentou melhor resultado. Para evitar que a escolha fosse feita como um caso isolado, os resultados das redes com topologia semelhante também foram observados se mostraram quase tão bons quanto a escolhida, destacando-se das outras topologias.

A base de dados é composta por 400 padrões de treinamento, 200 padrões de validação e 200 padrões de testes, sendo cada um desses três grupos (treinamento, validação e testes) dividido igualmente entre as quatro atividades mentais a serem identificadas. A avaliação do desempenho dos modelos propostos foi obtida pelo resultado médio de dez bases de dados geradas pelo mesmo usuário.

5.1. Comitê de Redes Neurais MLP com DPR

O primeiro modelo proposto para esse problema é um comitê de redes neurais *Multi Layer Perceptron* (MLP), devido ao seu bom desempenho na generalização (64). O comitê é composto por quatro redes MLP, e cada uma delas classifica melhor um dos quatro grupos (RM, LM, UM e DM) (Figura 35).

A replicação direcionada de padrões (*Driven Pattern Replication – DPR*) é utilizada para criar diferentes membros do comitê. Cada membro especializado na classificação de um dos quatro grupos é treinado com os padrões correspondentes a esse grupo replicados quatro vezes no conjunto de treinamento, enquanto o número de padrões respectivos às outras atividades mentais se mantém o mesmo.

Cada membro é então treinado com seu respectivo conjunto de treinamento, e no treinamento de todos eles é utilizada a parada antecipada, permitindo-se que o erro do conjunto de validação cresça por 80 épocas de treinamento. Cada rede é composta por 24 processadores na camada de entrada, 32 na camada escondida e 4 na camada de saída (um para cada atividade mental). Durante o treinamento foi utilizado um termo de “momentum” igual a 0,7 e taxa de aprendizagem adaptativa igual a 0,75.

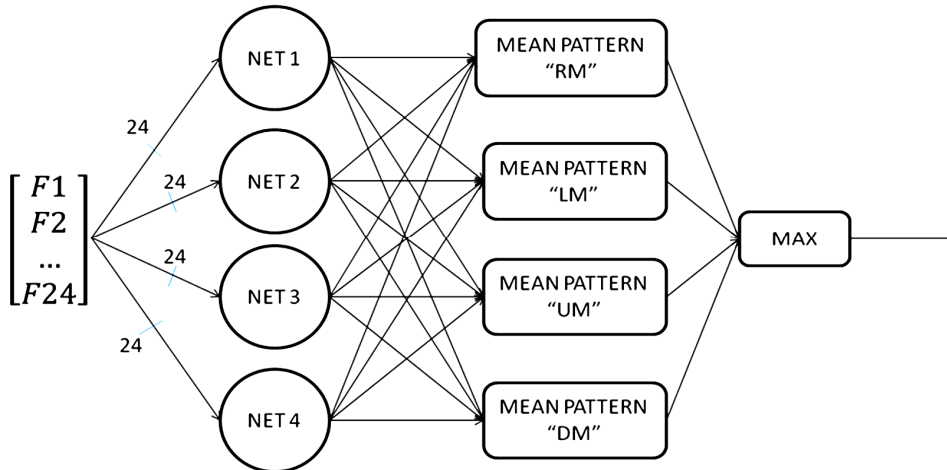


Figura 35 - Comitê de redes MLP com DPR.

A obtenção do resultado do classificador é feita apresentando-se um vetor característico aos quatro membros do comitê e, em seguida, combinando-se as saídas correspondentes a uma mesma atividade mental pelo seu valor médio. O grupo (atividade mental) que possuir a maior média de classificação é então escolhido como o que representa o padrão apresentado.

5.2. Múltiplas Redes Modulares (MRM).

Nesse modelo (Figura 36), outra vez, quatro redes neurais são usadas. Porém, dessa vez, cada rede possui apenas duas saídas, e é treinada para classificar o vetor apresentado como pertencendo ou não ao grupo para o qual foi treinada para classificar.

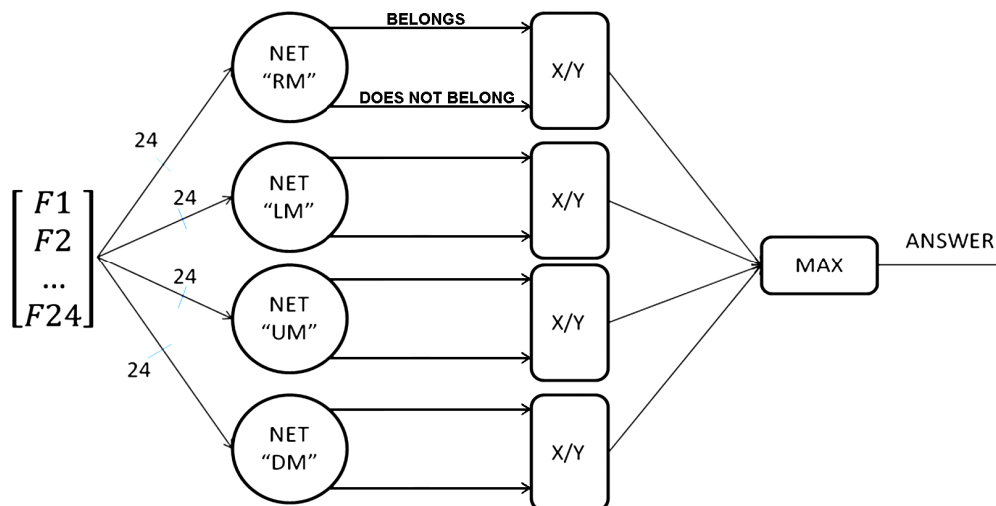


Figura 36 - Classificador baseado em múltiplas redes modulares.

A combinação das respostas das redes é feita em duas etapas. Primeiramente é atribuído um grau de certeza da classificação de cada rede. Isso é feito dividindo-se o valor da saída relativa ao grupo "pertence ao grupo" pelo valor da saída "não pertence ao grupo". Em seguida, é aplicada uma operação de máximo entre os quatro graus obtidos para identificar o grupo classificado.

Um modelo combinando diretamente cada saída "pertence ao grupo" pelo operador "máximo" também foi testada. Entretanto, a atribuição do grau pela divisão das duas saídas de cada rede resultou em uma melhor taxa de acerto na classificação.

Cada rede é treinada com o mesmo conjunto de treinamento, validação e testes, contendo todos os padrões de cada um dos quatro grupos (atividades mentais). A diferenciação é feita alterando-se apenas os "targets" de treinamento. Sendo assim, cada rede passa a possuir, no conjunto de treinamento, 300 padrões a serem treinados como "não pertence ao grupo", e apenas 100 padrões com "targets" de "pertence ao grupo". Isso poderia causar uma tendência da rede em classificar grande parte dos padrões apresentados como não pertencentes ao grupo. Para evitar isso, os padrões do conjunto de treinamento relativos ao grupo "pertence ao grupo" foram replicados três vezes,

igualando assim o número de padrões de cada grupo no conjunto de treinamento.

No treinamento das quatro redes é utilizada a parada antecipada, permitindo-se que o erro do conjunto de validação cresça por 80 épocas de treinamento. Cada rede é composta por 24 processadores na camada de entrada, 28 na camada escondida, e 2 na camada de saída (“pertence ao grupo” e “não pertence ao grupo”). Durante o treinamento, foi utilizado um termo de “momentum” igual a 0,8 e taxa de aprendizagem adaptativa igual a 0,75.

5.3. Modelo Hierárquico (MH).

O modelo hierárquico foi proposto após avaliar o desempenho do modelo MRM. Analisando a matriz de confusão (Tabela 2) do modelo citado, é possível observar que a maioria dos padrões classificados de maneira errada está entre os grupos “UM” e “DM”.

Tabela 2 - Matriz de confusão do modelo MRM.

	DM	UM	RM	LM
DM	27	13	4	6
UM	10	22	9	9
RM	2	2	40	6
LM	6	6	11	27

Sendo assim, o modelo hierárquico é dividido em dois níveis, como pode ser visto na Figura 37. No primeiro nível, redes neurais MLP são utilizadas como no modelo MRM, distinguindo o padrão apresentado como pertencendo ou não ao seu grupo. Entretanto, ao invés de quatro grupos, o primeiro nível distingue apenas entre três grupos: RM, DM e um novo padrão resultante da união dos dois restantes {DM ou UM}. No segundo nível, caso o grupo {DM ou UM} tenha sido pré-classificado no primeiro nível, uma nova rede MLP é utilizada para classificar entre os padrões DM e LM.

Sendo assim, o mesmo vetor característico é apresentado a todas as redes do primeiro e segundo níveis. A classificação final depende dos classificadores do primeiro nível do modelo. Se a rede treinada para reconhecer o grupo {DM ou UM} apresentar a maior saída (grau calculado como no modelo MRM) entre as três do primeiro nível, então a resposta do sistema é dada pela

classificação do segundo nível do modelo. Caso contrário, a resposta é obtida pela rede do primeiro nível com maior valor de saída.

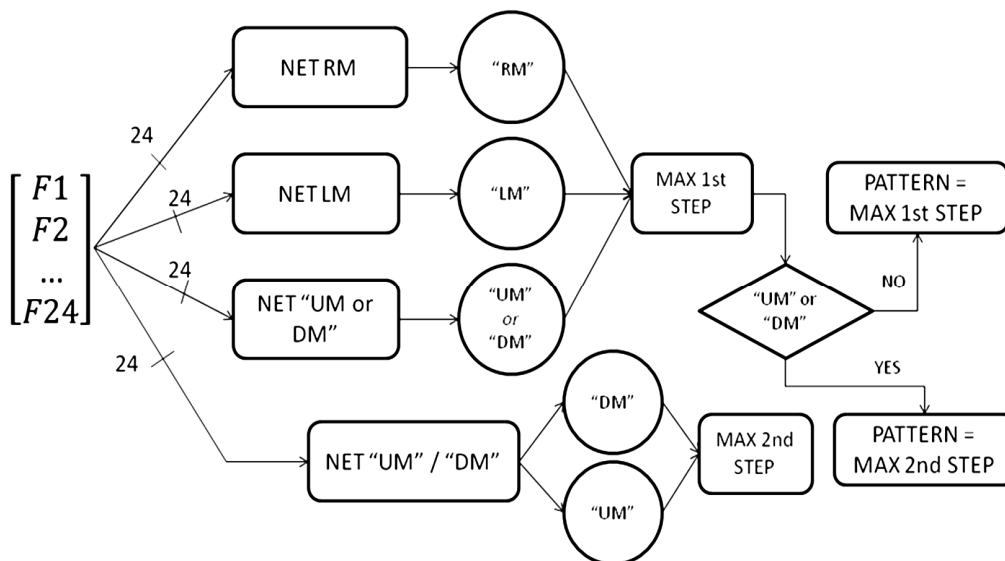


Figura 37 - Modelo Hierárquico.

Como resultado, a nova matriz de confusão apresenta melhores resultados que o modelo MRM, aumentando as classificações corretas não só dos padrões antes confusos, como também do padrão LM.

Tabela 3 - Matriz de confusão do modelo hierárquico.

	DM	UM	RM	LM
DM	28	12	4	6
UM	5	27	9	9
RM	2	2	40	6
LM	6	5	9	30

Como pode ser visto na Tabela 4, o modelo hierárquico resultou num aumento considerável da taxa de acerto em relação aos outros classificadores. Para fins comparativos, um modelo de classificador com uma única rede MLP e outro modelo baseado em redes neurais proposto por Achanccaray² (65) (com o respectivo processo de extração de características) foram avaliados.

² Achanccaray analisou as variações da Banda Delta durante a imaginação do movimento e outras atividades cognitivas, e utilizou redes neurais probabilísticas para classificar os padrões.

Como mencionado anteriormente, o resultado foi obtido pela média dos resultados de 10 conjuntos de testes, cada um contendo 200 padrões (50 padrões de cada atividade mental), gravados de um mesmo usuário. Os resultados apresentados foram avaliados com e sem a remoção de artefatos oculares do conjunto de padrões de treinamento, e é possível verificar que a remoção dos mesmos não resultou numa melhora significativa na taxa de acerto dos classificadores.

Tabela 4 - Taxas de acerto dos diferentes classificadores.

	Com remoção de artefatos	Sem remoção de artefatos
Achancaray (2009)	36%	36%
MLP	54%	54%
Comitê	60%	59%
MRM	61%	59%
HM	65%	63%

Os modelos propostos resultaram em taxas de acerto entre 60% e 65%. Entretanto, essas taxas de acerto ainda podem ser insuficientes para algumas das tarefas de uma interface cérebro máquina. Dessa forma, não é uma boa idéia usar uma única tentativa (padrão) para ser classificado e convertido em uma ação da BMI durante a aplicação.

Para resolver esse problema, duas implementações dos modelos de classificação propostos foram feitas, utilizando múltiplas tentativas. Estas implementações tornam, inclusive, desnecessária a remoção de artefatos. As duas implementações usam consecutivas tentativas de 1 segundo de leitura do EEG cada, que são processadas, classificadas individualmente, e então combinadas para resultar numa classificação final do sistema, como é descrito a seguir.

5.4.Implementação de Disparo com MRM.

Nessa primeira implementação, o modelo de Múltiplas Redes Modulares (MRM) foi utilizado para classificar cada tentativa pois, além de ter apresentado uma taxa de acertos similar ao comitê de redes neurais, fornece um grau de classificação atribuído a cada um dos grupos estimados da mesma maneira (o modelo hierárquico utiliza redes diferentes devido à sua divisão em dois níveis). Os graus atribuídos para cada saída (correspondentes aos quatro grupos RM,

LM, UM e DM) são somados aos graus correspondentes da próxima tentativa / classificação até que um valor de disparo seja alcançado por um dos quatro grupos, quando é então declarado como o grupo desejado. No exemplo do esquema da Figura 38, a atividade mental do usuário corresponde ao padrão UM e o valor de disparo igual a 5 e, mesmo com uma tentativa classificada errada (tentativa 2), o sistema consegue distinguir a atividade desejada quando, neste exemplo, o somatório atinge o valor 5.2 (maior ou igual a 5).

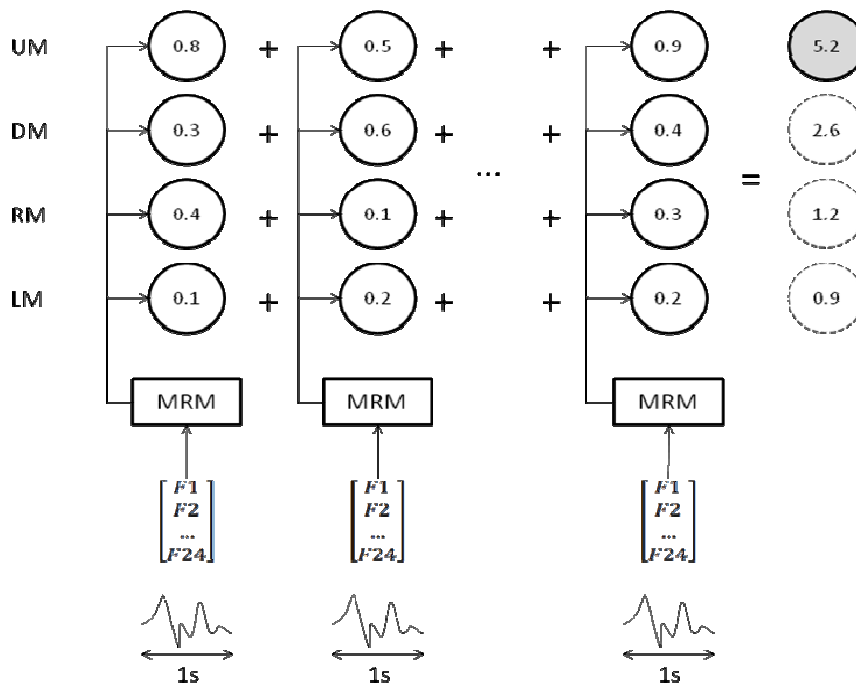


Figura 38 - Exemplo de implementação de disparo com MRM.

É evidente que quanto maior o número de tentativas, maior é a probabilidade de uma classificação final correta, pois a probabilidade de acerto do grupo desejado (o que resulta em graus atribuídos maiores para aquele grupo) em cada tentativa é de 60% (probabilidade obtida com os classificadores), enquanto a probabilidade dos outros grupos está dividida nos 40% restantes. Dessa forma, espera-se que a diferença do somatório dos graus de cada grupo aumente ao longo das tentativas.

O valor de disparo é escolhido, então, de acordo com a habilidade do usuário em se concentrar na atividade mental desejada. Quanto maior a capacidade de concentração do usuário, mais rápido o somatório dos graus da atividade mental desejada diverge dos outros e, conseqüentemente, o número de tentativas pode ser menor, bem como o valor de disparo. Dessa forma, na primeira vez em que o usuário utiliza o sistema, é natural que um valor de

disparo alto seja escolhido e, na medida em que o usuário ganhe experiência em gerar os padrões corretos, esse valor pode ser reduzido.

É importante ressaltar que o grau atribuído pelas redes para cada grupo é limitado ao valor três, pois caso a saída “não pertence ao grupo” tenda a zero, o grau resultante da divisão das duas saídas tenderia a infinito. Então, numa classificação nas melhores condições possíveis, o grau atribuído seria três. Nesse trabalho, o menor valor de disparo atribuído foi 5, o que requer pelo menos duas tentativas de controle. Caso o número de tentativas exceda quinze vezes, determinou-se que nenhuma divergência significativa ocorreu entre o somatório de cada grupo, e o comando é então declarado como “confuso” e nenhuma ação da BMI é tomada.

Deve-se considerar também a possibilidade de dois grupos atingirem o valor de disparo na mesma tentativa. Nesse trabalho, essa situação resulta na ausência de comandos da interface, classificando o comando como “confuso”. Entretanto, essa possibilidade abre espaço para o estudo de uma possível combinação entre os quatro grupos. Por exemplo, caso os grupos UM (associado ao movimento para cima) e RM (associado ao movimento para direita) atingissem o valor de disparo numa mesma tentativa, uma ação intermediária entre esses dois grupos, como mover-se na diagonal superior direita, poderia ser executada pela BMI.

5.5.Implementação Estatística com o Modelo Hierárquico

Como na implementação por disparo, a implementação estatística foi criada de forma a precisar de mais de uma tentativa para dar uma resposta de classificação. Entretanto, ao invés do modelo MRM, o modelo hierárquico é usado como classificador em cada tentativa.

Nessa implementação, a ocorrência da classificação de cada grupo em “n” tentativas é avaliada após um número mínimo de tentativas N_{\min} . Após o número mínimo de tentativas, novas tentativas são avaliadas até que a ocorrência da classificação de um grupo seja maior ou igual a 50%, quando esse grupo é então escolhido como resposta final. Na Figura 39, um exemplo de classificação é apresentado. Após o mínimo de 5 tentativas, somente na oitava tentativa o grupo UM apresentou uma ocorrência maior ou igual a 50%, quando foi então declarado como a classificação final do sistema.

