

UNIVERSIDADE FEDERAL DE VIÇOSA
CENTRO DE CIÊNCIAS EXATAS E TECNOLÓGICAS
DEPARTAMENTO DE ENGENHARIA ELÉTRICA

AUGUSTO CÉSAR FONSECA FERREIRA

INVESTIGAÇÃO DA ATENÇÃO SELETIVA
AUDITIVA PARA INTERFACE
CÉREBRO-COMPUTADOR USANDO MÁQUINAS DE
VETOR DE SUPORTE

VIÇOSA
2011

AUGUSTO CÉSAR FONSECA FERREIRA

**INVESTIGAÇÃO DA ATENÇÃO SELETIVA
AUDITIVA PARA INTERFACE
CÉREBRO-COMPUTADOR USANDO MÁQUINAS DE
VETOR DE SUPORTE**

Monografia apresentada ao Departamento de Engenharia Elétrica do Centro de Ciências Exatas e Tecnológicas da Universidade Federal de Viçosa, para a obtenção dos créditos da disciplina ELT 490 - Monografia e Seminário e cumprimento do requisito parcial para obtenção do grau de Bacharel em Engenharia Elétrica.

Orientador: Prof. Dr. Leonardo Bonato Felix.

VIÇOSA
2011

AUGUSTO CÉSAR FONSECA FERREIRA

**INVESTIGAÇÃO DA ATENÇÃO SELETIVA AUDITIVA PARA
INTERFACE CÉREBRO-COMPUTADOR USANDO MÁQUINAS
DE VETOR DE SUPORTE**

Monografia apresentada ao Departamento de Engenharia Elétrica do Centro de Ciências Exatas e Tecnológicas da Universidade Federal de Viçosa, para a obtenção dos créditos da disciplina ELT 490 - Monografia e Seminário e cumprimento do requisito parcial para obtenção do grau de Bacharel em Engenharia Elétrica.

Aprovada em 29 de junho de 2011.

COMISSÃO EXAMINADORA

Prof. Dr. Leonardo Bonato Felix - Orientador
Universidade Federal de Viçosa

Prof. Dr. Tarcísio de Assunção Pizziolo - Membro
Universidade Federal de Viçosa

Bel. Marcos Antônio Abdalla Junior - Membro
Universidade Federal de São João del Rei

*Aos meus pais Roque e
Mirtes pelo apoio incondicional
durante a minha graduação.*

Agradecimentos

Agradeço primeiramente a Deus pela oportunidade de ter tantas pessoas maravilhosas ao meu redor. Estas me propiciaram uma experiência única em minha vida que foi estudar na Universidade Federal de Viçosa.

Agradeço aos meus pais, Roque e Mirtes, que sempre me incentivaram a trilhar os caminhos do conhecimento e que deram todo suporte para que eu pudesse me tornar não apenas um engenheiro, mas também um cidadão. Ao meu irmão Rafael que sempre me fez lembrar o valor da família.

Como não poderia faltar, agradeço imensamente a minha namorada Raphaela que teve muita paciência nos momentos em que estive ausente e que sempre me deu apoio na realização desta monografia. Fi-la ler todo o texto em busca de erros. Obrigado por estar sempre perto e por fazer meus últimos períodos bastantes especiais.

Aos amigos do laboratório NIAS, grupo de pesquisa no qual participei com muito orgulho, onde pude aprender muito e compartilhar resenhas e conhecimentos.

Aos companheiros da república Gaborandi (tanto os que já passaram quanto os atuais integrantes) que fizeram da minha estadia em Viçosa algo memorável e que fará bastante falta.

Aos colegas, amigos e *irmãos* do curso de Engenharia Elétrica da UFV pelas discussões e sugestões no desenvolvimento da pesquisa, pelas proveitosas horas de estudo e pelas horas de lazer, sem as quais não conseguiria me manter firme nos meus objetivos.

Agradeço especialmente todas as pessoas que cederam minutos ou horas de suas vidas como voluntários para o desenvolvimento desse projeto. Sem eles nada disso seria possível.

Deixo um especial agradecimento ao meu orientador, Leonardo Bonato Felix, por ter me confiado essa tarefa, pela amizade e orientação. Pessoa pela qual adquiri muita admiração e respeito.

A FAPEMIG, a CAPES e ao CNPq pelo apoio financeiro concedido, sem o qual esta pesquisa não teria sido possível.

*”Quando as portas da
percepção forem abertas,
o homem verá as coisas como
elas realmente são: infinitas”*
William Blake (1757-1827)
Poeta e pintor inglês

Resumo

Neste trabalho é apresentado uma forma de se classificar estímulos auditivos captados por eletroencefalograma (EEG) utilizando-se máquinas de vetor de suporte (SVM). O objetivo do projeto foi desenvolver um sistema de interface cérebro-computador (ICC) explorando os efeitos de atenção nas respostas auditivas em regime permanente (ASSRs), onde o usuário faça escolhas binárias. Este sistema foi baseado em EEG, uma vez que os sinais foram coletados simultaneamente com dois diferentes tons de amplitude modulada (AM). O processo de classificação foi realizado após a redução dimensional dos dados com análise de componentes principais (PCA) e extração de características usando-se os parâmetros auto regressivos (AR). É abordado também uma nova forma de se avaliar as ASSRs tentando-se classificar se o indivíduo encontra-se focando a atenção ou não no estímulo reproduzido e em qual dos ouvidos ele focou a atenção. O melhor resultado binário para o caso geral foi uma máquina de vetor de suporte que, utilizando a função kernel polinomial e um modelo de ordem 6, obteve um acerto em 76,88% dos dados. Já a melhor resposta para o sistema multi-classe no qual foram disponibilizados 70% dos dados para teste foi uma SVM com 100% de acerto para um modelo de ordem 6 e 9 para o caso em que utilizou-se 21 amostras de um mesmo indivíduo.

Abstract

This paper presents aims to classify auditory stimulus recorded from electroencephalogram (EEG) using support vector machines (SVM). The main purpose was to develop a brain-computer interface (BCI) system exploring the attention effect in auditory steady-state response (ASSRs), in which the user must perform binary selections. This system was EEG-based, since these signals were recorded simultaneously with two different AM tones. The classification process was conducted after a dimensionality reduction using the principal component analysis (PCA) and feature extraction by autoregressive (AR) parameters. Its also discussed a new way to evaluate ASSRs where a volunteer is focusing ones's attention in one about two presented stimuli or none of them. Our best binary result for general case was a SVM that used polynomial kernel function and 6th order AR model and hence it obtained a hit score 76,88% of the data. Besides, the best response for multi-class system was a SVM that hit 100% of the data, in which 70% of data were avaiable for test. In this case we utilize 21 samples of the same person.