Caso o número de tentativas exceda 15, o comando é declarado como “confuso”, e nenhum comando da BMI é executado. Assim como na implementação por disparo, o número mínimo de tentativas pode aumentar ou

diminuir conforme a habilidade do usuário em gerar os padrões corretos, bem como a porcentagem de ocorrência de classificações de um grupo em “n” tentativas. Vale lembrar que a probabilidade natural de ocorrência entre quatro grupos é de 25%, logo, para se fazer uma classificação, é necessário que o índice de ocorrência seja maior que 25%. Uma análise computacional detalhada deste modelo é feita no capítulo 6.

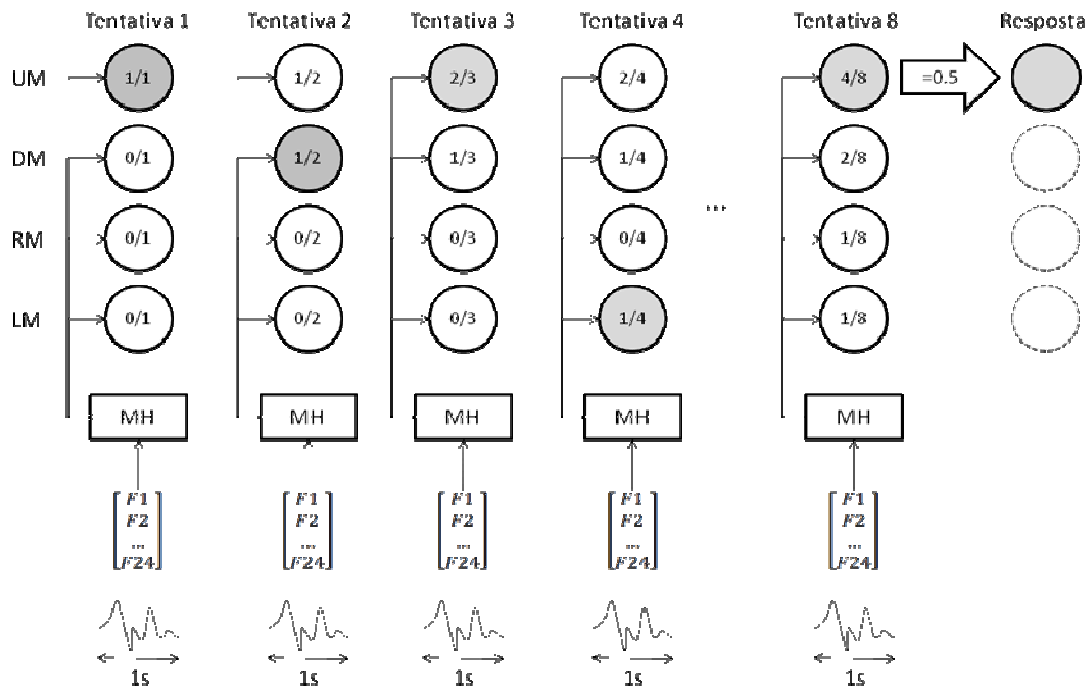


Figura 39 - Exemplo de implementação estatística.

Como dito anteriormente, artefatos podem ser considerados como eventos singulares e aleatórios nos sinais EEG. Dessa forma, numa aplicação com múltiplas classificações, a classificação de um sinal de uma atividade mental contaminado por um artefato não é estatisticamente relevante para a classificação final do sistema, tornando desnecessária a preocupação em detectar tal artefato.

No próximo capítulo, os algoritmos propostos são aplicados à BMI desenvolvida para movimentar um manipulador robótico.

6 Aplicação da BMI a um Manipulador Robótico

Uma vez desenvolvidos os elementos da BMI, resta descrever uma metodologia de aplicação da mesma (Figura 40). Esse capítulo tem como objetivo descrever o uso dos métodos apresentados nos capítulos anteriores no controle de um dispositivo. O dispositivo a ser controlado é um manipulador robótico modelo MA2000, que foi programado para se movimentar em um plano vertical com movimentos para cima, para baixo, para esquerda e para direita, de acordo com os comandos da BMI.



Figura 40 - Sistema completo.

6.1. Controle do Manipulador MA-2000

O manipulador MA2000 (Figura 41), disponível no laboratório onde foram desenvolvidos os experimentos, foi utilizado nesse trabalho.



Figura 41 – Manipulador robótico MA2000.

O manipulador possui 6 graus de liberdade (6DOF), possuindo seis elos, sendo todos eles representados por juntas rotativas como no esquemático da

Figura 42, e todos acionados por motores de corrente contínua. Potenciômetros acoplados ao eixo de rotação de cada elo são utilizados como sensores de posicionamento.

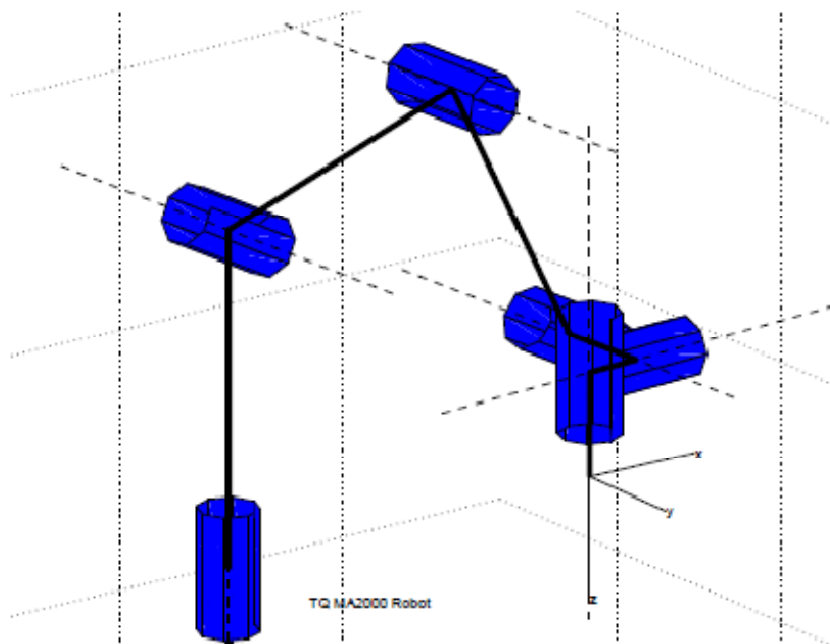


Figura 42 - Modelo esquemático do MA2000.

Para acionamento dos motores de corrente contínua, leitura do potenciômetro, e comunicação com o computador, um sistema eletrônico dedicado foi especialmente desenvolvido para essa dissertação (Figura 43). A eletrônica é composta por três pontes H de alta potência para acionamento dos motores dos três elos próximos à base, três pontes H de baixa potência para acionamento dos três elos próximos à extremidade, um regulador de tensão, conversores A/D para leitura dos potenciômetros, duas entradas de nível lógico opto-acopladas, um conversor de níveis de TTL para RS-232, e um microcontrolador responsável por todo o processamento e comunicação com o computador. A eletrônica possui ainda uma interface de programação ICSP (*In Circuit Serial Programming*) para carregar o microcontrolador com o código de controle.

O microcontrolador escolhido (dsPIC30F4013) pertence à família dsPIC® da empresa Microchip Inc., e é dotado de um processador de 16-bits, memória Flash de 48Kb de programação e memória RAM de 2Kb sendo, então, capaz de executar as instruções necessárias para o controle do manipulador na frequência de controle desejada.




Figura 43 - Eletrônica de controle do manipulador robótico.

Como a BMI desenvolvida possui quatro comandos, o mesmo número de comandos deve ser adotado pelo controle do manipulador. Dessa forma, foi decidido que o manipulador atuaria apenas em um plano vertical, deslocando sua extremidade para cima, para baixo, para a direita, e para a esquerda, sem sair desse plano. Uma vez reduzidos os graus de liberdade necessários às tarefas, optou-se também por reduzir o número de elos do manipulador, sendo mantidos apenas os três primeiros elos próximos à base do manipulador, e os subsequentes foram desmontados. A Figura 44 representa o manipulador e seus parâmetros de Denavit-Hartenberg.

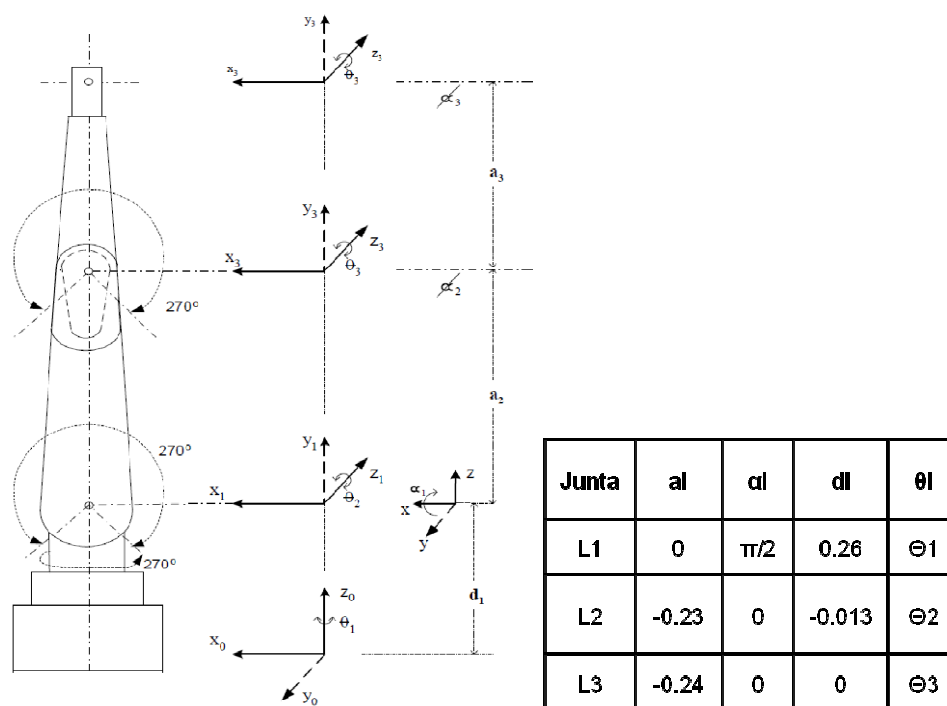


Figura 44 - Parâmetros de Denavit Hartenberg para os três primeiros elos do MA2000.

Sendo assim, o controle do manipulador deve ser capaz de deslocar a extremidade do mesmo ao longo de um plano vertical. Para isso, foi necessário o cálculo da cinemática inversa das três primeiras juntas do manipulador para que, dada a posição desejada da extremidade, seja conhecido também o posicionamento de cada junta. Primeiro calculou-se a cinemática inversa para um manipulador plano, como visto na Figura 45.

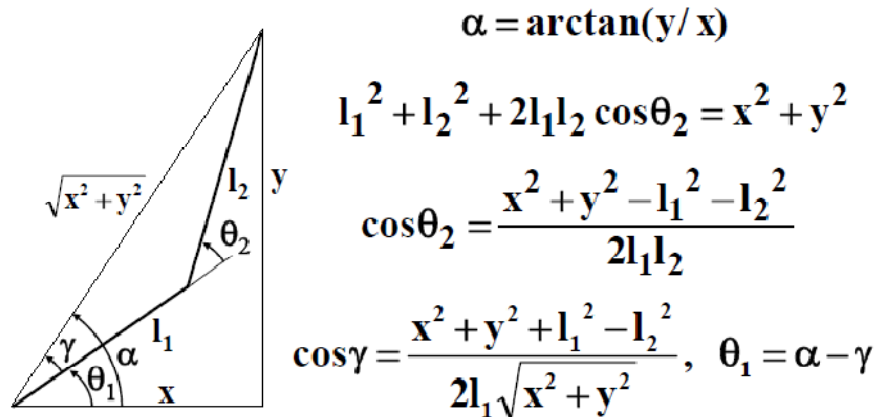


Figura 45 - Cálculo da cinemática inversa para um manipulador de dois elos.

Em seguida, adaptou-se o modelo para o espaço tri-dimensional fazendo as substituições:




Figura 46 - Esquemático 3D dos três primeiros elos do MA2000.

$$\begin{aligned}
\alpha &= \operatorname{atan}\left(\frac{z}{(x^2+y^2)^{\frac{1}{2}}}\right) & \theta_2 &= \gamma - \alpha & \theta_1 &= \operatorname{atan}\left(\frac{y}{x}\right) \\
\theta_2 &= \operatorname{atan}\left(\frac{z}{(x^2+y^2)^{\frac{1}{2}}}\right) - \operatorname{acos}\left(\frac{x^2+y^2+z^2+l_1^2-l_2^2}{2l_1\sqrt{x^2+y^2+z^2}}\right) \\
\theta_3 &= \operatorname{acos}\left(\frac{x^2+y^2+z^2-l_1^2-l_2^2}{2l_1l_2}\right) & & & & (7)
\end{aligned}$$

A cinemática inversa foi programada no microcontrolador, que recebe, via comunicação serial, a posição desejada da extremidade do manipulador (x_d , y_d e z_d) e automaticamente calcula as posições desejadas para cada elo.

Com as posições desejadas dos elos já calculadas, o microcontrolador utiliza um controlador PID (implementado em *software* e gravado também no microcontrolador) para controlar o posicionamento de cada junta individualmente.

Dessa forma, para que o manipulador posicione sua extremidade, basta enviar à eletrônica, por protocolo de comunicação serial (RS-232), as posições x , y e z desejadas para a extremidade, seguidas dos ganhos proporcional, integral e derivativo.

6.2. Protocolo de Treinamento.

Como o título desse trabalho descreve, o processo de treinamento é uma atividade de duas vias onde, primeiramente, a interface se adapta ao usuário e, em seguida, o usuário se adapta à interface. Sendo assim, o treinamento do sistema é dividido em duas etapas: treinamento das redes neurais classificadoras e treinamento do usuário.

Para o treinamento dos classificadores, é necessário que se gere um banco de dados contendo diversos vetores característicos originados das atividades cerebrais do usuário. Para isso, o usuário veste a touca de eletrodos (juntamente com os dois eletrodos posicionados no lóbulo de cada orelha, referentes ao sinal de referência e RLD), conectando-se ao eletroencefalógrafo, e posiciona-se de frente a uma tela de computador, onde são apresentados comandos que indicam quando o usuário deve executar cada uma das atividades mentais.

Primeiramente o computador exhibe, em sua tela, a palavra “BAIXO”. O usuário deve então se concentrar no movimento imaginário de seus pés, e em

seguida pressionar qualquer tecla do computador. Ao pressionar a tecla, um sinal sonoro é emitido, indicando o início da aquisição. A partir daí, o usuário deve continuar se concentrando no movimento imaginário de seus pés por mais onze segundos, quando outro sinal sonoro indica o término da aquisição dos sinais EEG. Desses onze segundos, apenas os dez últimos são realmente adquiridos, a fim de se evitar qualquer influência do sinal sonoro ou do movimento de pressionar a tecla do computador. Dessa forma, o computador divide os dez segundos adquiridos em 10 sinais de um segundo cada que, através do processo de extração de características, serão convertidos em 10 vetores característicos correspondentes à atividade mental DM (movimento para baixo).

Em seguida, o computador exibe na tela a palavra “CIMA”, quando o mesmo procedimento deve ser feito com o usuário se concentrando na imaginação do movimento de sua língua. O mesmo se repete para a atividade “DIREITA”, com a imaginação do movimento do braço direito, e “ESQUERDA”, com a imaginação do movimento do braço esquerdo. Terminadas essas quatro aquisições, o mesmo protocolo se repete 20 vezes, resultando em oitocentos padrões adquiridos (200 padrões de cada atividade mental), que serão divididos em conjuntos de treinamento (400 padrões), de validação (200 padrões) e testes (200 padrões).

Com o banco de dados pronto, pode-se dar início ao treinamento das redes neurais. Os modelos são então carregados e treinados com os padrões adquiridos, e então estão prontos para serem aplicados. No uso do modelo hierárquico, entretanto, deve-se primeiramente treinar o classificador MRM, observar sua matriz de confusão, e identificar os dois padrões com maior índice de erros entre si, para que o segundo nível classifique entre os mesmos.

Após o treinamento da rede, dá-se início ao treinamento do usuário. Os classificadores treinados passam a ser usados em tempo real no controle do manipulador. A partir daí, cabe ao usuário se condicionar a gerar os padrões desejados de forma que o manipulador obedeça aos seus pensamentos. Para isso, o usuário deve tentar executar pelo menos 10 comandos corretos repetidos em sequência para cada um dos quatro comandos possíveis, enquanto olha diretamente para o manipulador. O sinal de reforço nada mais é do que o movimento real do manipulador de acordo com a classificação da interface. No caso específico do classificador interpretar o comando como “confuso”, o computador emitirá um sinal sonoro e indicará também em sua tela que o

usuário excedeu o número de tentativas, mantendo o manipulador parado e dando início a uma nova classificação.

6.3. Uso da Interface.

Muitos elementos de uma interface cérebro máquina são comuns a diferentes aplicações. A mesma interface pode ser usada no controle de diversos dispositivos, mantendo-se os métodos de aquisição dos sinais eletrofisiológicos, os processos de extração de características, e também os métodos de classificação. Então, a determinação do protocolo de utilização está diretamente relacionada à aplicação da interface.

Para o uso da interface no controle do manipulador, devem-se mapear as quatro atividades mentais que a interface é capaz de reconhecer em quatro funções (Figura 47). As atividades mentais escolhidas, como já mencionadas anteriormente, foram o movimento imaginário do braço esquerdo, braço direito, língua e pés, que fazem o manipulador se movimentar para a esquerda, para a direita, para cima e para baixo, respectivamente, ao longo de um plano vertical. No entanto, o movimento do manipulador possui características mono-estáveis baseadas na discretização do seu posicionamento no espaço, sendo o estado estável quando o manipulador está parado. Dessa forma, o manipulador se mantém parado até que um sinal de controle referente à classificação de um dos quatro padrões faça com que se inicie o movimento na direção correspondente. O manipulador irá se movimentar até completar um percurso arbitrado de 3 cm na direção escolhida, quando volta então a ficar parado. No caso de um comando ser classificado como confuso, o manipulador se mantém parado.

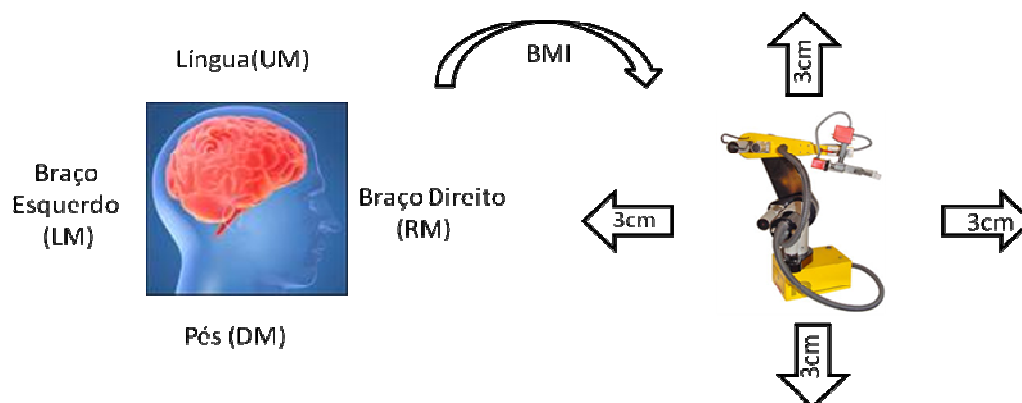


Figura 47 - Correspondência das atividades mentais na ativação de um manipulador robótico.

O controle do movimento do manipulador é feito enviando à eletrônica de controle a posição desejada da extremidade, que se constitui da posição atual da

extremidade acrescida ou diminuída de 3 cm nas coordenadas z ou x, mantendo a coordenada y sempre constante, o que mantém o manipulador em um mesmo plano vertical.

Quando a interface é iniciada, sinais EEG de 1 segundo são constantemente adquiridos e classificados pelos modelos de classificadores. O usuário deve então se concentrar na atividade mental correspondente ao comando desejado pelo tempo necessário à classificação. Esse tempo pode variar de acordo com a habilidade do usuário. Como dito anteriormente, nas duas implementações baseadas em múltiplas tentativas, se o usuário conseguir atingir classificações parciais (a cada 1 segundo) corretas constantemente, mais rapidamente o classificador irá convergir para uma resposta correta. Quando o classificador fornece o resultado, um intervalo de 1 segundo é dado sem aquisição para que o usuário possa mudar a atividade mental sem que o transiente influencie na próxima classificação.

Todos os cálculos computacionais da interface (aquisição e processamento dos sinais, extração de características, classificação dos padrões, e envio da posição desejada para o manipulador) foram implementados no ambiente de desenvolvimento MATLAB®, e o tempo de processamento da ordem de micro segundos se torna desprezível quando comparado ao tempo de 1 segundo de aquisição dos sinais EEG.

6.4. Experimentos e Resultados

6.4.1. Simulações do Algoritmo de Classificação Estatística

A implementação estatística descrita no capítulo 5 visa o aumento da confiabilidade de classificações corretas do classificador através do aumento do número de classificações unitárias. A seguir, é feita uma prova conceitual através da dedução da confiabilidade do sistema simplificado, onde existem dois padrões, “P” e “Q”, e as probabilidades de serem sorteados em um evento são 65% e 35%, respectivamente. Como no classificador descrito, para ser classificado, um padrão precisa apresentar ocorrência maior ou igual a 50% em ‘n’ amostras, com $n \geq 5$. Para esse caso simplificado, sendo apenas dois padrões a se classificar, na quinta tentativa um deles sempre será sorteado pelo menos três vezes, satisfazendo a condição para ser classificado.

Combinações de classificação do padrão P:

Ocorrência de Q e P	Exemplo					Probabilidade
3P x 0Q	P	P	P	X	X	$0.65^3 = 27.46\%$
3P x 1Q	P	P	Q	P	X	$0.65^3 * 0.35 * C_1^3 = 28.84\%$
3P x 2Q	P	Q	Q	P	P	$0.65^3 * 0.35^2 * C_2^4 = 20.18\%$
Total = 76,48%						

Combinações de classificação do padrão Q:

Ocorrência de Q e P	Exemplo					Probabilidade
3Q x 0P	Q	Q	Q	X	X	$0.35^3 = 4.29\%$
3Q x 1P	Q	Q	P	Q	X	$0.35^3 * 0.65 * C_1^3 = 8.36\%$
3Q x 2P	Q	P	P	Q	Q	$0.35^3 * 0.65^2 * C_2^4 = 10.87\%$
Total = 23,52%						

Neste exemplo, para uma distribuição de probabilidade de sorteio qualquer 'p' e 'q' entre os dois padrões, temos que a probabilidade de P ser classificado é dada por:

$$Prob P = p^3 + p^3 * q * C_1^3 + p^3 * q^2 * C_2^4 \quad (8)$$

Generalizando para um número de sorteios 'n' ímpar qualquer, onde 'r' ($r = n/2 + 0,5$) é o número mínimo de ocorrências que satisfaz a condição $\geq 50\%$, temos :

$$Prob P = p^r + \sum_{i=1}^{r-1} p^r * q^i * C_i^{(r+i-1)} \quad (9)$$

Dessa forma, variando o número de sorteios (sempre números ímpares a fim de se evitar resultados de empate que caracterizam um comando confuso), é possível observar que a confiabilidade de classificação do padrão 'P' aumenta com o número de sorteios, desde que $p > q$. Como a probabilidade ProbQ de classificar erroneamente é sempre igual a $1 - ProbP$, a probabilidade de classificação do padrão Q decresce com o aumento do número de sorteios, como pode ser observado na Figura 48.




Figura 48 - Confiabilidade x Número de sorteios.

O problema real estudado nesse trabalho possui quatro padrões com probabilidades de classificação distribuídas não uniformemente, resultando numa dedução analítica muito extensa. Sendo assim, optou-se por usar o método de Monte Carlo para fazer uma análise estatística do problema apresentado. Para validação do método de Monte Carlo utilizado, o modelo simplificado mais uma vez foi abordado, variando-se o número de sorteios (tentativas). O resultado obtido com o modelo analítico e por Monte Carlo foi essencialmente o mesmo para mais de 10^5 eventos simulados, com erros menores que 0,1%, vide Figura 49.

O modelo hierárquico, descrito no capítulo 5, usado na implementação estatística, apresentou um resultado de 65% de classificações corretas. As classificações incorretas (as 35% restantes), no entanto, não estão distribuídas uniformemente entre os outros três padrões e, pela análise da matriz de confusão, pode-se aproximar a probabilidade de classificação dos padrões errados para uma razão $q_1=15\%$, $q_2=10\%$ e $q_3=10\%$. Essa distribuição desigual se justifica pelo fato de os padrões possuírem separabilidades distintas, o que leva um padrão a ter maior ocorrência nas classificações erradas.




Figura 49 - Validação da solução analítica para dois padrões, usando o método de Monte Carlo.

De acordo com a implementação proposta, existe um número mínimo de tentativas N_{\min} (que, como demonstrado, quanto maior for, maior é a confiabilidade de uma classificação correta), bem como um número máximo de tentativas N_{\max} , de modo que o tempo de uma classificação possua um limite superior. A influência do número máximo de tentativas sobre a confiabilidade de classificação (mantendo-se o número mínimo de tentativas $N_{\min} = 5$) é avaliado no gráfico da Figura 50. Pela análise do gráfico, considerando as inclinações da curva de aumento de confiabilidade, pode-se observar que para $N_{\max} = 15$ a confiabilidade atinge um ponto aceitável de convergência.

Outro parâmetro, também avaliado, corresponde à condição de ocorrência mínima em 'n' tentativas para que se classifique um dos padrões. O valor adotado na formulação apresentada foi 0,5, ou seja, é preciso que um padrão seja classificado em pelo menos metade das tentativas. Mas outros fatores poderiam ser considerados. O gráfico da Figura 51 mostra a avaliação da diferença entre as classificações corretas e erradas de acordo com a variação da taxa mínima de ocorrência dos padrões no número de amostras. O gráfico possui as curvas para N_{\min} iguais a 2, 5 e 10. Pode-se então observar que uma

ocorrência mínima de 50% (taxa mínima igual a 0,5, como mencionado anteriormente) para classificação de um padrão apresenta uma diferença entre as classificações corretas e erradas próxima do valor máximo dentre todas as outras taxas, tanto para $N_{\min} = 5$ quanto para $N_{\min} = 10$. Portanto, a adoção do critério de 50% fica assim justificada.

A etapa seguinte consistiu da avaliação da confiabilidade de classificação variando-se N_{\min} , dado um N_{\max} constante. É possível observar no gráfico da Figura 52 que, a partir de um mínimo de 5 tentativas, o aumento da confiabilidade de classificação do padrão correto é muito baixo até que, depois de $N_{\min} = 10$, essa confiabilidade começa a decair com o aumento de N_{\min} . Isso ocorre pois, com N_{\min} se aproximando de N_{\max} , a taxa de classificações confusas tende a aumentar. O caso que apresenta maior confiabilidade de classificações corretas, e com classificações erradas mais baixas, se dá para um $N_{\min} = 10$. Entretanto, o N_{\min} utilizado ($N_{\min} = 5$), resulta em pouca alteração no desempenho, e o tempo de classificação pode ser reduzido pela metade, como é demonstrado a seguir.




Figura 50 - Confiabilidade x Número de tentativas máximo N_{\max} ($N_{\min} = 5$).




Figura 51 - Análise da variação da condição de ocorrência para $N_{\max} = 15$.




Figura 52 - Confiabilidade de classificação x N_{\min} para $N_{\max} = 15$.

O gráfico da Figura 53 mostra o número de tentativas médio que o algoritmo leva para convergir para uma resposta (seja ela correta, errada ou confusa) em função do número mínimo de tentativas. É possível observar que o número de tentativas que o algoritmo leva para fornecer uma resposta varia linearmente com N_{\min} , e se aproxima de uma reta $x = y + 0,5$. Dessa forma, para um $N_{\min} = 5$, o algoritmo tende a convergir para uma solução, em média, na metade do tempo do que para $N_{\min} = 10$, uma vez que cada tentativa possui o mesmo tempo de duração (nos testes efetuados, 1 segundo por tentativa).




Figura 53 - Número de tentativas médio para obtenção de resultado x N_{\min} .

Para um melhor estudo dos resultados, os histogramas da Figura 54 foram gerados, mostrando o número de classificações finais (corretas, erradas ou confusas) obtidas em cada tentativa, calculadas por simulações de Monte Carlo, que avaliou 10^4 eventos. Pode-se ver que, para $N_{\min} = 5$, aproximadamente 80% dos resultados das classificações foram obtidos na quinta tentativa, enquanto para $N_{\min} = 10$ mais de 90% das classificações foram obtidas na décima tentativa.




Figura 54 - Histograma das classificações obtidas pelo número de tentativas.

Das simulações de Monte-Carlo que geraram o gráfico da Figura 52, pode-se extrair então a confiabilidade de ocorrência das classificações corretas, erradas e confusas (Tabela 5), para o caso utilizado nos experimentos com a interface ($N_{\min} = 5$), e para o caso de maior confiabilidade dos comandos corretos ($N_{\min} = 10$).

Tabela 5 - Confiabilidade de classificação.

N_{\min}	Corretos	Confusos	Errados
5	91,83%	1,47%	6,7%
10	94,79%	4,09%	1,12%

Após a avaliação do sistema para quatro comandos, foi decidido realizar um experimento para classificação entre três padrões. As redes neurais foram então treinadas para classificar apenas entre os padrões: Esquerda, Direita e Cima. Um banco de dados gerado pelo mesmo usuário dos demais experimentos foi utilizado para treinamento, validação e testes das redes neurais, resultando na matriz de confusão da Tabela 6.

Tabela 6 - Matriz de confusão para três padrões.

	UM	RM	LM
UM	32	11	7
RM	4	44	2
LM	9	6	35

Dessa forma, podem-se aproximar as probabilidades para: Acerto = 74%, $q_1 = 16\%$ e $q_2 = 10\%$.

Analisando o gráfico da Figura 55, pode-se observar que houve uma elevação acentuada da confiabilidade de se classificar o padrão correto entre apenas três (ao invés de quatro), chegando a 96,2% para $N_{\min} = 5$ e 98,6% para $N_{\min} = 10$. Assim, em aplicações envolvendo apenas 3 tipos de comando, é desejável implementar esta versão reduzida com apenas 3 padrões, devido ao aumento de confiabilidade.




Figura 55 - Confiabilidade x N_{\min} para três padrões.

6.4.2. Experimentos com a Interface.

Experimentos (Figura 56) foram realizados com um único usuário saudável, do sexo masculino com 24 anos de idade (o autor). Cada seção

experimental incluiu o protocolo de treinamento e utilização da interface. O usuário permaneceu sentado sozinho, confortavelmente em um ambiente silencioso, olhando fixamente para o manipulador. As seções foram limitadas a um período de duas horas, já incluso o período de treinamento, e não se repetiam em período inferior a três dias.



Figura 56 - Experimento com a interface para controle do manipulador.

Os experimentos consistiram em executar 100 vezes cada movimento do manipulador (totalizando 400 comandos), divididos em dez seções de 10 movimentos consecutivos para cada comando. Entre as seções, o usuário foi solicitado a repousar por não mais do que cinco minutos. No total, dois experimentos foram feitos (400 comandos cada), cada um utilizando um dos métodos de classificação descritos anteriormente (disparo e estatístico). Cada classificação levou em média 5 tentativas (5 segundos) para ser concluída. Os resultados do controle do manipulador robótico para as implementações por disparo e estatística encontram-se na Tabela 7.

Tabela 7 - Resultados da aplicação da BMI ao manipulador robótico.

Controle MA2000	Comandos Corretos	Comandos Confusos	Comandos Errados
Implementação de Disparo	82,75%	9,75%	7,5%
Implementação Estatística	84,25%	5,75%	10,0%

Para fins comparativos, o sistema foi rapidamente adaptado para controlar um robô móvel de 55Kg (Figura 57), com locomoção diferencial, que possui sistema de locomoção e potência semelhantes aos de uma cadeira de rodas elétrica (66). O robô em questão já se encontrava disponível no Laboratório de Robótica da PUC-Rio, e já estava configurado para ser operado por rádio frequência. Dessa forma, nenhum desenvolvimento adicional foi necessário.



Figura 57 - Experimento com o robô móvel: 1- Eletrodos; 2- Computador; 3- EEG; 4-PCTx Link; 5-Transmissor RF; 6-Robô móvel.

O controle do robô foi feito pelo mapeamento das atividades mentais (Figura 58) da seguinte maneira: o movimento imaginário da língua move o robô meio metro para frente; os movimentos imaginários dos braços esquerdo e direito fazem o robô girar 30 graus à esquerda e 30 graus à direita, respectivamente; e a imaginação dos movimentos dos pés faz com que o robô permaneça parado.




Figura 58 - Correspondência das atividades mentais: robô móvel.

A mesma metodologia experimental utilizada na avaliação do controle do manipulador robótico foi também utilizada, e os resultados podem ser vistos na Tabela 8.

Tabela 8 - Resultados da aplicação a um robô móvel.

Controle Robô Móvel	Comandos Corretos	Comandos Confusos	Comandos Errados
Implementação de Disparo	88.75%	4.5%	6.75%
Implementação Estatística	91.0%	1.25%	7.75%

Os resultados obtidos na aplicação com o robô móvel são superiores aos obtidos no controle do manipulador robótico. Isso se deve, provavelmente, ao ambiente em que foram realizados os experimentos, e ao treinamento das redes neurais, que podem ter resultado num melhor classificador para o caso do robô. O ambiente em que se encontrava o robô móvel apresentava condições mais favoráveis ao uso da interface, como silêncio, iluminação e conforto, do que o local onde se encontrava o manipulador robótico. Os fatores ambientais impactam diretamente na concentração do usuário e alteram, mesmo que subconscientemente, alguns sinais EEG relacionados ao estresse emocional e à fadiga física.

Foi possível observar, através dos resultados, que em ambas as aplicações a implementação do classificador estatístico resultou em um melhor índice de classificações corretas. Isso pode ter ocorrido devido ao método de estimativa dos graus atribuídos aos grupos na classificação baseada em MRM.

Apesar de possuírem boa generalização, as redes neurais envolvidas podem não alterar proporcionalmente as suas saídas (pertence ou não pertence ao grupo), de acordo com nível de concentração do usuário no momento em que se gera um novo padrão. Isso poderia acarretar então numa discrepância no somatório das saídas em várias classificações. Entretanto, a implementação por disparo possui grande potencial para futuros estudos na combinação (linear ou não) de comandos, na medida em que a semelhança de determinados padrões a dois grupos distintos pode ser avaliada e propagada ao longo das tentativas. Outra maneira de classificação combinada poderia ser obtida com o usuário se concentrando durante alguns segundos num comando, e alguns segundos em outro comando, resultando num alto somatório de graus para dois padrões ao longo das tentativas.

Os resultados obtidos com os experimentos utilizando a interface são compatíveis com os previstos pelas simulações de Monte Carlo.

7 Conclusões e Trabalhos Futuros

Uma interface cérebro máquina não-invasiva baseada no condicionamento operante do RSM foi desenvolvida, operando com quatro atividades mentais para o comando de um manipulador robótico. A interface utiliza algoritmos inovadores, e utiliza atividades mentais intuitivas, como a imaginação do movimento do braço esquerdo para mover o manipulador para esquerda, sem a necessidade da imaginação de sólidos em rotação, ou mesmo operações aritméticas como são utilizadas em outras interfaces.

O processo de treinamento é realizado em duas etapas. Na primeira, a interface aprende os padrões do usuário e, na segunda, o usuário aprende a controlar seus sinais cerebrais para ativação da interface.

Através de experimentos, foi concluído que a representação de uma atividade mental por um vetor característico que contenha as energias das bandas Alpha, Beta e 0-32Hz de um sinal EEG com duração de um segundo, para oito eletrodos, resulta em uma alta separabilidade entre diferentes atividades mentais.

Diferentes classificadores baseados em redes neurais foram utilizados para classificar entre quatro atividades mentais distintas. Um extenso banco de dados de 8.000 padrões foi utilizado para treinar e avaliar esses classificadores. Dentre eles, o que apresentou melhor desempenho foi o modelo hierárquico. Entretanto, o percentual de acerto apresentado por esse modelo pode ser considerado insuficiente para a maioria das aplicações. Para aumentar a confiabilidade de uma classificação correta, duas implementações baseadas em múltiplas classificações foram desenvolvidas e avaliadas.

Para a implementação estatística, foi feita uma análise da dependência do modelo a alguns parâmetros que, além de ser usada na validação dos experimentos, demonstra que a interface pode ser adaptada a usuários em diferentes níveis de treinamento. Para um usuário com pouca ou nenhuma experiência no uso da interface, pode-se definir o número mínimo de classificações consecutivas de forma a aumentar a confiabilidade e, conseqüentemente, o tempo de resposta. Para um usuário com mais

experiência, o número de classificações mínimas pode ser reduzido e, juntamente com ele, o tempo de resposta do sistema.

Os resultados obtidos através de experimentos com a interface se aproximam muito dos obtidos pela análise estatística, para ambos os dispositivos estudados (robô móvel e manipulador). É importante destacar que o cansaço físico, a falta de concentração, e outros fatores que implicam numa redução da probabilidade de acerto do classificador baseado em redes neurais, resultam em perda de desempenho do sistema como um todo.

As implementações dos classificadores com múltiplas tentativas resultaram em um aumento significativo do percentual de acertos e numa redução ainda maior do percentual de erros, introduzindo um novo conceito de comando confuso. Esse conceito é de valor inestimável do ponto de vista de engenharia, pois está relacionado diretamente à satisfação e segurança do usuário.

Pôde-se observar ao longo dos experimentos que o usuário apresentou um aumento gradativo na capacidade de controle ao longo do tempo, necessitando de diversas seções de treinamento para atingir o seu desempenho máximo de controle. Observou-se também que, de um experimento para outro, realizados em dias diferentes, é necessário que o usuário treine a interface novamente, aplicando o protocolo de treinamento desde o início. Concluiu-se então que, apesar de o usuário acumular uma capacidade de controle dos sinais cerebrais ao longo dos experimentos, esses sinais podem ser sensivelmente diferentes entre esses experimentos. Assim sendo, um usuário terá mais dificuldade na sua adaptação à interface quando essa tiver sido treinada com padrões de experimentos passados, em outro ambiente, ou com os eletrodos posicionados de forma diferente.