Sumário

Lista de Figuras

Lista de Tabelas

1	Introdução	11
1.1	A atividade elétrica cerebral em humanos	11
1.2	Respostas evocadas	13
1.2.1	Resposta auditiva em regime permanente	14
1.3	Interface cérebro-computador (ICC)	15
1.4	Fisiologia da audição	16
2	Objetivos	20
3	Materiais e Métodos	21
3.1	Estimulação e Coleta de Dados	22
3.2	Aquisição de Sinais	25
3.2.1	Sistema Internacional 10-20	25
3.2.2	Coleta de sinais de EEG	25
3.3	Processamento de sinais	26
3.3.1	Pré-processamento dos sinais	26
3.3.2	Análise de Componentes Principais (PCA)	26
3.3.3	Coeficiente do Modelo AR	28
3.3.4	Máquinas de Vetor de Suporte	29

4	Resultados e Discussões	31
4.1	Sinais Coletados	31
4.2	Classificador SVM	33
4.2.1	Caso Geral	33
4.2.2	Casos para 1 indivíduo	34
4.2.3	Caso Especial	38
5	Conclusões	40
	Referências	42
	Anexo A – Algoritmos do SVM	45

Lista de Figuras

1	Divisão anatômica do sistema auditivo	17
2	Representação esquemática da Membrana Basilar desenrolada	18
3	Córtex Cerebral	18
4	Etapas seguidas para o reconhecimento de padrões em sinais auditivos . . .	22
5	GUI construída para gerar os estímulos e o sinal do <i>trigger</i>	23
6	<i>E-A-RTONE®5A Insert Earphone</i>	24
7	Circuito divisor de tensão	24
8	Sistema internacional 10-20	25
9	<i>BrainNet BNT 36</i>	26
10	Sinal antes de ser filtrado	32
11	Sinal depois do filtro	32

Lista de Tabelas

1	Resultados obtidos na classificação do SVM a partir dos coeficientes do modelo AR de ordem 4	33
2	Melhores resultados obtidos após o treinamento de 70% do conjunto total de dados com o SVM, variando-se a ordem do modelo AR	34
3	Exemplo de um Classificador <i>todos-contra-todos</i> com votação por maioria .	35
4	Resultados obtidos após o treinamento de 21 exames de um mesmo voluntário variando- se o número de elementos no grupo de treino e validação .	36
5	Melhores resultados obtidos após o treinamento de 30% dos 21 exames disponíveis com o SVM, variando-se a ordem do modelo AR.	36
6	Resultados obtidos após o treinamento de 54 exames de um mesmo voluntário variando- se o número de elementos no grupo de treino e validação . .	37
7	Melhores resultados obtidos após o treinamento de 30% dos 54 exames disponíveis com o SVM, variando-se a ordem do modelo AR	38
8	Resultados obtidos após o treinamento de 12 exames para uma mesma combinação de frequências variando- se o número de elementos no grupo de treino e validação	38

1 *Introdução*

Neste capítulo será proposta uma visão geral do tema principal deste trabalho, abordando alguns fatos históricos que são o pilar para a maioria dos assuntos tratados nessa monografia. Além disso, serão apresentados alguns conceitos que servem de base para o entendimento posterior do texto e, finalmente, os objetivos gerais que se esperam alcançar ao final do projeto.

1.1 A atividade elétrica cerebral em humanos

Desde a descoberta, por *Luigi Galvani*, em 1784, que o tecido nervoso é eletricamente excitável, a neurofisiologia lentamente começou a desvendar as propriedades da bioeletrogênese, ou seja, a geração de impulsos elétricos em nervos e músculos. Este trabalho foi realizado ao longo do século XIX, por cientistas como *Emil du Bois-Reymond*, que, ajudados por sucessivos desenvolvimentos técnicos que permitiam a medida de correntes elétricas cada vez menores, passaram a estudar com crescente detalhe as propriedades da atividade elétrica do sistema nervoso [1].

Naturalmente, questões relacionadas às funções centrais passaram a ser feitas como, por exemplo, se o cérebro possuía atividade elétrica assim como os nervos e músculos, se ela tinha correlação com as funções sensoriais, motoras e cognitivas e, ainda, se existiam localizações específicas no sistema nervoso central para tais ativações elétricas. O registro eletrográfico cerebral exigia a detecção de correntes e potenciais elétricos de cerca de duas ordens de magnitude mais débeis do que aqueles registrados em nervos e músculos. Por conta disso, ele teve que aguardar a evolução da eletrotécnica. Isso ocorreu tempos depois com o desenvolvimento de galvanômetros e eletrômetros de maior sensibilidade, como, por exemplo, o galvanômetro de *d'Arsonval* e o galvanômetro refletor, inventado por *Lord Kelvin* em 1858 [1].

De posse do galvanômetro refletor, um médico de Liverpool, Inglaterra, chamado

Richard Caton (1842-1926) foi o primeiro a descobrir alterações de corrente elétrica na superfície exposta em animais experimentais em 1875. Até meados de 1890, *Caton* realizou vários experimentos e deparou-se com alguns fatos consideráveis sobre essa atividade:

- A atividade elétrica estava presente na matéria cinzenta (neurônios) e desaparecia com a morte, ou seja, era um processo metabolicamente ativo;
- A matéria cinzenta superficial era positiva em relação à profunda, e exibiam variações elétricas em direção à negatividade, com alguma atividade;
- A atividade elétrica em determinados pontos aumentava quando os animais se moviam;
- Estímulos visuais provocavam um aumento na variação elétrica do córtex, contralateralmente ao olho estimulado;
- A atividade elétrica aumentava em amplitude quando os animais adormeciam em virtude de uma anestesia, diminuindo novamente ao recobrar a consciência.

Apesar de suas descobertas, foi apenas na década de 1920, que a neurociência conseguiu definir que o cérebro humano também apresentava atividade elétrica na forma de ondas oscilantes constantes.

Em 1929, um neurologista e psiquiatra alemão chamado *Hans Berger* (1873-1921), que lecionava na Universidade de *Jena*, na Alemanha, anunciou ao mundo científico e médico que:

- Era possível registrar fracas correntes elétricas geradas no cérebro humano, sem a necessidade de abrir o crânio, e mostrá-las na forma de um registro em papel. *Berger* denominou a esta nova forma de registro fisiológico de eletroencefalograma (ou EEG);
- Além disso, determinou que existiam dois ritmos dominantes, os quais eles nomeou ritmos alfa (de 8 a 10Hz) e beta (12 a 20Hz);
- Esta atividade mudava de características de acordo com o estado funcional do cérebro, como por exemplo, a apresentação a estímulos sensoriais, durante o sono, na anestesia, na hipóxia (falta de oxigênio) e em certas doenças nervosas, como a epilepsia.