O sistema completo, salvos o computador pessoal e as licenças de software, foram desenvolvidos a um custo unitário relativamente baixo, da ordem de US\$500,00. Assim, espera-se atingir um número significativo de usuários. Para aproximar a interface ainda mais de um sistema de baixo custo e alto desempenho, foi desenvolvida uma placa eletrônica dedicada contendo um DSP (*Digital Signal Processor*) capaz de armazenar o algoritmo de classificação, que substitui o computador pessoal e dispensa seu uso durante o uso da interface. Note, no entanto, que o treinamento ainda precisa ser executado com o uso do computador pessoal.

Como trabalhos futuros sugerem-se a investigação de novos modelos de classificadores baseados em múltiplas tentativas, e o desenvolvimento de uma metodologia de programação da eletrônica, de modo a conter o algoritmo de

classificação. Sugere-se também a otimização dos modelos existentes, investigando a relação entre a redução do tempo de aquisição dos sinais EEG (que resulta na redução do tempo de classificação de uma tentativa) e o número de tentativas utilizadas para obtenção de uma resposta. Acredita-se ser possível que um número maior de classificações mais rápidas (menos que 1 segundo cada, o valor adotado nos experimentos) resulte em um maior percentual de acertos e, dependendo de quantas tentativas forem necessárias, num menor tempo de classificação.

A classificação de três padrões apresentou resultados superiores à de quatro padrões. Dessa forma pode-se investigar a viabilidade do uso de uma interface com apenas três padrões, quando aplicável à tarefa em questão. para aumentar ainda mais a confiabilidade.

Bibliografia

1. **Garcia, G. N.** Direct brain-computer communication through scalp recorded EEG signals. *Doctor's thesis, Department of Electricity, Ecole Polytechnique Fédérale de Lausanne, Lausanne.* 2004.
2. **Millan, J. d. R.** Brain-Computer Interfaces, Handbook of Brain Theory and Neural Networks. *Cambridge, MA, The MIT Press.* 2, 2002.
3. **Norris, F. H.** Amyotrophic lateral sclerosis: The clinical disorder. *In R. A. Smith (Ed), Handbook of Amyotrophic Lateral Sclerosis.* (pp.3–38). New York: Marcel Dekker., 1992.
4. **Birbaumer, N.** Slow cortical potentials: Plasticity, operant control, and behavioral effects. *The Neuroscientist, 5,* 74–78. 1999.
5. **Birbaumer N, Elbert T, Canavan AGM, Rockstroh B.** Slow cortical potentials of the cerebral cortex and behavior. *Physiol Rev* 70:1–41. 1990.
6. **Kubler, A., Kotchoubey, B., Kaiser, J., Wolpaw, J., & Birbaumer, N.** Brain-computer communication: Unlocking the locked-in. *Psychological Bulletin, 127,* 358–375. 2001.
7. **Birbaumer, N., Hinterberger, T., Kubler, A., & Neumann, N.** The thought-translation-device (TTD): Neurobehavioral mechanisms and clinical outcome. *IEEE Transactions on Neural Systems and Rehabilitation Engineering, 11,* 120–123. 2003.
8. **Wolpaw, J. R., Birbaumer, N., McFarland, D., Pfurtscheller, G., & Vaughan, T.** Brain-computer interfaces for communication and control. *Clinical Neurophysiology, 113,* 767–791. 2002.
9. **Wolpaw, J. R., & McFarland, D. J.** Control of a two-dimensional movement signal by a noninvasive brain-computer interface in humans. *Proceedings of the National Academy of Sciences, USA, 101,* 17849–17854. 2004.
10. **Schalk, McFarland, Hinterberger,.** BCI2000. <http://www.bciresearch.org/>. [Online] 2004.
11. **Birbaumer, N.** Breaking the silence: Brain-computer interfaces (BCI) for communication and motor control. *Psychophysiology, 43.* 2005.

12. **Kennedy, P. R., Kirby, M. T., Moore, M. M., King, B., & Mallory, A.** Computer control using human intracortical local field potentials. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 12, 339–344. 2004.
13. **Brunner, C., Graitmann, B., Huggins, J. E., Levine, S. P., & Pfurtscheller.** Phase relationships between different subdural electrode recordings in man. . *Neuroscience Letters*, 375, 69–74. 2005.
14. **Carmena, J. M., Lebedev, M. A., Crist, R. E., O’Doherty, J. E., Santucci, D. M., Dimitrov, D. F., et al.** Learning to control a brain-machine interface for reaching and grasping by primates. *PLoS Biology*, 1, E42. 2003.
15. **Garcia, G. N.** Direct Brain-Computer Communication. *Doctor’s thesis*. Lausanne : s.n., 2004.
16. **Machado, Angelo.** *Neuroanatomia Funcional*. s.l. : Atheneu, 1993.
17. <http://www.jcda.ca/article/a25>. *JCDA.CA*. [Online] [Citado em: 23 de Agosto de 2010.]
18. **B. Obermaier, G. Müller, G. Pfurtscheller.** Virtual Keyboard controlled by spontaneous EEG activity. 2001.
19. **Mourino, J. del R. Millán and J.** Asynchronous BCI and local neural classifiers: an overview of the adaptive brain interface project. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*. pp. 159–161, 2003, Vol. 11, 2.
20. **Pfurtscheller, G.** Graz-bci: State of the Art and Clinical Applications. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*. pp.177–180, 2003, Vol. 11, 2.
21. **B. Rebsamen, E. Burdet, C. Guan, C. L. Teo, Q. Zeng, M. Ang, C. Laugier.** Controlling a wheelchair using a BCI with low information transfer rate. *IEEE International Conference on Rehabilitation Robotics (ICORR)*. 2007, Vols. pp. 1003-1008.
22. **F. Galán, M. Nuttin, E. Lew, P. W. Ferrez, G. Vanacker, J. Philips and J. del R. Millán.** A Brain-Actuated Wheelchair: Asynchronous and Non-Invasive Brain-Computer Interfaces for Continuous Control of Robots. *Clinical Neurophysiology*. pp. 2159–2169, 2008, Vol. 119.
23. **I. Iturrate, J. Antelis, A. Kübler, J. Minguez.** A noninvasive brain-actuated wheelchair based on a P300 neurophysiological protocol and automated navigation. *IEEE Transactions on Robotics*. pp. 1–14, 2009, Vol. 99.

24. **J. d. R. Millán, F. Renkens, J. Mouriño, W. Gerstner.** Noninvasive Brain-Actuated Control of a Mobile Robot by Human EEG. *IEEE Transactions on Biomedical Engineering*. pp 1026-1033, 2004, Vol. 51, 6.
25. **E. R. Kandel, J. H. Schwartz, and T. M. Jessell.** Principles of Neural Science. 1991, 3.
26. Neuro Development Center. <http://www.neurodevelopmentcenter.com>. [Online] [Citado em: 30 de Julho de 2010.]
27. 10-20 System of Electrode Placement. [Online] [Citado em: 07 de Julho de 2010.] <http://faculty.washington.edu/chudler/1020.html>.
28. **W. W. Orrison Jr., J. D. Lewine, J. A. Sanders, and M. F. Hartshorne.** Functions Brain Imaging. St Louis : Mosby-Year Book, Inc, 1995.
29. <http://fc.units.it/ppb/neurobiol/neuroscienze%20per%20tutti/1020.html>. [Online] [Citado em: 23 de Agosto de 2010.]
30. **Skinner, B. F.** The Behavior of Organisms, NewYork: Appleton, 1938.
31. **Vaughan, T. M., et al.** Brain-Computer Interface Technology: A Review of the Second International Meeting, IEEE Transactions on Neural Systems and Rehabilitation Engineering, 11(2):94–109, June 2003.
32. **Miller, N.** Learning of visceral and glandular responses. *Science*. 163, 434–445, 1969.
33. **Skinner, F.** Science and Human Behavior. . NewYork: Macmillan, 1953.
34. **Kamiya, J.** Biofeedback and self-control: An Aldine reader. *Chicago: Aldine*. 1971.
35. **Birbaumer, N.** Operant enhancement of EEG-theta activity: Aspiration and reality. In *J. Beatty & H. Legewie (Eds.), Biofeedback and Behavior (pp. 135–146)*. New York: Plenum Press. 1977.
36. **Sterman, M. B.** EEG biofeedback: Physiological behavior modification. *Neuroscience and Biobehavioral Reviews*. 5, 1981, Vols. , 405–412.
37. **Pfurtscheller, G., Neuper, C., & Birbaumer, N.** Human brain–computer interface (BCI). In *A. Riehle & E. Vaadia (Eds.), Motor cortex in voluntary movements. A distributed system for distributed functions (pp. 367–401)*. Boca Raton, FL: CRC Press. 2005.
38. **Jeannerod, M. J.** Mental imagery in the motor context. *Neuropsychologia*. 33(11):1419–1432, 1995.
39. **Nikolaev, A. R. e Anokhin, A. P.** Eeg frequency ranges during perception and mental Rotation of two and three dimensional objects. *Neuroscience and Behavioral Physiology*, 6(28):670–677, 1998.

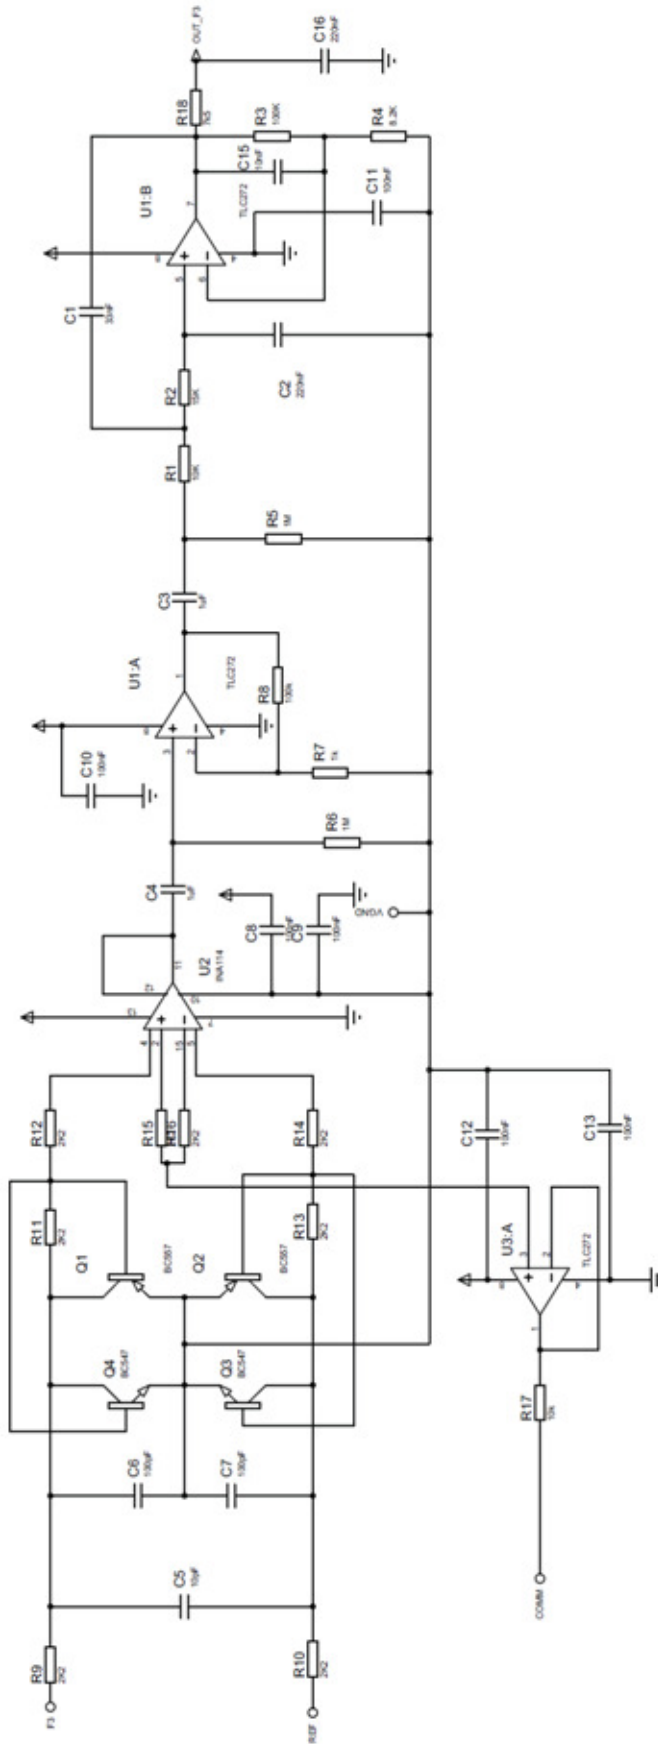
40. **Galin, D. e Ornstein, R. F.** Human Behavior and Brain Function., chapter *Hemispheric Specialization and the Duality of Consciousness*, pp. 3–23, Thomas Books, 1975.
41. **Rotenberg, V. S. e Arshavsky, V. V.** Right and left brain hemispheres activation in the representatives of two different cultures. *Homeostasis in Health & Disease*, 38(2):49–57, 1997.
42. **Sutter, E.E.** The brain response interface: communication through visually-induced. *Journal of Microcomputer Applications*. pp. 31—45, 1992, Vol. 15.
43. **Bragdon, R.M. Chapman and H.R.** Evoked responses to numerical and nonnumerical. *Nature*. pp. 1155 - 1157, 1964, Vol. 203.
44. **John, S. Sutton and M. Braren and J. Zublin and E.** Evoked potential correlates of. *Science*. pp. 1187 - 1188, 1965, Vol. 150.
45. **Donchin, L.A. Farwell and E.** Talking off the top of the head: toward a mental prosthesis utilizing event-related brain potentials. *Electroenceph. Clin. Neurophysiol.* pp. 510—523, 1988.
46. **Schwartz, Andrew B.** CORTICAL NEURAL PROSTHETICS. Pittsburgh, Pennsylvania : Departments of Neurobiology and Bioengineering, University of Pittsburgh, 2004.
47. **Meel Velliste, Sagi Perel, M. Chance Spalding, Andrew S. Whitford and Andrew B. Schwartz.** Cortical control of a prosthetic arm for self-feeding. *Nature*. 2008.
48. **Machado, Saulo Jesiel Siqueira.** Desenvolvimento de um sistema de captura e processamento de sinais eletroencefalográficos quantitativo não-invasivo. *Universidade Federal de Uberlândia*.
49. **Van de Velde, M., Van Erp, G. e Cluitmans, P. J. M.** Detection of muscle artifact in the normal human awake EEG. . *Electroencephalography and Clinical Neurophysiology*. 107(2):149–158, April1998.
50. **TORRELLA, M.** Topographic mapping of EEG and evoked potentials in psychiatry:Delusions, illusions, and realities. *Brain Topography*.
51. **HAYKIN S.** 1994. *Neural Networks: A Comprehensive Foundation*. Macmillan, New York, NY.
52. **Dan Griffiths, Nelo, Jim Peters, Andreas Robinson, Jack Spaar.** OpenEEG. <http://openeeg.sourceforge.net/doc/index.html>. [Online] [Citado em: 17 de 07 de 2010.]
53. **Benning, M., et al.** The Experimental Portable EEG/EMG Amplifier. *ELEC 499A Report, University of Victoria, Faculty of Engineering*. 2003.

54. **Joseph J. Carr, John M. Brown.** Introduction to Biomedical Equipment Technology. 4th edition, 2001 isbn 0-13-010492-2.
55. <http://focus.ti.com/docs/prod/folders/print/ina114.html>. [Online] 26 de Julho de 2010.
56. <http://sine.ni.com/nips/cds/view/p/lang/en/nid/201987>. [Online] 26 de Julho de 2010.
57. **Babiloni F, Cincotti F, Carducci F, Rossini PM, Babiloni C.** Spatial enhancement of EEG data by surface Laplacian estimation: the use of magnetic resonance imaging-based head models. *Clin Neurophysiol.* 112:724–7, 2001.
58. **PL., Nunez.** Toward a quantitative description of large-scale neocortical dynamic function and EEG. *Behav Brain Sci.* 23:371–437, 2000.
59. **PL., Nunez.** Electric fields of the brain. *New York: Oxford University Press.* 1981.
60. **B., Hjorth.** An on-line transformation of EEG scalp potentials into orthogonal source derivations. *Electroenceph Clin Neurophysiol.* 526–30, 1975, Vol. 39.
61. **C. Tandonnet, B.Burle, T.Hasbroucq, F.Vidal.** Spatial enhancement of EEG traces by surface Laplacian estimation: comparison between local and global methods. *Clinical Neurophysiology.* pp. 18-24, 2005, Vol. 116, 1.
62. **Akay, M.** Wavelets applications in medicine. *Spectrum.* pp. 50-57, 1997.
63. **Sergio Fugivara, Alison de O. Moraes, José C. J. de Almeida.** Aplicação da transformada de wavelets para compressão de dados de telemetria. *CTA – Centro Técnico Aeroespacial.*
64. **A.O.G. Barbosa, D.R. Achancaray, M. Vellasco, M.A. Meggiolaro, R. Tanscheit.** Mental Tasks Classification for a Noninvasive BCI Application. *19th International Conference on Artificial Neural Networks, ICANN'09, Limassol, Cyprus.* 2009.
65. **D.R. Achancaray, M.A. Meggiolaro.** Brain Computer Interface Based on Electroencephalographic Signal Processing. *XVI IEEE International Congress of Electrical, Electronic and Systems Engineering - INTERCON 2009, Arequipa, Peru, 2009.*
66. **Alexandre O. G. Barbosa, David R. Achancaray, and Marco A. Meggiolaro.** Activation of a Mobile Robot through a Brain Computer Interface. *2010 IEEE International Conference on Robotics and Automation, Anchorage Convention District, May 3-8, 2010, Anchorage, Alaska, USA.* 2010.

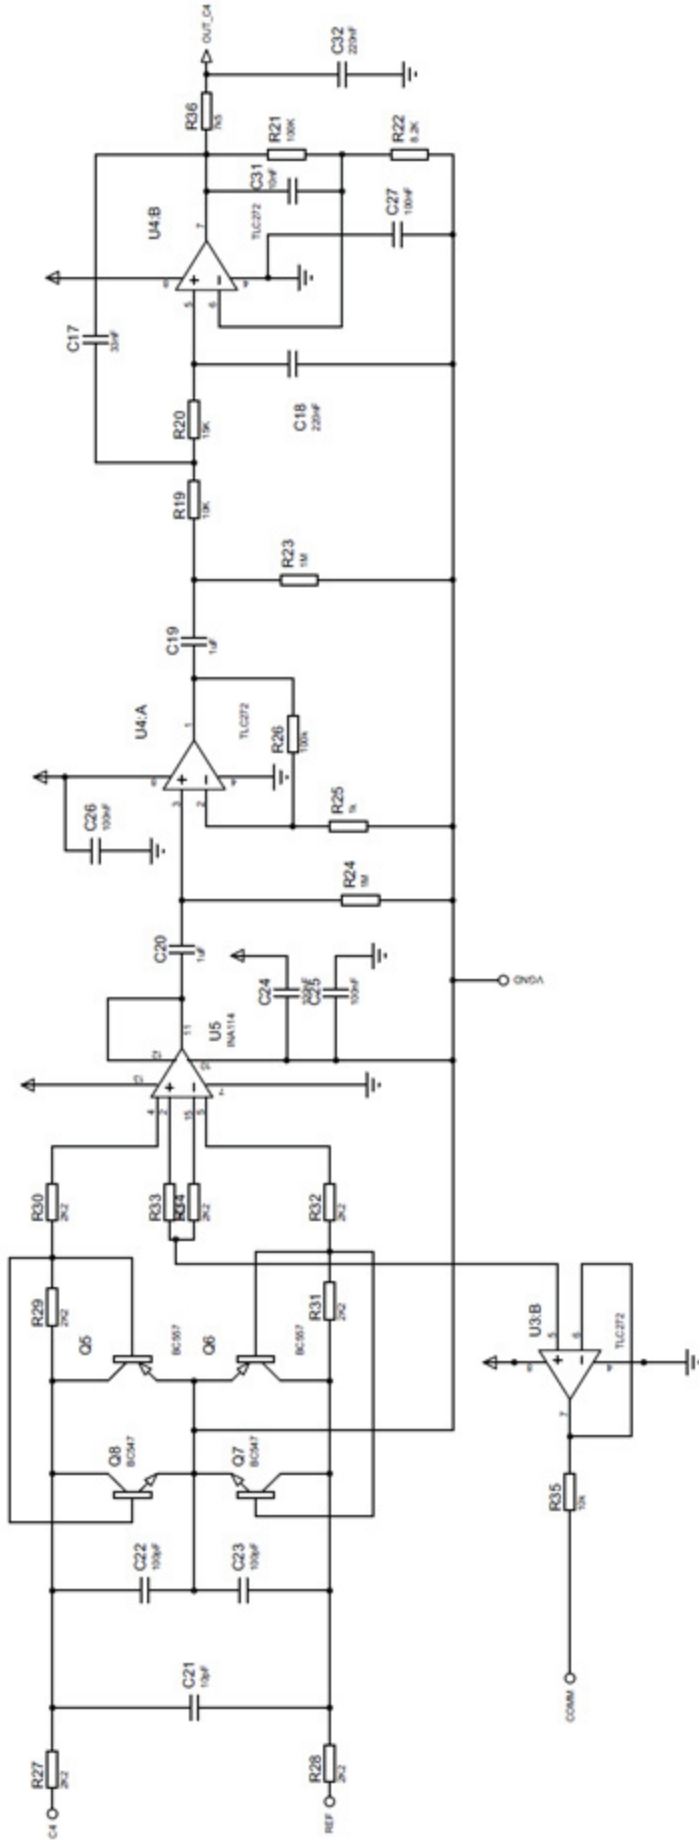
Anexos

- I. Circuito esquemático do eletroencefalógrafo.
- II. Circuito impresso do eletroencefalógrafo.
- III. Circuito esquemático da eletrônica do manipulador.
- IV. Circuito impresso da eletrônica do manipulador.
- V. Código do microcontrolador da eletrônica do manipulador.
- VI. *Datasheet* do amplificador instrumental INA114.

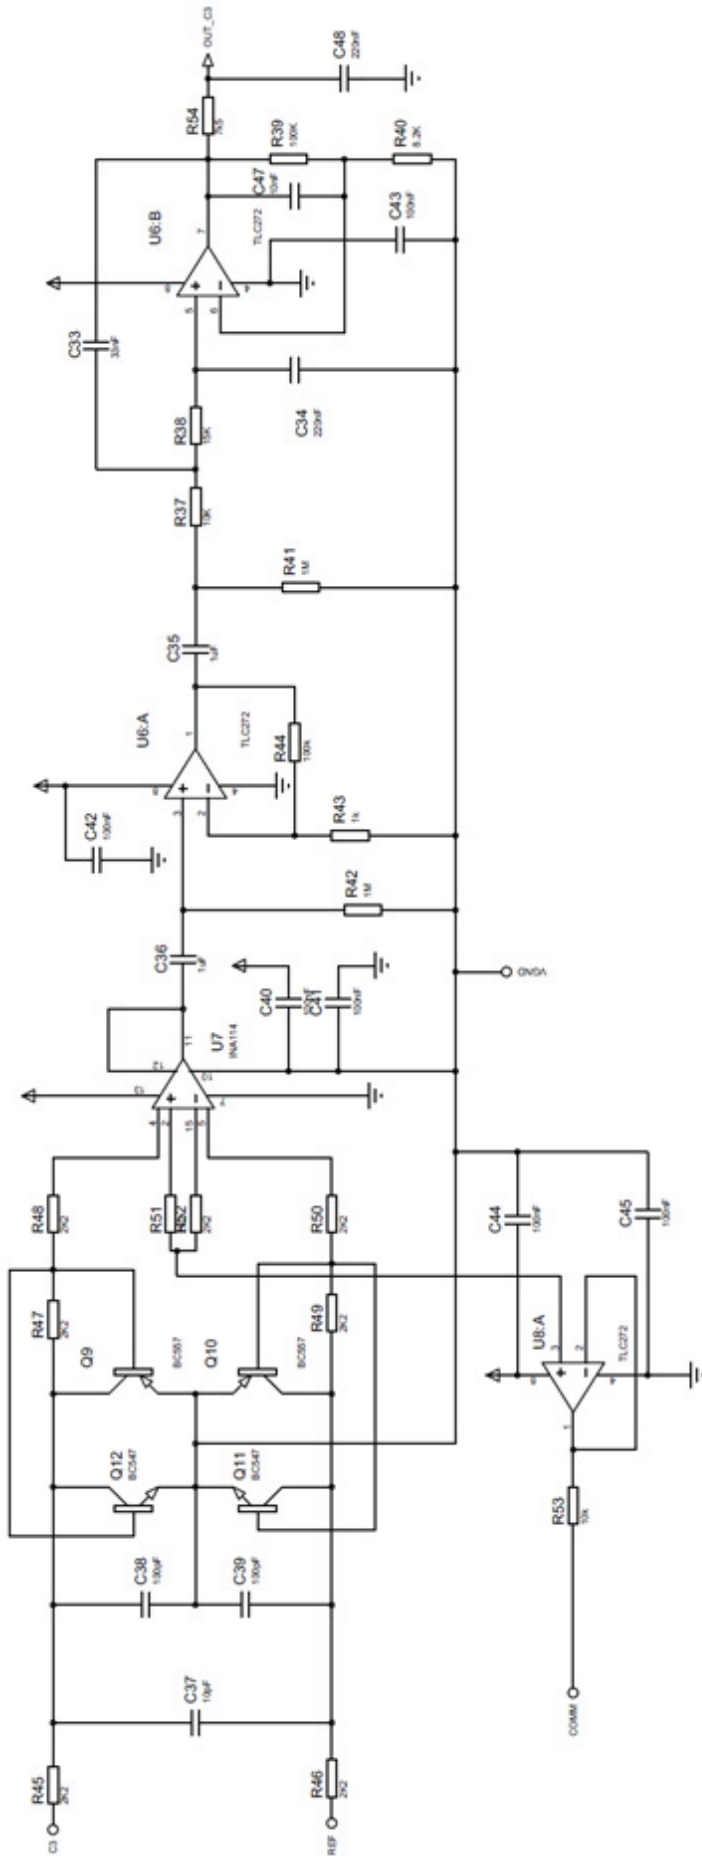
Anexo I



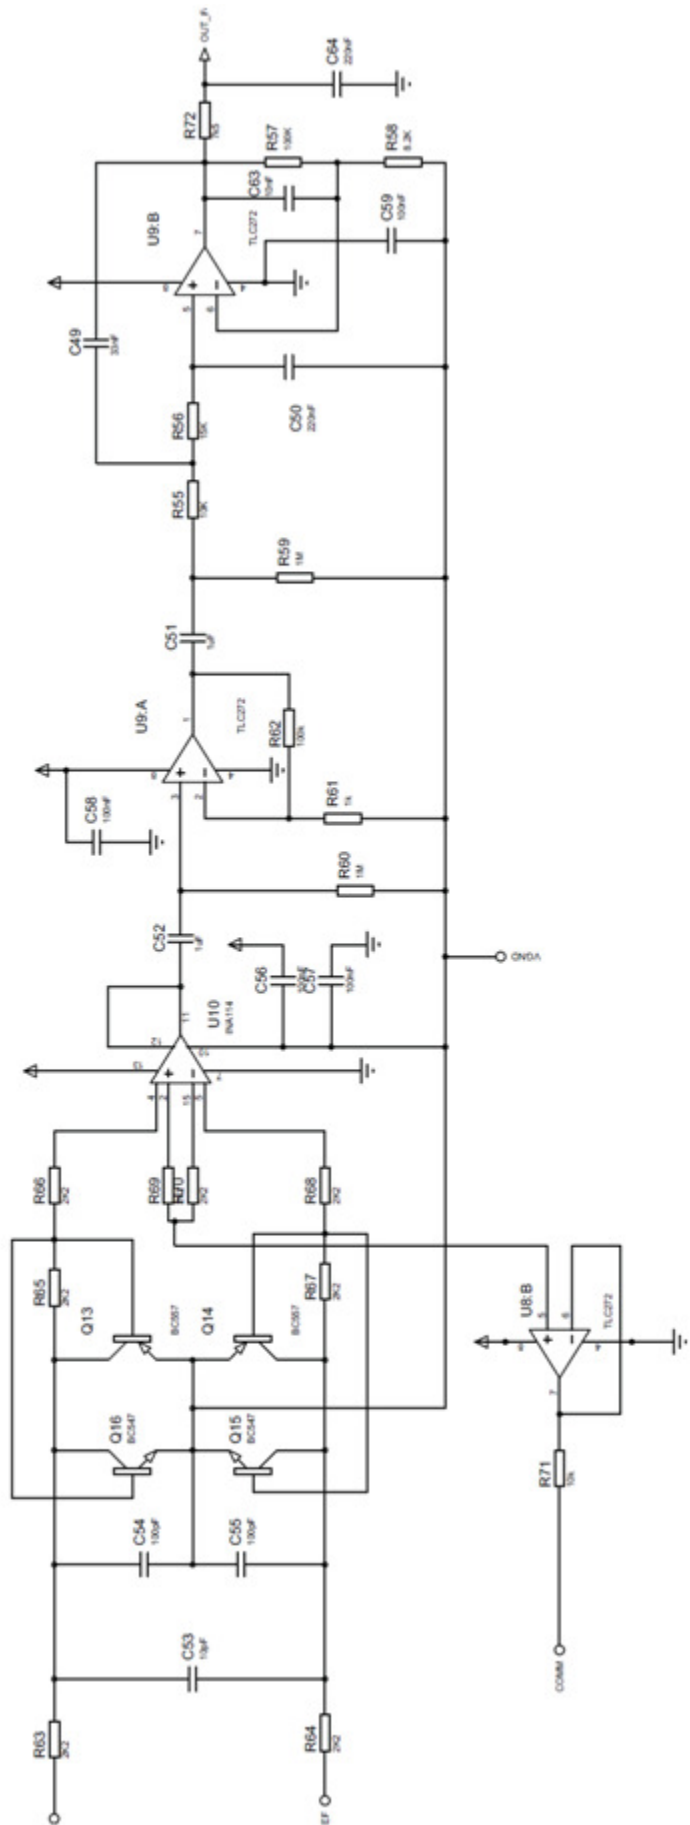
TITLE	8CH - EEG	DATE	10/08/10
BY: Barbosa, Alexandre O. G.		PAGE	1/9
		REV.	



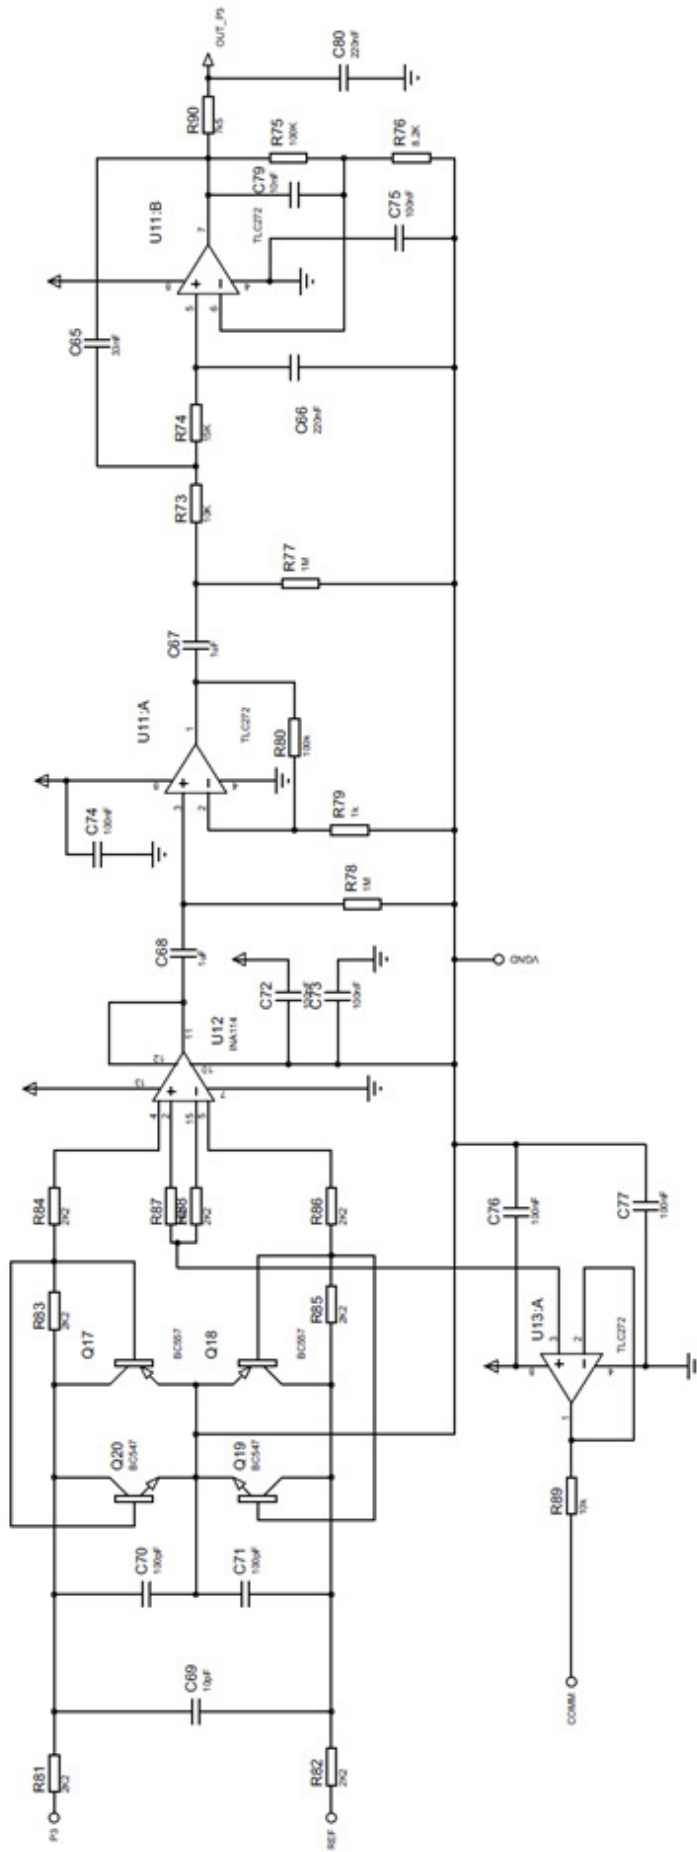
TITLE	8CH - EEG	DATE	10/08/10
BY	Barbara Alvares O. G.	PAGE	2/9
		REV	



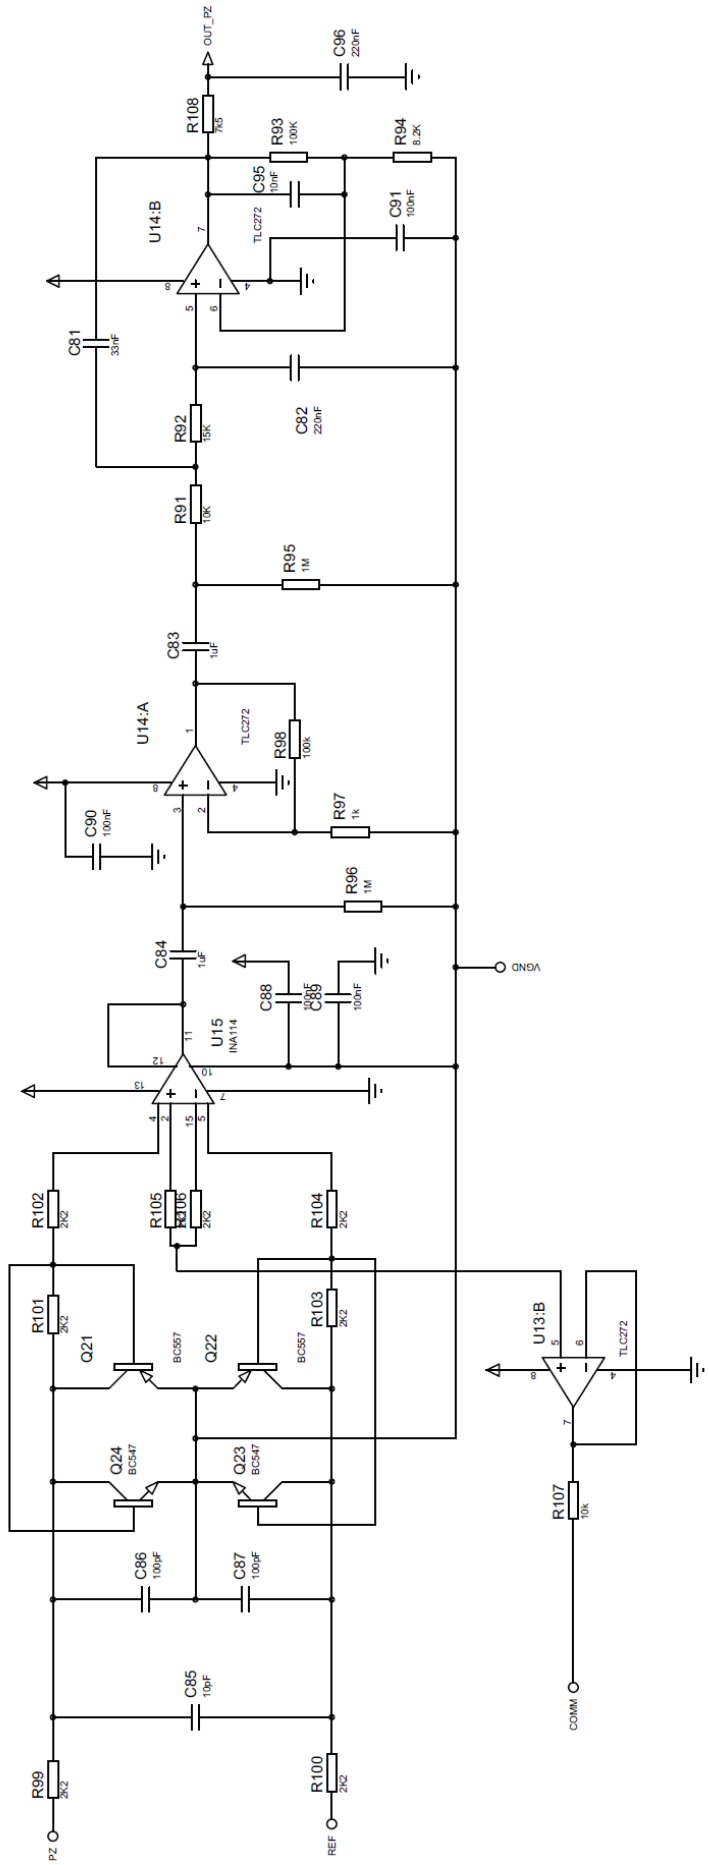
TITLE:	8CH - EEG	DATE:	10/08/10
BY:	Barbara Alexandra O. G.	PAGE:	3/9
		REV:	