Foi a partir desse trabalho que nascia o EEG, e com ele começou a identificação de padrões neurais (ondas ou ritmos, cerebrais). Entretanto, foi apenas na década de 1950, com o avanço dos dispositivos eletrônicos que se tornou possível medir quantitativamente e de forma não invasiva, os sinais elétricos cerebrais com amplitudes da ordem de microvolts. Com esse avanço tecnológico o passo seguinte foi o de integrar diversas áreas do conhecimento desde a neurofisiologia até a engenharia biomédica passando por física, eletrônica e computação [2]. Esta integração possibilitou o estudo detalhado dos sinais elétricos cerebrais dentro de um panorama quantitativo de causa-efeito.

O padrão da atividade elétrica cerebral é determinado pelo nível da atividade encefálica no momento em que o sinal é adquirido. A intensidade dos sinais cerebrais é resultante, principalmente, do número de neurônios que disparam em sincronismo e, não do nível total da atividade elétrica do encéfalo, ou seja, os sinais elétricos disparados na forma assíncrona contribuem com uma intensidade muito baixa no EEG [2].

As várias regiões do cérebro não emitem estes ritmos com a mesma frequência simultaneamente. Um eletrodo de EEG colocado no escalpo vai captar vários sinais, cada um com diferentes características no que se refere à frequência e amplitude. Isto representou desde sempre um problema para os investigadores que tentavam interpretar a grande quantidade de informação proveniente de apenas um registro de EEG [3].

1.2 Respostas evocadas

As atividades elétricas encontradas no cérebro são uma consequência do fluxo de correntes iônicas desencadeadas por potenciais de ação, em função de estímulos sensoriais, execução de tarefas, pensamentos etc. Ao registro eletrográfico de atividades cerebrais no escalpo dá-se o nome de eletroencefalograma (EEG). São de especial interesse os sinais de EEG coletados concomitantemente à apresentação de estímulos sensoriais, pois tais sinais carregam informações acerca da via neural e dos núcleos cerebrais ativados no processamento da informação sensorial - este potencial elétrico relacionado a eventos é conhecido como resposta evocada (RE). De acordo com [4], as REs podem ser subdivididas em transitórias e de regime permanente. Na RE transitória, os estímulos são apresentados a uma taxa de repetição suficientemente lenta ($< 2Hz$) para que cada resposta termine antes da chegada do próximo estímulo, ou seja, a RE transitória tem um início e fim bem demarcados. No caso de o estímulo ser apresentado a uma taxa suficientemente elevada ($> 5Hz$), onde cada resposta se sobrepõe temporalmente à subsequente, considera-se que

a rede neuronal alcançou um equilíbrio de excitabilidade e que, então, uma RE em regime permanente é alcançada.

As REs são usadas de várias formas em clínicas médicas, como por exemplo: audiometria usando respostas auditivas em regime permanente (ASSRs) [5], avaliação de lesões na via auditiva primária através das respostas evocadas de tronco encefálico - também conhecido como BERA [4], monitoração de cirurgia através de REs somatosensitivos [6] e ativação do EEG em pacientes epiléticos [7].

1.2.1 Resposta auditiva em regime permanente

Um potencial evocado por estímulos auditivos reflete a resposta das várias estruturas neuronais envolvidas na transmissão e processamento da informação sonora, em especial o VIII nervo craniano, o tronco cerebral e o córtex auditivo [8]. Da mesma maneira, uma resposta auditiva em regime permanente (ASSR, do inglês *auditory steady-state response*) ocorre quando um som é apresentado a uma taxa suficientemente elevada, de modo que a resposta a qualquer som sobreponha-se à resposta ao som anterior. A modulação senoidal da amplitude de um tom contínuo (tom AM) é um exemplo de estímulo acústico que evoca uma resposta auditiva em regime permanente [9]. De acordo com [10], a ASSR evocada por um tom AM é caracterizada por um aumento de energia na frequência da moduladora (e seus harmônicos) no espectro de potência do sinal registrado. [11] atestam que, em comparação com os estímulos auditivos transitórios, o tom AM tem a vantagem de ser mais próximo dos sons que acontecem na natureza, tornando as ASSRs evocadas mais próximas das situações cotidianas e contribuindo para uma abrangência maior de um eventual teste.

Em humanos, as ASSRs evocadas por tons AM mais estudadas são as com frequência de modulação entre 70 e 110Hz, bem como a 40Hz [10]. Essas respostas a modulações de 40Hz são amplamente estudadas, apresentando as seguintes características:

- Sua amplitude decai consideravelmente durante o sono [12];
- É difícil de se registrar em crianças [13];
- É significativamente atenuada por anestesia [14].

Embora a amplitude da resposta entre 70 – 110Hz tenha uma intensidade 2 a 3 vezes menor que a resposta de 40Hz durante vigília, tais respostas apresentam as seguintes vantagens:

- Muito menos afetadas pelo sono e pelo despertar [15].
- Prontamente registradas em crianças [16].

Os estudos disponíveis sobre o efeito da atenção nas ASSRs são inconclusivos. [17] observou diferenças na RE transitória durante a atenção, porém nenhum efeito foi encontrado na amplitude e fase das ASSRs. Todavia, um aumento na amplitude da ASSR foi reportado em [18]. O experimento em [17] foi parcialmente reproduzido por [19] usando magnetoencefalografia e um aumento na amplitude da ASSR evocada pelo estímulo focado foi observado entre 200 e 500ms após o início do estímulo. Todos estes experimentos foram conduzidos por estímulos com moduladoras na faixa de 40Hz.

1.3 Interface cérebro-computador (ICC)

Interface cérebro-computador é um sistema que fornece uma via de controle entre o cérebro e o ambiente externo, de maneira que os músculos não estejam envolvidos. Os estudos sobre ICCs se iniciaram na década de 1960. Contudo, pode-se afirmar que somente a partir dos anos 1990 este assunto tenha se tornado uma área de ponta na neurociência.

Em termos gerais, uma ICC é um sistema por meio do qual uma pessoa, ou um animal, envia informações do cérebro para um computador (sistema microprocessado), onde esta informação é processada e, posteriormente, disponibilizada para controle de um dispositivo externo. Estas informações, representadas pela atividade cerebral, podem ser obtidas por meio de técnicas como a eletroencefalografia (EEG), magnetoencefalografia (MEG), tomografia por emissão de positrons (PET), ressonância magnética funcional (fMRI) e eletrocorticografia (ECoG). Devido ao menor custo e a praticidade, as técnicas de eletroencefalografia e eletrocorticografia têm sido mais utilizadas [20]. Porém, a eletrocorticografia, por ser uma técnica invasiva, apresenta os riscos inerentes aos procedimentos cirúrgicos [21].