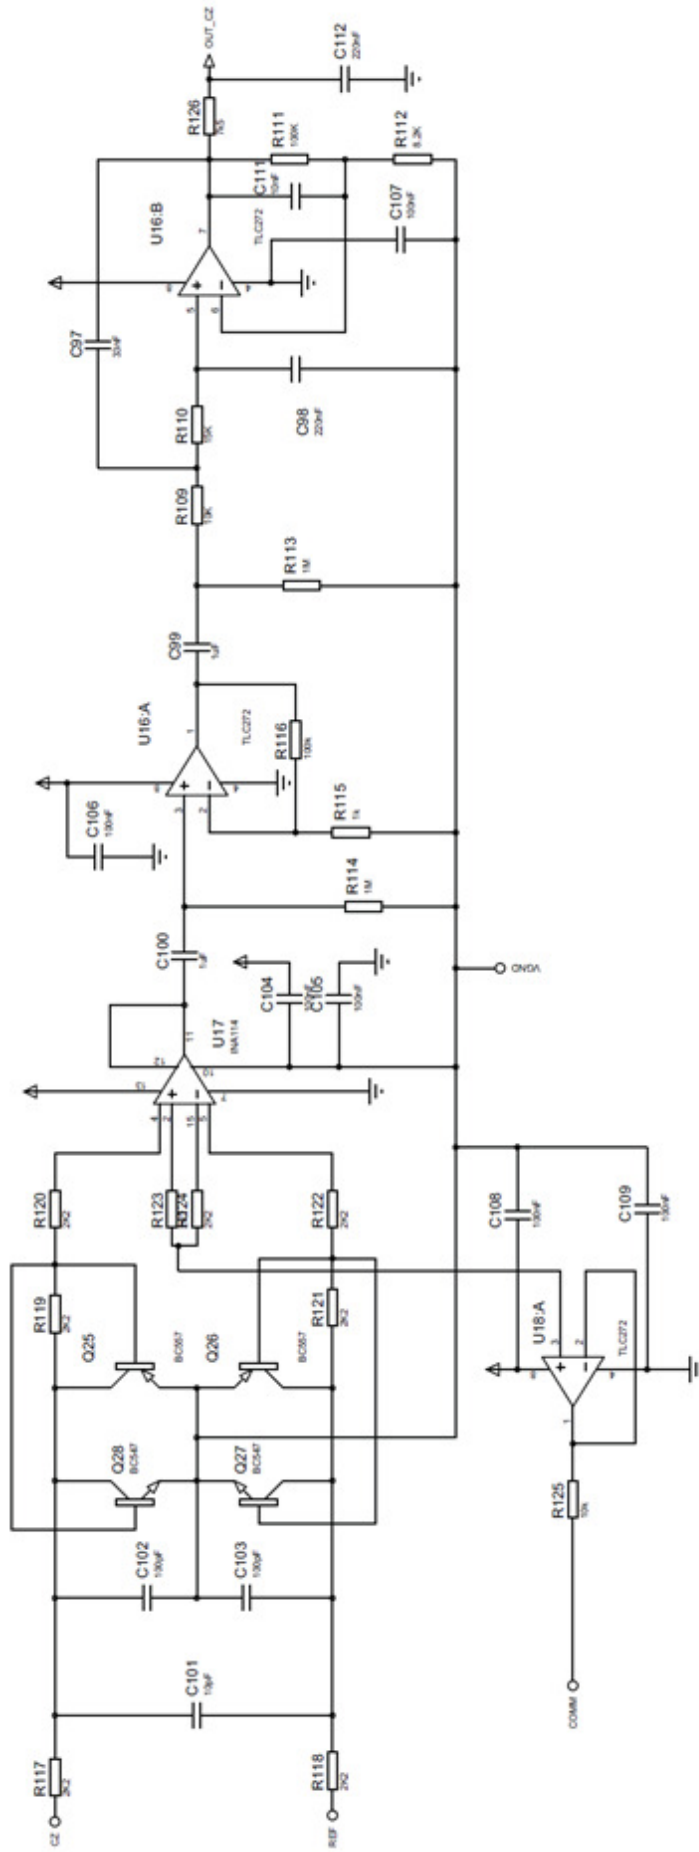
TITLE:	8CH - EEG	DATE:	10/08/10
BY:	Barbosa, Alexandre D. G.	PAGE:	4/9
		REV:	



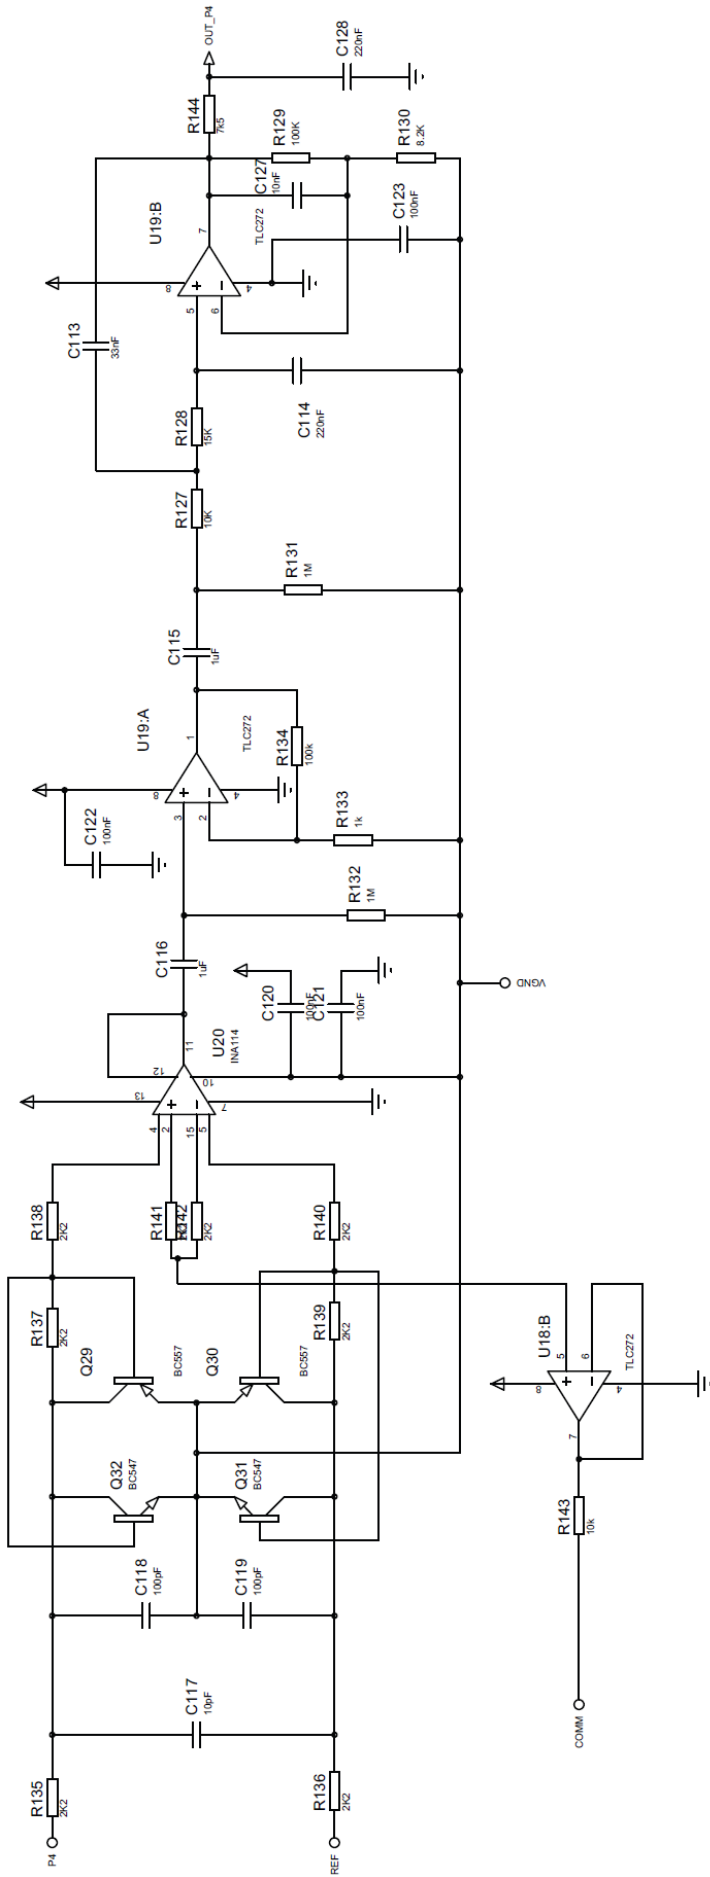
TITLE	DATE
8CH - EEG	10/08/10
REV	PAGE
BV - Barbosa, Alexandre O. G.	5/9






TITLE:	8CH - EEG	DATE:	10/08/10
BY:	Barbosa, Alexandre O. G.	PAGE:	6/9
REV:			



TITLE	8CH - EEG	DATE	10/08/10
BY: Barbara Almeida O. G.		PAGE:	7/9
		REV:	




TITLE:	8CH - EEG
DATE:	10/08/10
PAGE:	8/9
BY:	Barbosa, Alexandre O. G.
REV:	




TITLE:	8CH - EEG	DATE:	10/08/10
BY:	Barbosa, Alexandre O. G.	PAGE:	9/9
		REV:	

Anexo II

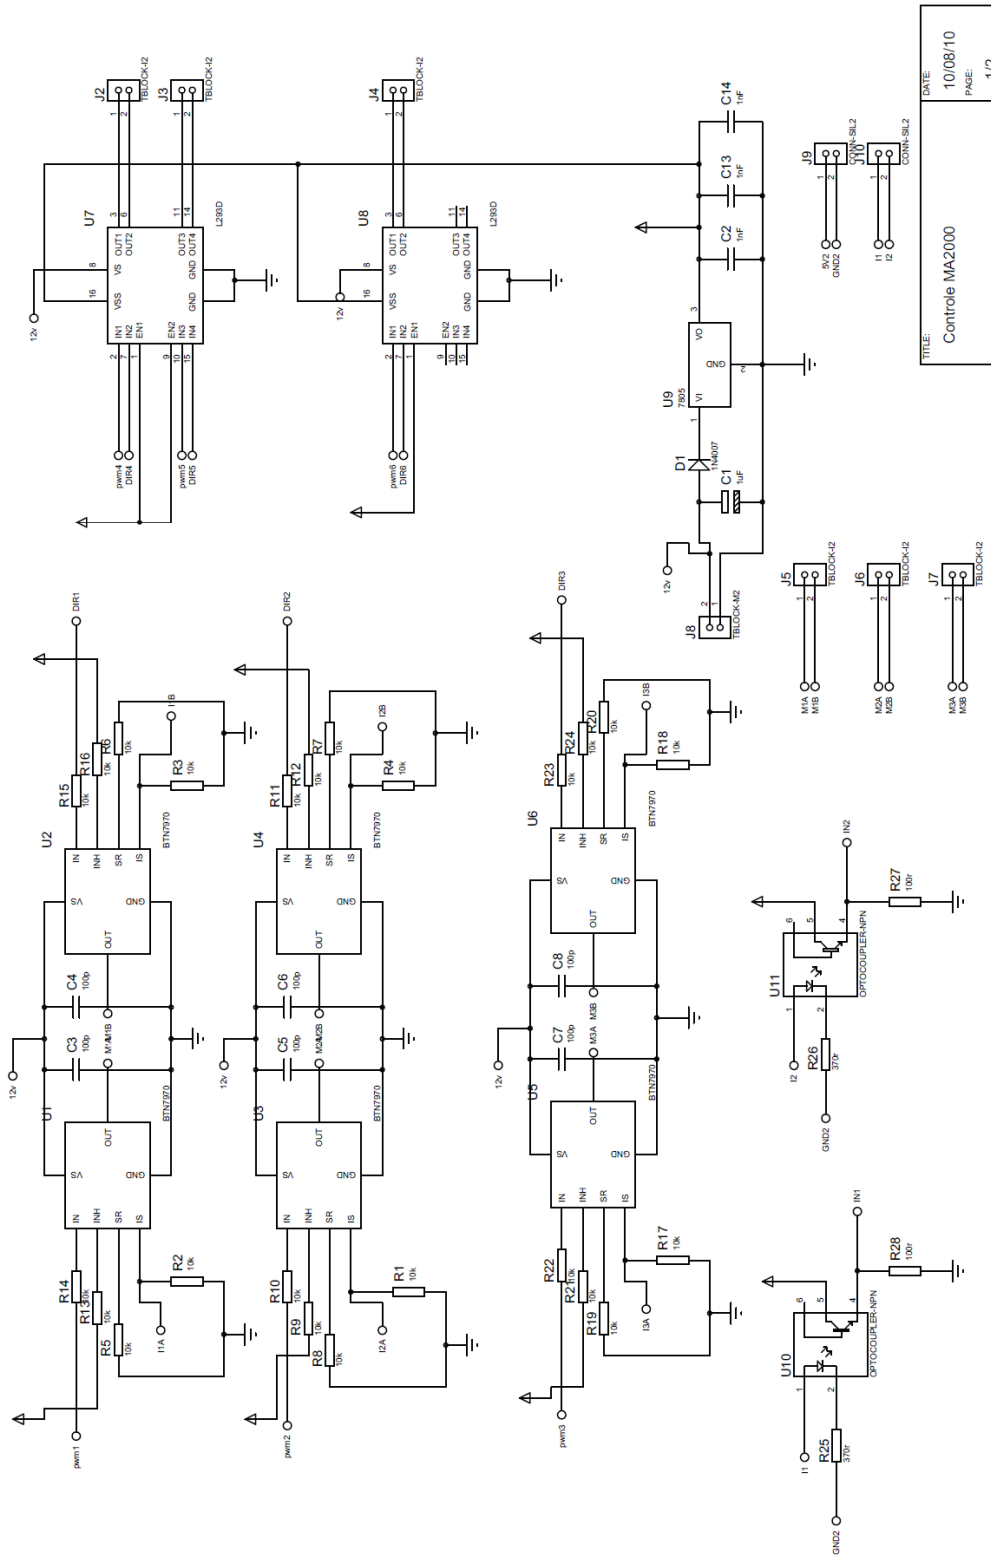


Face Superior

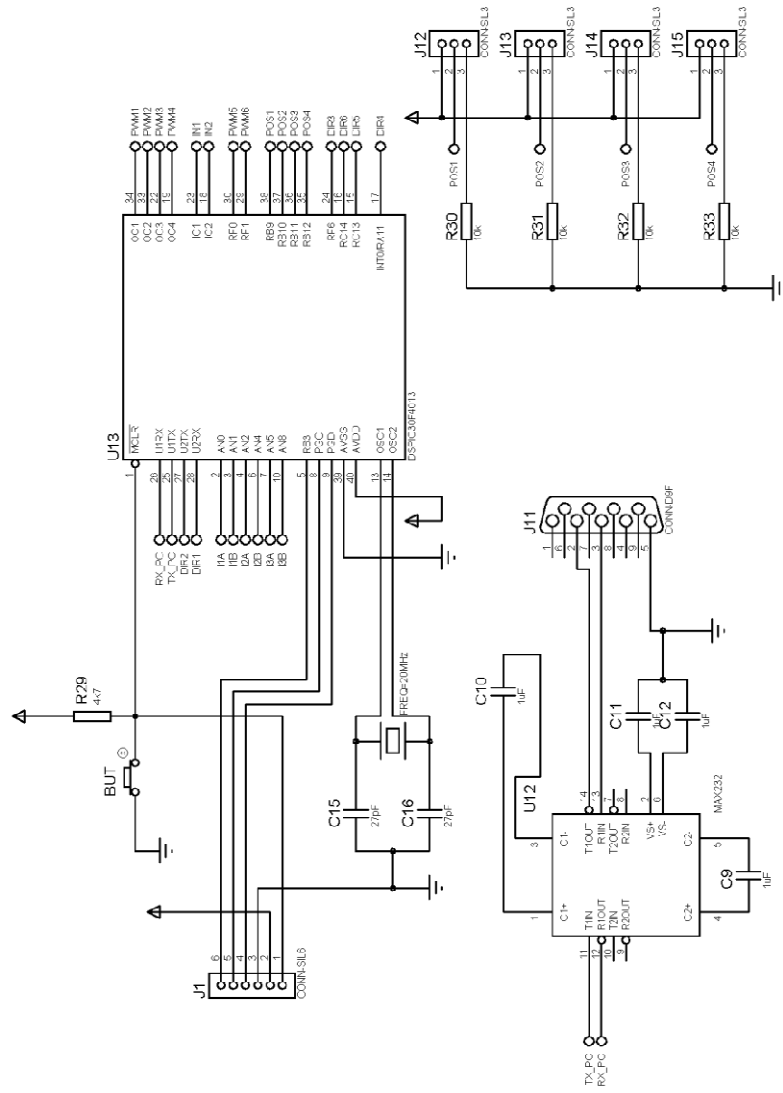


Face inferior

Anexo III




TITLE:	Control MA2000
BY:	Barbosa, Alexandre Olimpia Galvão
REV:	1
DATE:	10/08/10
PAGE:	1/2




TITLE	DATE
Control MA2000	10/08/10
EY: Barros, Alexandre Omega Cavêdo	PAGE
REV. 1	2/2

Anexo IV



Face superior



Face inferior


```

void RDA_isr()
{
    xi = getc ();
    yi = getc ();
    zi = getc ();
    kpi = getc ();
    kii = getc ();
    kdi = getc ();
    kt_m2i = getc ();
    kti = getc ();
    flag = 1;
    x = xi;
    y = yi;
    z = zi;
    kp = (FLOAT) kpi / 100.00;
    ki = (FLOAT) kii / 1000.00;
    kd = (FLOAT) kdi / 100.00;
    kt_m2 = (FLOAT) kt_m2i;
    kt = (FLOAT) kti / 100.00;
}

//*****
// LEITURA DAS POSIÇÕES //////////////////////////////////////
//*****

float read_pos(INT link)
{
    FLOAT pos;
    set_adc_channel (link);
    delay_us (10);
    pos = read_adc ();
    RETURN pos;
}

//*****
// Cinemática INVERSA //////////////////////////////////////
//
//*****

void id()
{
    flag = 0;
}