O objetivo de uma ICC é obter o potencial relacionado a um evento (PRE) como, por exemplo: estimulação visual, movimento e imaginação de movimento, e torná-lo capaz de acionar um dispositivo externo como uma prótese ou órtese. O principal desafio a ser enfrentado, na implementação de uma ICC, é a identificação do PRE em meio à atividade elétrica *espontânea* do cérebro (EEG espontâneo). Enquanto a amplitude dos PRE's é de alguns microvolts, a atividade *espontânea* pode atingir centenas de microvolts. Várias técnicas têm sido propostas para detectar PRE's no EEG, tanto no domínio do

tempo quando da frequência. Dentre as técnicas e ferramentas matemáticas utilizadas nas ICC's, destacam-se: a Transformada Rápida de Fourier [22]; Transformada *Wavelet* [23]; modelagem paramétrica [24]; redes neurais [25]; componentes principais e componentes independentes [26] [27]; máquinas de vetor de suporte [28] além de outros tipos de filtros como, por exemplo, filtros espaciais [22].

Recentemente, as máquinas de vetor de suporte (do inglês Support Vector Machine, SVM), que tem uma abordagem baseada em *kernel* com uma sólida base teórica, tornou-se uma ferramenta popular para máquinas de aprendizagem que envolvam classificação e regressão. Tem obtido sucesso em várias aplicações, abrangendo identificação de faces, classificação de textos, bioinformática e mineração de dados [28]. Neste trabalho, buscase combinar componentes principais, modelos auto-regressivos e máquinas de vetor de suporte para, dessa forma, construir um classificador que tenha um desempenho melhor que outros classificadores como redes neurais.

1.4 Fisiologia da audição

Os sons captados na orelha externa ascendem até a cóclea por diversas estruturas, que funcionam como um casador de impedâncias acoplando as mudanças de pressão atmosférica à movimentos de fluido no interior da cóclea, com uma perda mínima de energia [8]. Os neurônios sensoriais da cóclea apresentam atividade quando ondas sonoras de frequência específica atingem esta estrutura, numa forma de decomposição espectral do estímulo sonoro. A informação elétrica ascende até o córtex pelas vias auditivas, gerando, neste caminho, os sinais elétricos correspondentes ao potencial evocado auditivo [29].

A audição é um processo complexo que envolve a captação, percepção e interpretação dos sons presentes no meio ambiente. A estrutura anatômica do sistema auditivo humano é dividida em três partes: orelha externa, orelha média e orelha interna (figura 1), sendo esta última continuada pela estrutura nervosa responsável por levar os sinais elétricos até o córtex auditivo, onde seu significado é decifrado [30].

As ondas sonoras viajam através do canal auditivo externo até a membrana timpânica, causando neste trajeto mudanças na pressão do ar e deslocamentos no tímpano. Estes movimentos são transmitidos através dos ossículos (martelo, bigorna e estribo) para a membrana da janela oval da cóclea [30]. A membrana timpânica e a cadeia ossicular não são apenas transmissores passivos dos movimentos. Em conjunto, funcionam como um acoplador acústico, que permite uma transmissão eficiente de movimento a partir do




Figura 1: Divisão anatômica do sistema auditivo (Adaptado de [31]).

ouvido médio para o líquido coclear [32].

A cóclea é uma estrutura que ocupa um lugar decisivo na via auditiva, pois é nela que a energia das ondas sonoras é transformada em sinais neurais. Anatomicamente, ela é um órgão com cerca de 9mm de diâmetro que possui uma estrutura cônica espiralada formada por três ductos que se afluam da base para o ápice. Esses ductos são: escala vestibular, escala média ou duto coclear e escala timpânica. As escalas vestibular e timpânica são preenchidos por um fluido, chamado de perilinfa. Já o duto coclear é preenchido pela endolinfa [30].

O som causa vibrações que empurram a platina do estribo sobre a janela oval, fazendo com que a perilinfa se desloque dentro da escala vestibular. Como a membrana de Reissner, que separa as escalas vestibular e média, é muito flexível, essas vibrações são também transmitidas para a endolinfa, no duto coclear [30]. O movimento da endolinfa faz com que a membrana basilar inicie um movimento na sua base em direção ao ápice. A distância que a onda percorre na membrana basilar depende da frequência do som incidente; altas frequências (sons agudos) produzem o deslocamento máximo na base da cóclea, enquanto que as baixas frequências (sons graves) produzem o deslocamento máximo em direção ao ápice [32] figura 2.

O arranjo entre a membrana basilar e o Córtex Auditivo Primário (A1) é tonotópico




Figura 2: Representação esquemática da Membrana Basilar desenrolada. (a) Estimulação por sons agudos, causando a vibração de porções iniciais da cóclea. (b) Estimulação por sons graves, causando vibração de porções finais da cóclea [31].

como pode ser visto na figura 3, isto é, tem-se um arranjo de 1:1 entre entrada sensorial e representação cortical: cada região da membrana basilar estimulada acaba por excitar uma determinada população de neurônios em A1 [30].

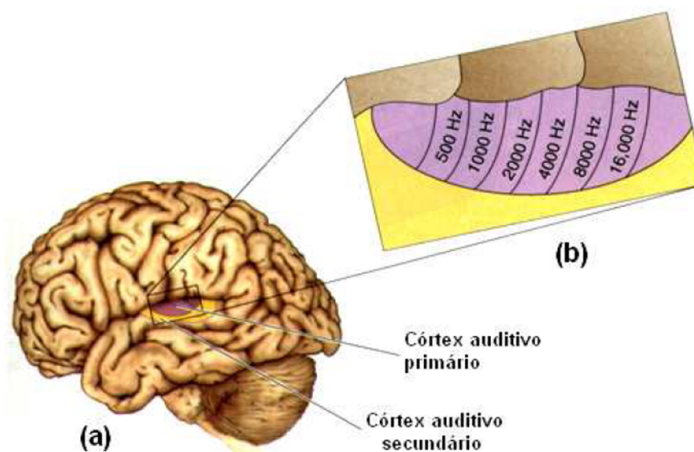


Figura 3: (a) Córtex auditivo primário e as áreas auditivas secundárias no lobo temporal superior; (b) Organização tonotópica do córtex auditivo primário. Cada área é demarcada por faixas que indicam suas frequências características [31].

Apoiado na membrana basilar está o órgão de Corti, que contém receptores auditivos: as células ciliadas internas e externas. O deslocamento dessas células marca o evento crítico na transdução do som em um sinal neural, onde é observada a despolarização

dessas células causada pelos movimentos decorridos de estímulos sonoros [30].

As células ciliadas fazem sinapses estimulando a rede de fibras nervosas da cóclea e conduzem o sinal ao gânglio espiral, que envia axônios, em torno de 30.000, para o nervo coclear. Quanto mais intensa a estimulação, maior é o número de células ciliadas que são excitadas e mais fibras nervosas da cóclea disparam [30]. Informações sobre a frequência e amplitude do estímulo são transmitidas para o sistema nervoso central (SNC) e codificadas através de padrões de descarga do nervo auditivo [32].

2 *Objetivos*

O objetivo geral do trabalho é desenvolver um sistema de ICC explorando os efeitos de atenção nas ASSRs no qual o usuário faça escolhas binárias. Este sistema fará a classificação de sinais EEG registrados em resposta a dois estímulos auditivos simultâneos. Para comunicar a decisão, o indivíduo deverá focar atenção em um dos dois estímulos auditivos apresentados.

Dado o objetivo geral, têm-se como objetivos específicos:

- Verificar a aplicabilidade das ASSRs como paradigma para ICC, através da variação de seus parâmetros de estimulação;
- Estudar o efeito da atenção nas ASSRs;
- Estudar o uso de SVM para classificar a atenção seletiva auditiva.

3 Materiais e Métodos

Inicialmente é importante destacar que independentemente do procedimento utilizado para a criação de uma ICC, este sempre objetivará o reconhecimento de padrões para a tomada de decisão. No caso deste trabalho, a identificação do sinal de EEG é feita para seleção binária.

A figura 4 exhibe os passos seguidos para o desenvolvimento deste projeto. Ela facilita o entendimento das etapas seguidas resumindo-as em um fluxograma. A primeira parte (EEG) consiste em registrar os sinais biológicos dos indivíduos através do eletroencefalógrafo. Após a coleta dos dados, é feito um pré-processamento dos mesmos onde o sinal é filtrado na frequência da rede de $60Hz$ onde os testes foram realizados. Além disso, é feita uma varredura nos canais dos eletrodos para a remoção de artefatos, tais como movimentos musculares e piscadas dos olhos.

Acabado o pré-processamento, inicia-se o processo para a diminuição do volume de dados utilizando para isso a ferramenta de análise de componentes principais. Com a quantidade de informações iniciais reduzidas é então criado um modelo AR (ordem 3 a 10, nesta monografia) do qual são retirados os parâmetros que serão os vetores de entrada para o classificador que dá nome a este trabalho.

Dessa forma, ficam assim distribuídas as seções. Na seção 2.1 aborda-se a estimulação sonora gerada para a realização dos exames e o banco de dados criado a partir destes. Em seguida, a seção 2.2 trata da aquisição de sinais de EEG. No último tópico, 2.3, apresenta-se todo o processamento dos sinais separando-o em três etapas: o pré-processamento, o processamento dos dados para, enfim, explicar como é feita a classificação das informações através das máquinas de vetor de suporte.




Figura 4: Etapas seguidas para o reconhecimento de padrões em sinais auditivos.

3.1 Estimulação e Coleta de Dados

Para a execução desse projeto criou-se um banco de dados com cerca de 270 exames utilizando-se 22 voluntários com idades entre 17 e 24 anos e que durante entrevista prévia não relataram nenhum histórico de problemas neurológicos ou de disfunção auditiva. Os indivíduos foram colocados em uma cabine com isolamento acústico onde permaneciam durante todo o exame e onde eram submetidos aos estímulos sonoros.

Os estímulos auditivos constituem de um tom senoidal puro modulado em amplitude (tom AM). Os tons AM podem ser gerados usando o seguinte procedimento:

$$s(t) = A \frac{1}{1 + \Psi} \text{sen}(2\pi \cdot f_c \cdot t) (1 + \Psi \cdot \text{sen}(2\pi \cdot f_m \cdot t)), \quad (3.1)$$

onde A é a amplitude do sinal, Ψ é a profundidade de modulação, f_c é a frequência da onda portadora, f_m é a frequência da onda moduladora e t , o tempo.

Para gerar os estímulos utilizou-se a ferramenta GUI (Graphical User Interface) do Matlab7.10.0 (R2010a) [10] que permite construir interfaces gráficas de interação com o usuário. Na GUI construída é possível selecionar as frequências das portadoras dos estímulos dos ouvidos esquerdo e direito, em 500, 1000, 2000 e 4000 Hz, e a intensidade sonora dos estímulos em 31, 1; 34, 7; 35, 8; 39, 36; 41, 7; 42, 9 e 46, 4 dB. Estes valores não poderiam ser escolhidos livremente de acordo com a vontade do usuário, pois há a necessidade de calibrar os fones para cada frequência e intensidade sonora desejada, e como já se tinham os valores de calibração dos fones para os valores citados acima, os mesmos foram fixados. A GUI apresentava também campos livres para digitar o valor das frequências da moduladora de cada estímulo, a frequência de amostragem, o tempo de estímulo e o número de pontos das janelas utilizadas para calcular a FFT dos sinais. Lembrando que a frequência de amostragem deve ser a mesma selecionada no equipamento *BNT-36* (EMSA, Brasil, www.emsamed.com.br) usado para coletar os sinais de EEG. A figura 5 mostra a GUI construída.

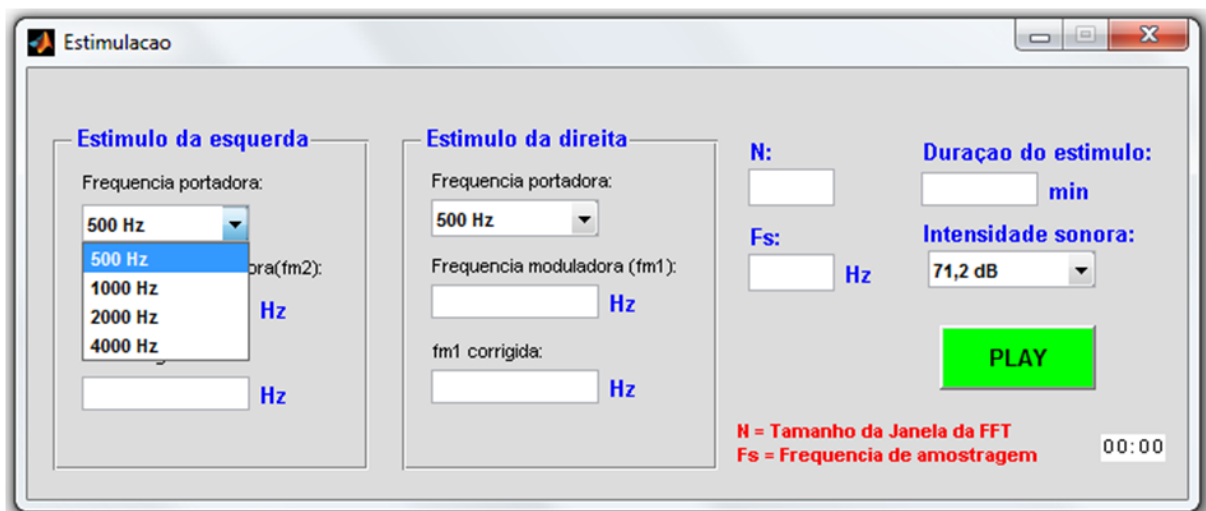


Figura 5: GUI construída para gerar os estímulos e o sinal do *trigger* [10].