```

```

sum = pwr (x, 2) + pwr (y, 2) + pwr (z, 2);
sum2 = pwr (x, 2) + pwr (y, 2);

IF (y == 0)
{
    y = 0.0001;
}

p1_des = atan (x / y) ;
p2_des = atan (z / (sqrt (sum2))) - acos ((sum - 47.00) / (sqrt (sum) * 46.00));
p3_des = acos ( ( (pwr (x, 2) + pwr (y,2) + pwr (z, 2)) - 1105.0) / 1104.0);
printf ("LINK1 = %f LINK2 = % f LINK3 = % f",p1_des, p2_des, p3_des);
delay_ms (10) ;
putc (13) ;
delay_ms (10) ;
p1_des = ((p1_des * 360 / 2 / 3.1415) * (65536 - 4183) / 360) + 35200.00;
p2_des = ((p2_des * 360 / 2 / 3.1415) * (65536 - 4183) / 360) + 32600.00;
p3_des = ((p3_des * 360 / 2 / 3.1415) * (65536 - 4183) / 360) + 25000;
printf ("LINK1 = %f LINK2 = % f LINK3 = % f",p1_des, p2_des, p3_des);
delay_ms (10) ;
putc (13) ;
delay_ms (10) ;
printf ("kp = %f ki = % f kd = %f", kp, ki, kd);
delay_ms (10) ;
putc (13) ;
delay_ms (10) ;
printf ("Cons. de Torque = %f kt_pos = % f", kt_m2, kt);
delay_ms (10) ;
putc (13) ;
delay_ms (10) ;
printf ("-----");
delay_ms (10) ;
putc (13) ;

IF (p3_des > 65536)
{
    p3_des = p3_des - 65536;
}

IF (p2_des > 65536)

```

```

{
    p2_des = p2_des - 65536;
}
}

//*****
// CONTROLE DE POSIÇÃO ////////////////////////////////////////////////////
//*****

float POS_contr(INT16 channel, float p, float p_des)
{
    FLOAT V = 0, ep1 = 0, ep2 = 0;
    ep = p_des - p;

    IF (ep > 34000)
        ep = - (65536 - ep);

    IF (ep < (-34000))
        ep = (65536 + ep);
    epi[channel] = epi[channel] + ep;
    epd = epant[channel] - ep;

    IF (epi[channel] > 100000)
        epi[channel] = 100000;

    IF (epi[channel] < (-100000))
        epi[channel] = - 100000;
    V = ep * kp + epi[channel] * ki + epd * kd;
    epant[channel] = ep;

    IF (V > 10000)
        V = 10000;

    IF (V < - 10000)
        V = - 10000;

    IF ( (ep < 100)&& (ep > - 100) )
        V = 0;
    RETURN V;
}

```

```

//*****
// TORQUE GRAVIDADE //////////////////////////////////////
//*****

float q_grav (FLOAT ang)
{
    FLOAT i_grav;
    ang = ( ang - 32600.00) / (65536 - 4183) * 2 * 3.1415;
    i_grav = cos (ang) * ((0.88 * 9.8 * 0.07) + (0.963 * 9.8 * 0.23)) * kt_m2;
    RETURN i_grav;
}

//*****
// ACIONAMENTO DOS MOTORES //////////////////////////////////////
//*****

void motor(INT link, float power)
{
    INT16 duty = 0;
    INT pin = 0;

    IF (power >= 0)
    {
        duty = (INT16) power;

        SWITCH (link)
        {
            CASE 1:
                output_low (DIR_1) ;
                set_pwm_duty (1, duty) ;
                BREAK;

            CASE 2:
                output_low (DIR_2) ;
                set_pwm_duty (2, duty) ;
                BREAK;

            CASE 3:
                output_low (DIR_3) ;
                set_pwm_duty (3, duty) ;
                BREAK;
        }
    }
}

```

```

}

ELSE
{
    duty = (INT16) (10000 + power);

    SWITCH (link)
    {
        CASE 1:
            output_high (DIR_1) ;
            set_pwm_duty (1, duty) ;
            BREAK;

        CASE 2:
            output_high (DIR_2) ;
            set_pwm_duty (2, duty) ;
            BREAK;

        CASE 3:
            output_high (DIR_3) ;
            set_pwm_duty (3, duty) ;
            BREAK;
    }
}

}

//*****
//*****
////////////////////////////////////////////////////////////////// MAIN //////////////////////////////////////
//*****
//*****

void main()
{

    INT loop_PID_POS = 0;

    FLOAT q1_POS = 0, q2_POS = 0, q3_POS = 0, q1_grav = 0, q2_grav = 0,
q3_grav
    = 0, q1_cur = 0, IA = 0, IB = 0;
    FLOAT p1 = 0, p2 = 0, p3 = 0;

```

```

setup_timer1 (TMR_INTERNAL|TMR_DIV_BY_8, 30000) ;
setup_timer2 (TMR_INTERNAL|TMR_DIV_BY_64, 10000) ;
setup_adc (ADC_CLOCK_INTERNAL);
setup_adc_ports (ALL_ANALOG);
enable_interrupts (INT_RDA);
enable_interrupts (INTR_GLOBAL);
setup_compare (1, COMPARE_PWM|COMPARE_TIMER2) ;
setup_compare (2, COMPARE_PWM|COMPARE_TIMER2) ;
setup_compare (3, COMPARE_PWM|COMPARE_TIMER2) ;
setup_compare (4, COMPARE_PWM|COMPARE_TIMER2) ;

output_low (DIR_1) ;
output_low (DIR_2) ;
output_low (DIR_3) ;
set_pwm_duty (1, 0) ;
set_pwm_duty (2, 0) ;
set_pwm_duty (3, 0) ;
p3_des = 23530.00;
p2_des = 32600.00;
p1_des = 35200.00;
delay_ms (2000) ;

//*****
****

// LOOP PRINCIPAL //////////////////////////////////////
///
//*****
****

WHILE (true)
{
  IF (flag == 1)
  {
    id ();
    flag = 0;
  }

  IF (loop_PID_POS == 1)
  {
    p1 = read_pos (POS1) ;
    p2 = read_pos (POS2) ;
  }
}

```

```
p3 = read_pos (POS3) ;  
// printf (" % f % f %f\n\r", p1, p2, p3);  
q1_POS = POS_contr (1, p1, p1_des) ;  
q2_POS = POS_contr (2, p2, p2_des) ;  
q3_POS = POS_contr (3, p3, p3_des) ;  
  
loop_PID_POS = 0;  
}  
  
motor (1, q1_POS) ;  
motor (2, q2_POS) ;  
motor (3, q3_POS) ;  
loop_PID_POS++;  
}  
}
```

Anexo VI



INA114

Precision INSTRUMENTATION AMPLIFIER

FEATURES

- LOW OFFSET VOLTAGE: 50 μ V max
- LOW DRIFT: 0.25 μ V/ $^{\circ}$ C max
- LOW INPUT BIAS CURRENT: 2nA max
- HIGH COMMON-MODE REJECTION: 115dB min
- INPUT OVER-VOLTAGE PROTECTION: \pm 40V
- WIDE SUPPLY RANGE: \pm 2.25 to \pm 18V
- LOW QUIESCENT CURRENT: 3mA max
- 8-PIN PLASTIC AND SOL-16

APPLICATIONS

- BRIDGE AMPLIFIER
- THERMOCOUPLE AMPLIFIER
- RTD SENSOR AMPLIFIER
- MEDICAL INSTRUMENTATION
- DATA ACQUISITION

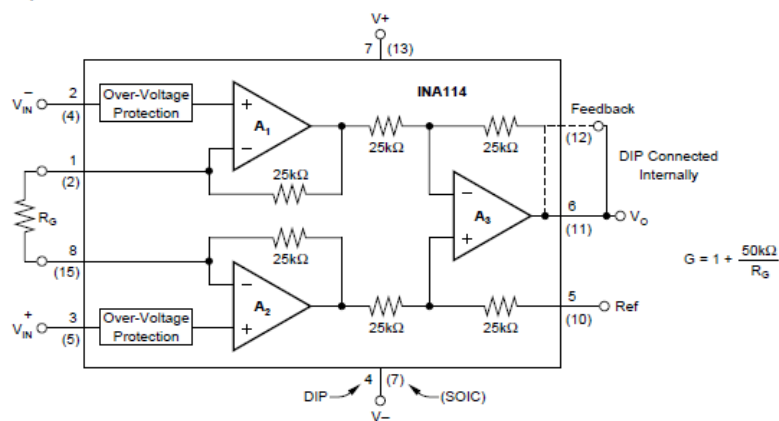
DESCRIPTION

The INA114 is a low cost, general purpose instrumentation amplifier offering excellent accuracy. Its versatile 3-op amp design and small size make it ideal for a wide range of applications.

A single external resistor sets any gain from 1 to 10,000. Internal input protection can withstand up to \pm 40V without damage.

The INA114 is laser trimmed for very low offset voltage (50 μ V), drift (0.25 μ V/ $^{\circ}$ C) and high common-mode rejection (115dB at G = 1000). It operates with power supplies as low as \pm 2.25V, allowing use in battery operated and single 5V supply systems. Quiescent current is 3mA maximum.

The INA114 is available in 8-pin plastic and SOL-16 surface-mount packages. Both are specified for the -40° C to $+85^{\circ}$ C temperature range.



International Airport Industrial Park • Mailing Address: PO Box 11400, Tucson, AZ 85734 • Street Address: 6730 S. Tucson Blvd., Tucson, AZ 85706 • Tel: (520) 746-1111 • Tw: 910-852-1111
Internet: <http://www.burr-brown.com/> • FAXLine: (800) 548-6133 (US/Canada Only) • Cable: BBRCORP • Telex: 066-6491 • FAX: (520) 889-1510 • Immediate Product Info: (800) 548-6132

SPECIFICATIONS

ELECTRICAL

At $T_A = +25^\circ\text{C}$, $V_S = \pm 15\text{V}$, $R_L = 2\text{k}\Omega$, unless otherwise noted.

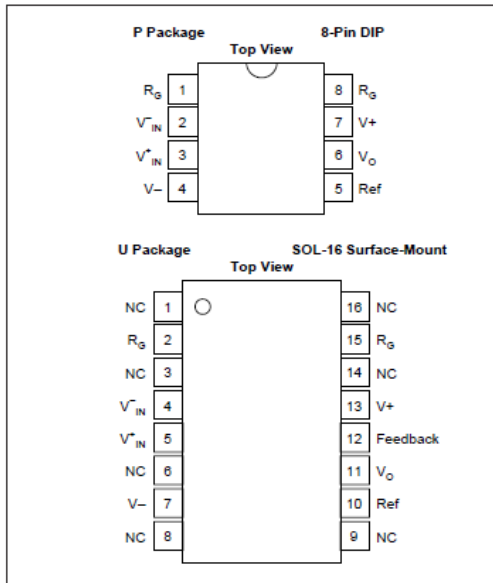
PARAMETER	CONDITIONS	INA114BP, BU			INA114AP, AU			UNITS
		MIN	TYP	MAX	MIN	TYP	MAX	
INPUT Offset Voltage, RTI Initial vs Temperature vs Power Supply Long-Term Stability Impedance, Differential Common-Mode Input Common-Mode Range Safe Input Voltage Common-Mode Rejection	$T_A = +25^\circ\text{C}$ $T_A = T_{\text{MIN}}$ to T_{MAX} $V_S = \pm 2.25\text{V}$ to $\pm 18\text{V}$ $V_{\text{CM}} = \pm 10\text{V}$, $\Delta R_G = 1\text{k}\Omega$ $G = 1$ $G = 10$ $G = 100$ $G = 1000$		$\pm 10 + 20/G$ $\pm 0.1 + 0.5/G$ $0.5 + 2/G$ $\pm 0.2 + 0.5/G$ $10^{10} \parallel 8$ $10^{10} \parallel 8$	$\pm 50 + 100/G$ $\pm 0.25 + 5/G$ $3 + 10/G$		$\pm 25 + 30/G$ $\pm 0.25 + 5/G$ *	$\pm 125 + 500/G$ $\pm 1 + 10/G$ *	μV $\mu\text{V}/^\circ\text{C}$ $\mu\text{V}/\text{V}$ $\mu\text{V}/\text{mo}$ $\Omega \parallel \text{pF}$ $\Omega \parallel \text{pF}$ V V
		± 11	± 13.5	± 40	*	*	*	dB dB dB dB
		80	96		75	90		dB
		96	115		90	106		dB
		110	120		106	110		dB dB
115	120		106	110				
BIAS CURRENT vs Temperature			± 0.5 ± 8	± 2		*	± 5 nA $\text{pA}/^\circ\text{C}$	
OFFSET CURRENT vs Temperature			± 0.5 ± 8	± 2		*	± 5 nA $\text{pA}/^\circ\text{C}$	
NOISE VOLTAGE, RTI $f = 10\text{Hz}$ $f = 100\text{Hz}$ $f = 1\text{kHz}$ $f_b = 0.1\text{Hz}$ to 10Hz Noise Current $f = 10\text{Hz}$ $f = 1\text{kHz}$ $f_b = 0.1\text{Hz}$ to 10Hz	$G = 1000$, $R_G = 0\Omega$		15 11 11 0.4			*	$\text{nV}/\sqrt{\text{Hz}}$ $\text{nV}/\sqrt{\text{Hz}}$ $\text{nV}/\sqrt{\text{Hz}}$ $\mu\text{V}/\text{p-p}$	
			0.4 0.2 18		*	*	*	$\text{pA}/\sqrt{\text{Hz}}$ $\text{pA}/\sqrt{\text{Hz}}$ $\text{pA}/\text{p-p}$
		1	$1 + (50\text{k}\Omega/R_G)$	10000	*	*	*	V/V V/V
		$G = 1$ $G = 10$ $G = 100$ $G = 1000$ $G = 1$	± 0.01 ± 0.02 ± 0.05 ± 0.5 ± 2	± 0.05 ± 0.4 ± 0.5 ± 1 ± 10	*	*	*	% % % % $\text{ppm}/^\circ\text{C}$
		Gain vs Temperature 50k Ω Resistance ⁽¹⁾ Nonlinearity	$G = 1$ $G = 10$ $G = 100$ $G = 1000$	± 25 ± 0.0001 ± 0.0005 ± 0.0005 ± 0.002	± 100 ± 0.001 ± 0.002 ± 0.002 ± 0.01	*	*	*
OUTPUT Voltage Load Capacitance Stability Short Circuit Current	$I_O = 5\text{mA}$, T_{MIN} to T_{MAX} $V_S = \pm 11.4\text{V}$, $R_L = 2\text{k}\Omega$ $V_S = \pm 2.25\text{V}$, $R_L = 2\text{k}\Omega$	± 13.5	± 13.7 ± 10.5		*	*	V V	
		± 1	± 1.5 1000		*	*	V pF	
			1000 ± 20 – 15		*	*	mA	
FREQUENCY RESPONSE Bandwidth, -3dB Slew Rate Settling Time, 0.01% Overload Recovery	$G = 1$ $G = 10$ $G = 100$ $G = 1000$ $V_O = \pm 10\text{V}$, $G = 10$ $G = 1$ $G = 10$ $G = 100$ $G = 1000$ 50% Overdrive		1 100 10 1			*	MHz kHz kHz kHz	
		0.3	0.6 18 20 120 1100		*	*	$\text{V}/\mu\text{s}$ μs μs μs μs	
			20		*	*	μs	
			20		*	*	μs	
			20		*	*	μs	
POWER SUPPLY Voltage Range Current	$V_{\text{IN}} = 0\text{V}$	± 2.25	± 15 ± 2.2	± 18 ± 3	*	*	V mA	
					*	*	$^\circ\text{C}$ $^\circ\text{C}$ $^\circ\text{C}/\text{W}$	

* Specification same as INA114BP/BU.

NOTE: (1) Temperature coefficient of the "50k Ω " term in the gain equation.

The information provided herein is believed to be reliable; however, BURR-BROWN assumes no responsibility for inaccuracies or omissions. BURR-BROWN assumes no responsibility for the use of this information, and all use of such information shall be entirely at the user's own risk. Prices and specifications are subject to change without notice. No patent rights or licenses to any of the circuits described herein are implied or granted to any third party. BURR-BROWN does not authorize or warrant any BURR-BROWN product for use in life support devices and/or systems.

PIN CONFIGURATIONS

ABSOLUTE MAXIMUM RATINGS⁽¹⁾

Supply Voltage	±18V
Input Voltage Range	±40V
Output Short-Circuit (to ground)	Continuous
Operating Temperature	-40°C to +125°C
Storage Temperature	-40°C to +125°C
Junction Temperature	+150°C
Lead Temperature (soldering, 10s)	+300°C

NOTE: (1) Stresses above these ratings may cause permanent damage.



ELECTROSTATIC DISCHARGE SENSITIVITY

This integrated circuit can be damaged by ESD. Burr-Brown recommends that all integrated circuits be handled with appropriate precautions. Failure to observe proper handling and installation procedures can cause damage.

ESD damage can range from subtle performance degradation to complete device failure. Precision integrated circuits may be more susceptible to damage because very small parametric changes could cause the device not to meet its published specifications.







PACKAGE/ORDERING INFORMATION

PRODUCT	PACKAGE	PACKAGE DRAWING NUMBER ⁽¹⁾	TEMPERATURE RANGE
INA114AP	8-Pin Plastic DIP	006	-40°C to +85°C
INA114BP	8-Pin Plastic DIP	006	-40°C to +85°C
INA114AU	SOL-16 Surface-Mount	211	-40°C to +85°C
INA114BU	SOL-16 Surface-Mount	211	-40°C to +85°C

NOTE: (1) For detailed drawing and dimension table, please see end of data sheet, or Appendix C of Burr-Brown IC Data Book.







TYPICAL PERFORMANCE CURVES

At $T_A = +25^\circ\text{C}$, $V_S = \pm 15\text{V}$, unless otherwise noted.









TYPICAL PERFORMANCE CURVES (CONT)

At $T_A = +25^\circ\text{C}$, $V_O = \pm 15\text{V}$, unless otherwise noted.



TYPICAL PERFORMANCE CURVES (CONT)


At $T_A = +25^\circ\text{C}$, $V_S = \pm 15\text{V}$, unless otherwise noted.




TYPICAL PERFORMANCE CURVES (CONT)

At $T_A = +25^\circ\text{C}$, $V_S = \pm 15\text{V}$, unless otherwise noted.


LARGE SIGNAL RESPONSE, $G = 1$




SMALL SIGNAL RESPONSE, $G = 1$




LARGE SIGNAL RESPONSE, $G = 1000$



SMALL SIGNAL RESPONSE, $G = 1000$



INPUT-REFERRED NOISE, 0.1 to 10Hz



APPLICATION INFORMATION

Figure 1 shows the basic connections required for operation of the INA114. Applications with noisy or high impedance power supplies may require decoupling capacitors close to the device pins as shown.

The output is referred to the output reference (Ref) terminal which is normally grounded. This must be a low-impedance connection to assure good common-mode rejection. A resistance of 5Ω in series with the Ref pin will cause a typical device to degrade to approximately 80dB CMR ($G = 1$).

SETTING THE GAIN

Gain of the INA114 is set by connecting a single external resistor, R_G :

$$G = 1 + \frac{50 \text{ k}\Omega}{R_G} \quad (1)$$

Commonly used gains and resistor values are shown in Figure 1.

The 50kΩ term in equation (1) comes from the sum of the two internal feedback resistors. These are on-chip metal film resistors which are laser trimmed to accurate absolute val-

ues. The accuracy and temperature coefficient of these resistors are included in the gain accuracy and drift specifications of the INA114.

The stability and temperature drift of the external gain setting resistor, R_G , also affects gain. R_G 's contribution to gain accuracy and drift can be directly inferred from the gain equation (1). Low resistor values required for high gain can make wiring resistance important. Sockets add to the wiring resistance which will contribute additional gain error (possibly an unstable gain error) in gains of approximately 100 or greater.