Para reproduzir os estímulos foram utilizados fones de inserção para audiometria *E-A-*

RTONE®5A Insert Earphone, da *E-A-R Auditory Systems*, mostrado na FIGURA 6. As espumas dos fones selam o ouvido do indivíduo e funcionam como um sistema de entrega de som, além de atenuar o ruído do ambiente de 30 a 40dB.



Figura 6: *E-A-RTONE®5A Insert Earphone*[33].

Além disso, a interface criada gera um sinal de trigger para os estímulos, o qual é apresentado em um dos canais DC do eletroencefalógrafo. Quando um estímulo é reproduzido, a GUI fica responsável pelo pino 7 de controle, RTS (Request to Send), seta a porta serial DB9 do computador em +11V, e quando nenhum estímulo é reproduzido, o pino 7 fica em -11V. Como este nível de tensão encontrava-se em um nível muito alto para os canais DC do eletroencefalógrafo, foi desenvolvido um circuito divisor de tensão com um diodo na entrada para setar o sinal de trigger em nível zero quando nenhum estímulo estivesse sendo reproduzido e, em 0,48V durante a reprodução dos estímulos como pode ser visto na figura 7 [10].




Figura 7: Circuito divisor de tensão [10].

Para a construção do banco de dados utilizando o programa mostrado na Figura 5 alguns parâmetros foram mantidos constantes. No caso, o número de janelas para FFT N ficou estabelecido em 1024 pontos, a duração do estímulo em 2 minutos, a intensidade sonora em 75,8dB para todos os exames e a frequência de amostragem foi definida como 601,5Hz que é o valor real da frequência de amostragem do equipamento BNT-36.

3.2 Aquisição de Sinais

3.2.1 Sistema Internacional 10-20

Para coletar os sinais de EEG foi utilizado o Sistema Internacional 10-20. Conforme pode ser visto na figura 8, este sistema padroniza o posicionamento dos eletrodos que são aderidos no escalpo de cada paciente e a designação de cada eletrodo.




Figura 8: Sistema internacional 10-20 [10].

O posicionamento dos eletrodos utiliza a relação de 10 ou 20% da distância total entre os marcos anatômicos da cabeça (nasal, na frente da cabeça; protuberância occipital, na parte de trás da cabeça; pontos pré-auriculares, nas laterais esquerdas e direitas da cabeça), como pontos de referência e permitindo assim uma cobertura mais uniforme possível de todas as regiões superficiais do cérebro. Os eletrodos são nomeados conforme a referente posição da cabeça: Fp para frontal-polar, F para frontal, C para central, P para parietal, T para temporal e O para occipital. Os números ímpares referem-se a eletrodos no lado esquerdo da cabeça, números pares a eletrodos do lado direito e a letra Z denota eletrodos na região central.

3.2.2 Coleta de sinais de EEG

Os sinais foram coletados usando o amplificador de sinais biológicos (BrainNet BNT-36), mostrado na figura 9, com filtro passa-alta e passa-baixa de 0,1 e 100Hz, respectivamente, e frequência de amostragem de 601,5Hz. Foram utilizados todos os canais do Sistema Internacional 10-20 com referência biauricular. Os estímulos gerados pela GUI foram levados para dentro da cabine através de um cabo blindado.



Figura 9: *BrainNet BNT 36*[34].

3.3 Processamento de sinais

3.3.1 Pré-processamento dos sinais

Primeiramente é feito um pré-processamento no domínio do tempo, que consiste na sincronização dos sinais de EEG com os instantes do estímulo. Esta sincronia é feita a partir do sinal de *Trigger*, enviado ao eletroencefalógrafo no instante em que o estímulo é aplicado ao voluntário.

Posteriormente os sinais são condicionados a processos de filtragem e remoção de artefatos. A cada trecho adquirido será aplicado um filtro passa-faixa, observando a frequência da moduladora, bem como um filtro rejeita-faixa de $60Hz$, para remover a componente espectral da rede elétrica, que geralmente apresenta elevado nível de potência [31].

Para rejeição de artefatos foram estudadas técnicas para descartar trechos de sinais coletados que contenham variações elevadas na amplitude do sinal em curto intervalo de tempo. [35] propuseram uma técnica de remoção automática de artefatos baseada no desvio padrão do sinal de EEG sem ruídos, de 20 segundos de duração, tomado como referência. A técnica consiste em rejeitar um trecho de sinal caso este tenha mais de 5% de amostras contínuas ou mais de 10% de quaisquer amostras coletadas que excedam ± 3 desvios padrões.

3.3.2 Análise de Componentes Principais (PCA)

A análise dos componentes principais - ACP ou PCA (do inglês *Principal Component Analysis*) é um método que tem por finalidade básica, a análise dos dados usados visando

sua redução, eliminação de sobreposições e a escolha das formas mais representativas de dados a partir de combinações lineares das variáveis originais.

É também chamado de Transformada Discreta de *Karhunen-Loève* (KLT) ou ainda Transformada *Hotelling*, em homenagem a *Kari Karhunen*, *Michel Loève* (1907 - 1979) e *Harold Hotelling*. Ela transforma variáveis discretas em coeficientes descorrelacionados. Foi derivada por *Hotelling* e por ele denominada como *Método dos componentes principais*.

Análise de componentes principais (PCA) é um dos métodos estatísticos de múltiplas variáveis mais simples. A PCA é considerada a transformação linear ótima, dentre as transformadas de imagens, sendo muito utilizada pela comunidade de reconhecimento de padrões.

Da perspectiva de reconhecimento estatístico de padrões, o valor prático da análise de componentes principais é que ela fornece uma técnica efetiva para redução de dimensionalidade. Em particular, podemos reduzir o número de características necessárias para a representação efetiva de dados descartando aquelas combinações lineares que têm variâncias pequenas e retendo apenas aqueles termos que têm variâncias grandes [36].

Logo, para calcular as componentes principais temos os seguintes passos:

- Obter os dados ou as M amostras de vetores de dimensão n ;
- Calcular a média ou o vetor médio destes dados;
- Subtrair a média de todos os itens dos dados;
- Calcular a matriz de covariância usando todas as subtrações. Ela é o resultado da média do produto de cada subtração por ela mesma e terá dimensão $n \times n$;
- Calcular os auto valores e auto vetores da matriz de covariância;
- Arranjar a matriz da Transformada de *Hotelling* (cujas linhas são formadas a partir dos auto vetores da matriz de covariância arranjados de modo que a primeira linha, o elemento $(0, 0)$, seja o auto vetor correspondente ao maior auto valor, e assim sucessivamente até que a última linha corresponda ao menor autovalor).

Essas etapas foram seguidas nessa monografia de forma a reduzir o grande volume de dados inicial. Após o pré-processamento onde um filtro passa-faixa foi utilizado e onde foram removidos artefatos definiu-se que seriam usadas as 4 primeiras componentes pois estas correspondiam em todos os casos a no mínimo 90% de informação dos dados iniciais.

O que se fez nesse processo foi a seleção de características, ou seja, o espaço de dados é transformado em um espaço de características que, em teoria, tem exatamente a mesma dimensão que o espaço original de dados. Porém, selecionamos apenas as características *efetivas*, ou seja, aquelas que realmente carregam informações relevantes sobre o registro feito.

3.3.3 Coeficiente do Modelo AR

Modelagem matemática é a área do conhecimento que estuda maneiras de desenvolver e implementar modelos matemáticos de sistemas reais. Há várias formas e técnicas de se obter modelos matemáticos, uma delas é a modelagem caixa branca. Nesse caso, faz-se necessário conhecer a fundo o sistema a ser modelado. Além de estar bem familiarizado com o sistema, para esse tipo de modelagem é necessário conhecer as relações matemáticas que descrevem os fenômenos envolvidos. Modelagem caixa branca é também conhecida como modelagem pela física ou natureza do processo ou ainda modelagem fenomenológica ou conceitual. Infelizmente, devido ao conhecimento e tempo necessário para modelar um sistema partindo do equacionamento dos fenômenos envolvidos, nem sempre é viável seguir esse procedimento de modelagem [37].

Identificação de sistemas é uma área do conhecimento que estuda técnicas alternativas de modelagem matemática. Uma das características dessas técnicas é que pouco ou nenhum conhecimento prévio do sistema é necessário e, conseqüentemente, tais métodos são também referidos como modelagem (ou identificação) caixa preta ou modelagem empírica. Em muitos casos será preferível usar técnicas de identificação de sistemas. Nesse caso, o tipo de modelos, as técnicas usadas e os requisitos necessários são bastante distintos dos análogos na modelagem pela natureza do processo [37].

O modelo auto-regressivo (AR do inglês autoregressive) é um modelo estocástico e é útil na representação de um grande número de séries temporais. O modelo auto-regressivo corresponde a um filtro que tem como entrada o ruído branco de média 0 e desvio padrão 1 e como saída o sinal desejado [38]. O valor corrente do processo é expresso como uma combinação linear finita de valores prévios do processo e um ruído aleatório a_t . O modelo AR de ordem p pode ser expresso como segue:

$$y(k) = a_1y(k-1) + a_2y(k-2) + a_p y(k-p) + a_t, \quad (3.2)$$

onde os coeficientes a_1, a_2, \dots, a_p descrevem como um valor corrente $y(k)$ relaciona-se com variáveis passadas $y(k-1), y(k-2), \dots, y(k-p)$.

Para o caso do processamento de sinais, que é o assunto desta monografia, essa técnica foi utilizada para criar um modelo AR a partir das características extraídas das componentes principais com o objetivo de reduzir ainda mais o conjunto de dados. Os modelos AR criados variaram da ordem de 3 a 10. De posse de uma equação que represente o exame, os coeficientes gerados são utilizados como vetor de entrada do classificador.

3.3.4 Máquinas de Vetor de Suporte

Fundamentada na Teoria da Aprendizagem Estatística, a Máquina de Vetores Suporte, do inglês Support Vectors Machine - SVM, foi desenvolvida por [39], com o intuito de resolver problemas de classificação de padrões.

Segundo [36] a máquina de vetores suporte é outra categoria das redes neurais alimentadas adiante, ou seja, redes cujas saídas dos neurônios de uma camada alimentam os neurônios da camada posterior, não ocorrendo a realimentação.

Esta técnica originalmente desenvolvida para classificação binária, busca, para padrões linearmente separáveis, a construção de um hiperplano como superfície de decisão, de tal forma que a separação entre exemplos seja máxima. Isso considerando padrões linearmente separáveis.

Já para padrões não-linearmente separáveis, busca-se uma função de mapeamento apropriada para tornar o conjunto mapeado linearmente separável.

Basicamente, a máquina de vetor de suporte é uma máquina linear com algumas propriedades muito interessantes. A ideia principal de uma máquina de vetor de suporte é construir um hiperplano como superfície de decisão de tal forma que a margem de separação entre exemplos positivos e negativos seja máxima. A máquina apresenta esta propriedade desejável seguindo uma abordagem fundamentada na teoria da aprendizagem estatística. Mais precisamente, a máquina de vetor de suporte é uma implementação do método de minimização estrutural de risco. Este princípio indutivo é baseado no fato de que a taxa de erro de uma máquina de aprendizagem sobre dados de teste (i.e, a taxa de erro de generalização) é limitada pela soma da taxa de erro de treinamento e por um termo que depende da dimensão de Vapnik-Chervonenkis (V-C); no caso de padrões separáveis, uma máquina de vetor de suporte produz um valor de zero para o primeiro termo e minimiza o segundo termo. Consequentemente, a máquina de vetor de suporte

pode fornecer um bom desempenho de generalização em problemas de classificação de padrões, apesar do fato de que ela não incorpora conhecimento do domínio do problema. Este atributo é único das máquinas de vetor de suporte [36].

Uma noção que é central à construção do algoritmo de aprendizagem por vetor de suporte é o núcleo do produto interno entre um "vetor de suporte" x_i e o vetor x retirado do espaço de entrada. Os vetores de suporte consistem de um pequeno subconjunto dos dados de treinamento extraído pelo algoritmo. Dependendo de como este núcleo de produto interno é gerado, podemos construir diferentes máquinas de aprendizagem, caracterizadas por superfícies de decisão não-lineares, próprias. Em particular, podemos usar o algoritmo de aprendizagem por vetor de suporte para construir os três seguintes tipos de máquinas de aprendizagem (entre outros)[36]:

- Máquinas de aprendizagem polinomial;
- Redes de função de base radial;
- Perceptrons de duas camadas (i.e., com uma única camada oculta);

Isto é, para cada uma dessas redes alimentadas adiante podemos usar o algoritmo de aprendizagem por vetor de suporte para implementar o processo de aprendizagem, usando um determinado conjunto de dados de treinamento, determinando automaticamente o número necessário de unidades ocultas [36].

Este algoritmo de classificação tornou-se, nos últimos anos, um dos métodos de classificação mais populares no campo da aprendizagem de máquinas e por conta disso buscou-se nesse trabalho estudar o poder dessa ferramenta ao tentar reconhecer padrões em sinais biológicos.

Feito todo o processamento de sinais desde a filtragem de $60Hz$ e seus harmônicos até a modelagem auto regressiva dos dados iniciais, iniciou-se classificação selecionando os coeficientes do modelos AR que foram usados como entrada. O número de coeficientes para cada exame depende do número de componentes principais e da ordem do modelo AR empregado. Finalmente, divide-se os vetores de entrada em dois grupos, um para treinamento e outro para classificação.