NOISE PERFORMANCE

The INA114 provides very low noise in most applications. For differential source impedances less than 1kΩ, the INA103 may provide lower noise. For source impedances greater than 50kΩ, the INA111 FET-input instrumentation amplifier may provide lower noise.

Low frequency noise of the INA114 is approximately 0.4μVp-p measured from 0.1 to 10Hz. This is approximately one-tenth the noise of "low noise" chopper-stabilized amplifiers.

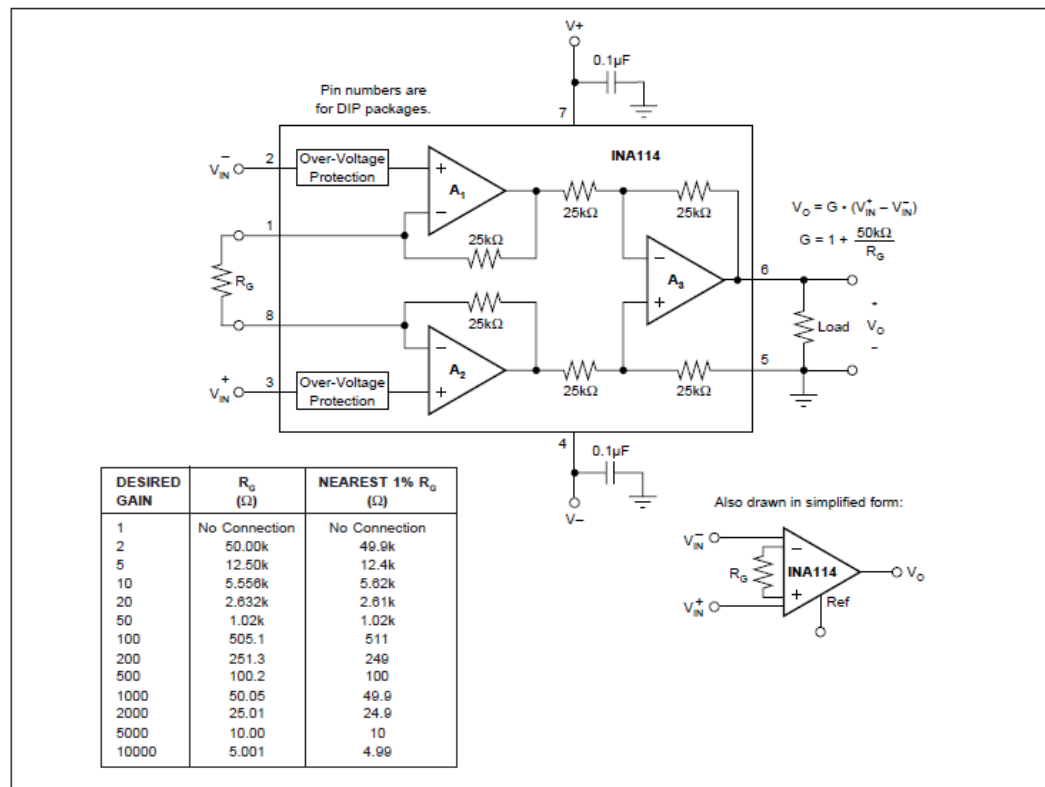


FIGURE 1. Basic Connections.

OFFSET TRIMMING

The INA114 is laser trimmed for very low offset voltage and drift. Most applications require no external offset adjustment. Figure 2 shows an optional circuit for trimming the output offset voltage. The voltage applied to Ref terminal is summed at the output. Low impedance must be maintained at this node to assure good common-mode rejection. This is achieved by buffering trim voltage with an op amp as shown.




FIGURE 2. Optional Trimming of Output Offset Voltage.

INPUT BIAS CURRENT RETURN PATH

The input impedance of the INA114 is extremely high—approximately $10^{10}\Omega$. However, a path must be provided for the input bias current of both inputs. This input bias current is typically less than $\pm 1\text{nA}$ (it can be either polarity due to cancellation circuitry). High input impedance means that this input bias current changes very little with varying input voltage.

Input circuitry must provide a path for this input bias current if the INA114 is to operate properly. Figure 3 shows various provisions for an input bias current path. Without a bias current return path, the inputs will float to a potential which exceeds the common-mode range of the INA114 and the input amplifiers will saturate. If the differential source resistance is low, bias current return path can be connected to one input (see thermocouple example in Figure 3). With higher source impedance, using two resistors provides a balanced input with possible advantages of lower input offset voltage due to bias current and better common-mode rejection.

INPUT COMMON-MODE RANGE

The linear common-mode range of the input op amps of the INA114 is approximately $\pm 13.75\text{V}$ (or 1.25V from the power supplies). As the output voltage increases, however, the linear input range will be limited by the output voltage swing of the input amplifiers, A_1 and A_2 . The common-mode range is related to the output voltage of the complete amplifier—see performance curve “Input Common-Mode Range vs Output Voltage.”

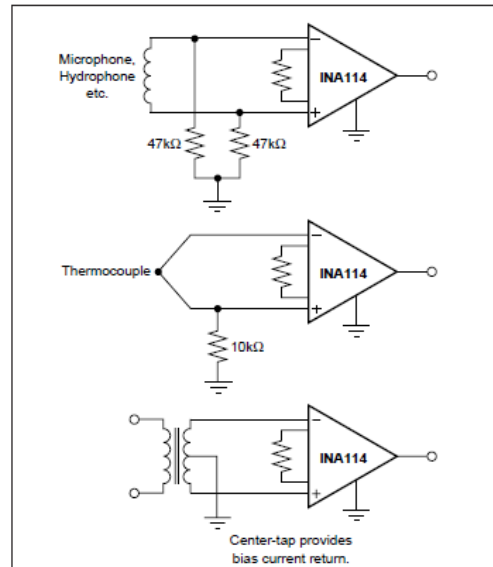


FIGURE 3. Providing an Input Common-Mode Current Path.

A combination of common-mode and differential input signals can cause the output of A_1 or A_2 to saturate. Figure 4 shows the output voltage swing of A_1 and A_2 expressed in terms of a common-mode and differential input voltages. Output swing capability of these internal amplifiers is the same as the output amplifier, A_3 . For applications where input common-mode range must be maximized, limit the output voltage swing by connecting the INA114 in a lower gain (see performance curve “Input Common-Mode Voltage Range vs Output Voltage”). If necessary, add gain after the INA114 to increase the voltage swing.

Input-overload often produces an output voltage that appears normal. For example, an input voltage of $+20\text{V}$ on one input and $+40\text{V}$ on the other input will obviously exceed the linear common-mode range of both input amplifiers. Since both input amplifiers are saturated to nearly the same output voltage limit, the difference voltage measured by the output amplifier will be near zero. The output of the INA114 will be near 0V even though both inputs are overloaded.

INPUT PROTECTION

The inputs of the INA114 are individually protected for voltages up to $\pm 40\text{V}$. For example, a condition of -40V on one input and $+40\text{V}$ on the other input will not cause damage. Internal circuitry on each input provides low series impedance under normal signal conditions. To provide equivalent protection, series input resistors would contribute excessive noise. If the input is overloaded, the protection circuitry limits the input current to a safe value (approximately 1.5mA). The typical performance curve “Input Bias Current vs Common-Mode Input Voltage” shows this input

current limit behavior. The inputs are protected even if no power supply voltage is present.

OUTPUT VOLTAGE SENSE (SOL-16 package only)

The surface-mount version of the INA114 has a separate output sense feedback connection (pin 12). Pin 12 must be connected to the output terminal (pin 11) for proper operation. (This connection is made internally on the DIP version of the INA114.)

The output sense connection can be used to sense the output voltage directly at the load for best accuracy. Figure 5 shows how to drive a load through series interconnection resistance. Remotely located feedback paths may cause instability. This can be generally be eliminated with a high frequency feedback path through C_1 . Heavy loads or long lines can be driven by connecting a buffer inside the feedback path (Figure 6).

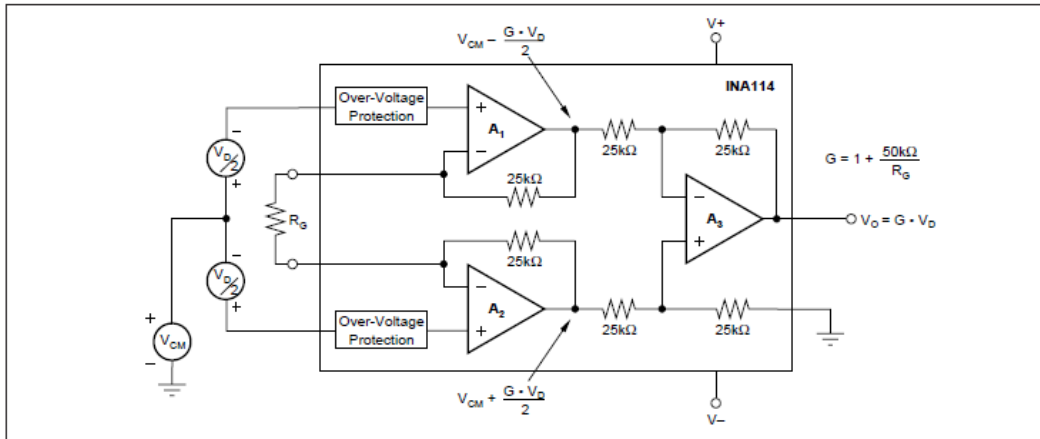


FIGURE 4. Voltage Swing of A_1 and A_2 .

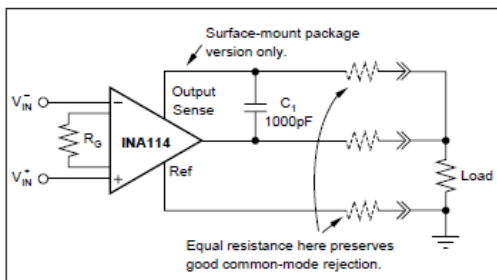


FIGURE 5. Remote Load and Ground Sensing.

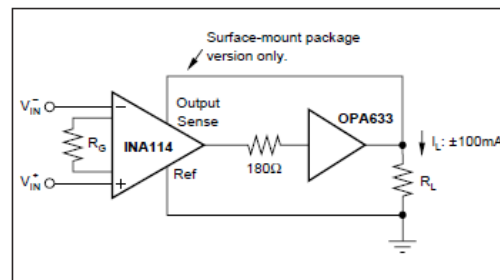


FIGURE 6. Buffered Output for Heavy Loads.

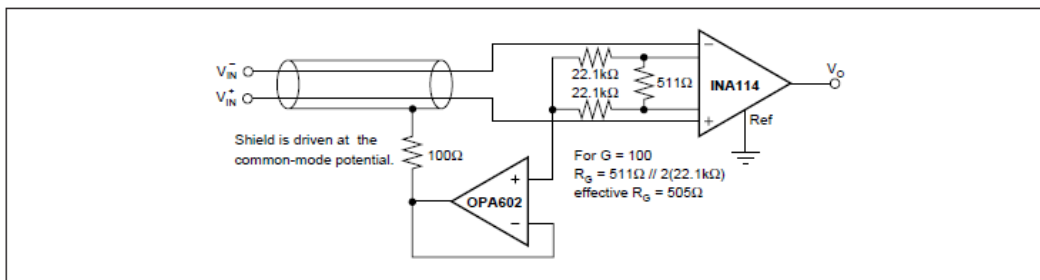


FIGURE 7. Shield Driver Circuit.

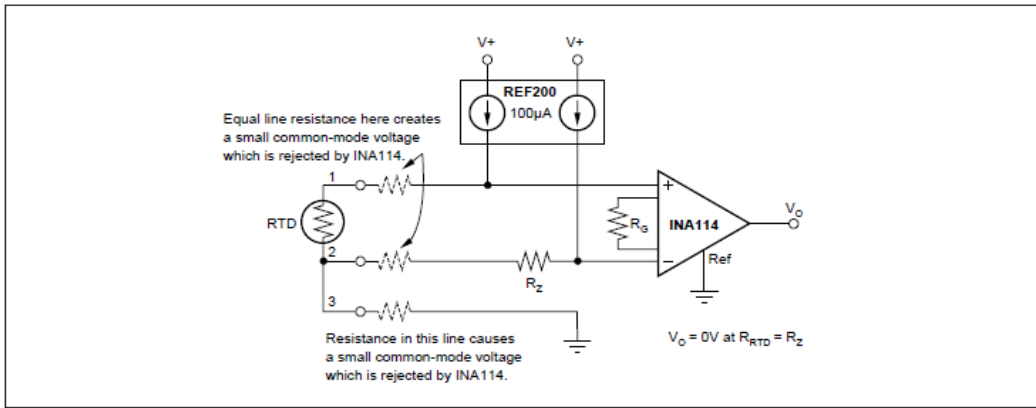


FIGURE 8. RTD Temperature Measurement Circuit.

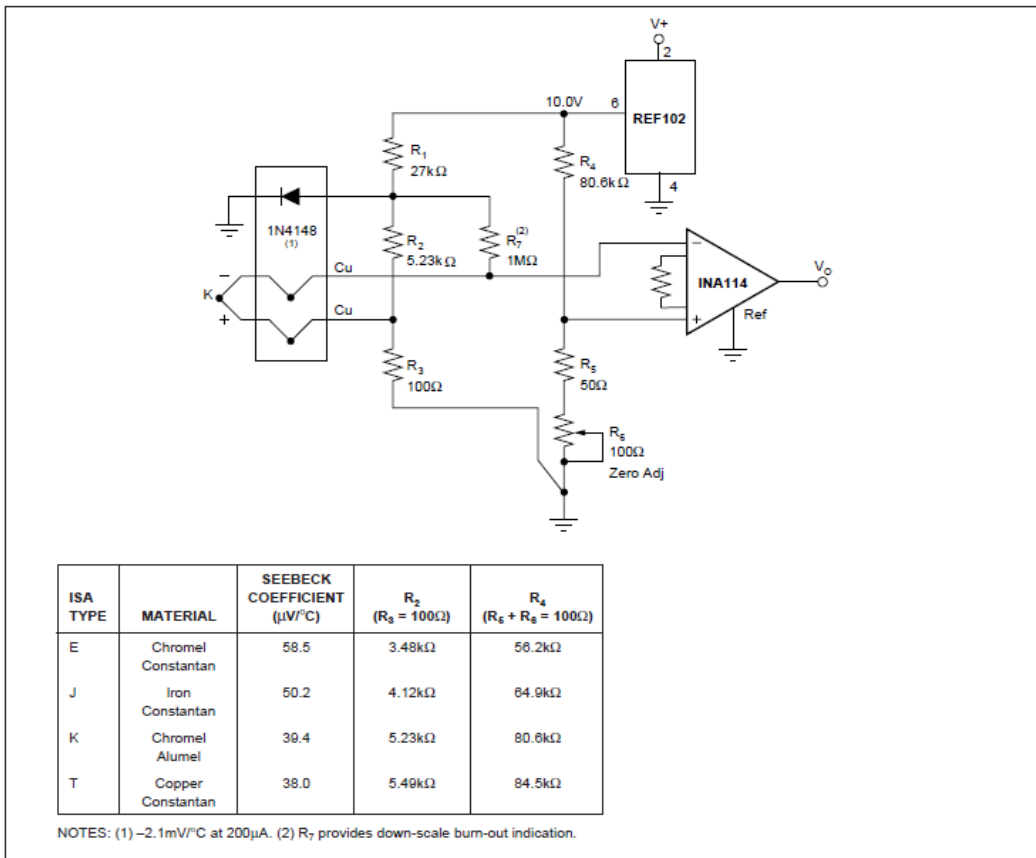


FIGURE 9. Thermocouple Amplifier With Cold Junction Compensation.

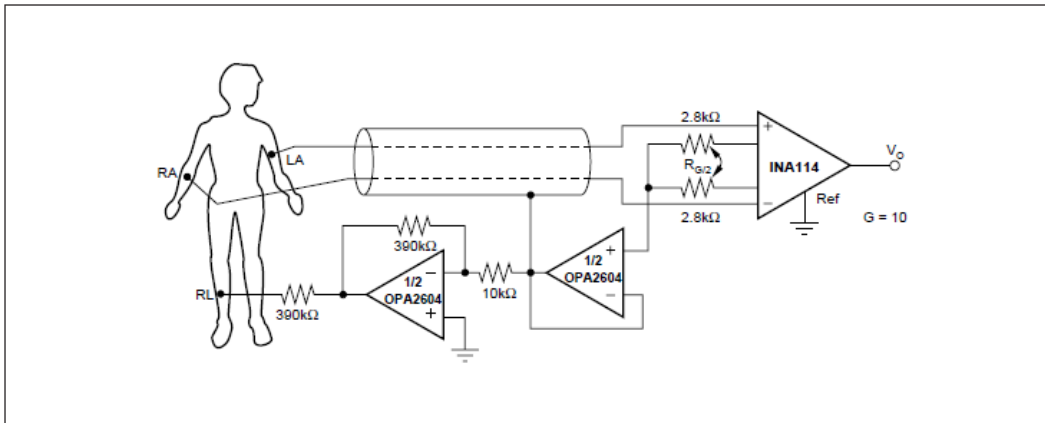


FIGURE 10. ECG Amplifier With Right-Leg Drive.




FIGURE 11. Bridge Transducer Amplifier.




FIGURE 12. AC-Coupled Instrumentation Amplifier.

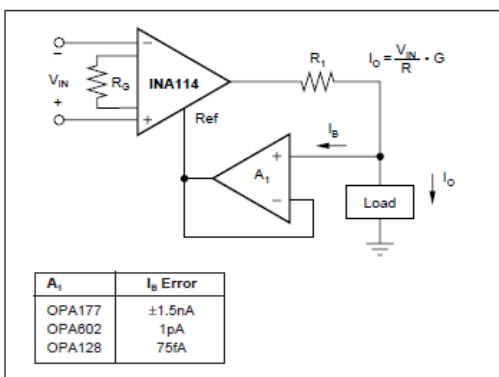


FIGURE 13. Differential Voltage-to-Current Converter.

IMPORTANT NOTICE

Texas Instruments and its subsidiaries (TI) reserve the right to make changes to their products or to discontinue any product or service without notice, and advise customers to obtain the latest version of relevant information to verify, before placing orders, that information being relied on is current and complete. All products are sold subject to the terms and conditions of sale supplied at the time of order acknowledgment, including those pertaining to warranty, patent infringement, and limitation of liability.

TI warrants performance of its semiconductor products to the specifications applicable at the time of sale in accordance with TI's standard warranty. Testing and other quality control techniques are utilized to the extent TI deems necessary to support this warranty. Specific testing of all parameters of each device is not necessarily performed, except those mandated by government requirements.

Customers are responsible for their applications using TI components.

In order to minimize risks associated with the customer's applications, adequate design and operating safeguards must be provided by the customer to minimize inherent or procedural hazards.

TI assumes no liability for applications assistance or customer product design. TI does not warrant or represent that any license, either express or implied, is granted under any patent right, copyright, mask work right, or other intellectual property right of TI covering or relating to any combination, machine, or process in which such semiconductor products or services might be or are used. TI's publication of information regarding any third party's products or services does not constitute TI's approval, warranty or endorsement thereof.