4 *Resultados e Discussões*

Neste capítulo são mostrados os resultados obtidos para os processos descritos no capítulo anterior. Foram feitos classificadores para alguns grupos de exame. Primeiramente, avaliou-se o classificador SVM para um conjunto de 267 amostras que envolviam diferentes voluntários e diferentes combinações de frequências moduladoras e portadoras. Neste classificador avaliou-se sua capacidade de detectar através do conjunto de dados de entrada (os parâmetros do modelo AR) se a pessoa estava ou não prestando atenção no estímulo gerado.

Em seguida, os mesmos testes são realizados, porém, para conjuntos de dados pertencentes a um mesmo indivíduo com diferentes combinações de frequências e também para 4 diferentes indivíduos para mesmos pares de frequências portadoras e moduladoras.

Finalmente, é feita a classificação para 3 classes, onde tenta-se classificar se o indivíduo não está prestando atenção ou se o mesmo está focando sua atenção no estímulo do ouvido esquerdo ou do ouvido direito. Para tal, foram utilizados os dados referentes a um indivíduo.

4.1 **Sinais Coletados**

Como foi dito no capítulo anterior, após a coleta dos sinais de EEG é feito um procedimento computacional para filtrar a frequência da rede no local do experimento ($60Hz$). Isso é feito porque durante o registro, o filtro *Notch* do aparelho de aquisição de dados permanece desligado. Mantemo-lo desligado pois a faixa de frequência que ele *corta* encontra-se, também, o intervalo das frequências que são utilizadas nesta monografia. Para se evitar que houvesse perda de informação preferiu-se fazer toda a parte de filtragem computacionalmente. Nas figuras 10 e 11 temos um exemplo do sinal registrado antes e depois do filtro.

Dando sequência ao pré-processamento dos dados, o sinal filtrado passa por uma





Figura 10: Sinal antes de ser filtrado

Figura 11: Sinal depois do filtro *NOTCH*

rotina de rejeição de artefatos, já descrito no capítulo anterior. Os canais escolhidos para fazer a rejeição foram os que ficam mais próximos do centro superior da cabeça, ou seja, os eletrodos Cz, Fz, Pz, F3, C3, P3, F4, C4 e P4.

Terminada essa parte inicial, dá-se início ao processamento onde, como já foi mencionado, o volume de informações é reduzido compactando-as através do uso de uma PCA e em seguida cria-se um modelo AR de onde são retirados os coeficientes. Inicialmente, havia 22 informações registradas a partir do EEG captadas através dos eletrodos sendo que 2 destes eram usados para referência. Então, ao se realizar a análise das componentes principais havia um arquivo com 20 eletrodos e milhares de informações que aparentemente não queriam dizer nada. Feito, então, todo o processo, obtivemos uma nova matriz de componentes principais. Fixou-se então que seriam aproveitadas as 4 primeiras componentes que correspondiam em todos os casos a mais de 90% de informação dos dados iniciais.

Esse novo conjunto de dados foi então conduzido a próxima etapa do processamento. Neste estágio eram extraídos os coeficientes do modelo auto-regressivo criado para as informações provenientes do sinal original. Estes modelos variaram de 3 a 10 a sua ordem para alterar o número de características que teríamos como entrada para o SVM. O algoritmo utilizado para a criação desse modelo foi o método de *Burg*. Este método, originalmente proposto por *Burg* como um algoritmo de máxima entropia, foi mais tarde interpretado como algoritmo de minimização dos mínimos quadráticos restritivo. A restrição imposta por *Burg* garante que os pólos dos filtros AR estejam dentro do círculo unitário (para garantir a estabilidade do filtro), no entanto as restrições parecem originar problemas tais como uma linha espectral partida (especialmente para sinais de banda estreita) e o viés (erro sistemático) da frequência estimada (que não ocorre quando é utilizada uma minimização não restringida com a mesma expressão do erro preditivo médio).

4.2 Classificador SVM

4.2.1 Caso Geral

Como foi dito no início do capítulo fez-se uma abordagem do classificador SVM avaliando-o para diferentes casos. Nesta primeira situação, foram utilizados todos os 267 exames disponíveis para a análise. Para chegar a esse número de exames foram necessários 22 voluntários com idade entre 17 e 24 anos, na sua maioria alunos de engenharia elétrica da Universidade Federal de Viçosa e várias dezenas de horas para a realização desses exames. Esses exames possuem diferentes pares de frequências portadoras e moduladoras. Os valores dessas frequências encontram-se na seção 3.1.

De posse dos coeficientes do modelos AR, criou-se uma rotina no MatLab que pegasse os coeficientes gerados para cada componente principal e os organizassem de forma a serem atribuídos como características de um mesmo sinal. Isso foi feito para todos os sinais. Os sinais foram distribuídos em classes de acordo com os exames realizados. As 3 classes criadas eram *Nenhuma*, *Esquerda* e *Direita* fazendo menção a atenção dedicada no instante do registro. Como o SVM é um classificador binário, foi feita a classificação de modo que houvesse distinção entre a classe *Nenhuma* e as outras duas classes. Durante o processo de classificação, variou-se o conjunto de dados que compunham os grupos de treinamento e teste com o objetivo de observar o comportamento de generalização da rede neural. Esses testes foram feitos para os diferentes coeficientes dos modelos AR criados. Na tabela 1 vemos os resultados obtidos para o melhor caso obtido que foi para um modelo AR de ordem 4 sendo que a taxa de acerto corresponde ao grupo de classificação e a função *kernel* à função usada durante o treinamento.

Tabela 1: Resultados obtidos na classificação do SVM a partir dos coeficientes do modelo AR de ordem 4

Grupos		Taxa de acerto	Função Kernel
Treinamento	Classificação		
10%	90%	72,08%	Linear
20%	80%	72,30%	Linear
30%	70%	73,66%	Linear
40%	60%	74,84%	Linear
50%	50%	77,44%	Polinomial
60%	40%	79,25%	Polinomial
70%	30%	81,01%	Quadrático
80%	20%	86,54%	Quadrático
90%	10%	92%	Quadrático

Foi feita também uma comparação entre os modelos AR para a mesma porcentagem de amostras no grupo de treinamento e teste para se analisar a eficiência dos coeficientes. Uma constatação importante ao analisarmos as melhores respostas para os modelos AR é que nem sempre teremos a mesma função kernel em todas as ordens. Na tabela 2 vemos as taxas de acerto obtidas e podemos ver que os melhores resultados foram para os modelos AR de ordem 6, 7 e 8 usando função kernel polinomial. Pode-se dizer que a complexidade do modelo não melhorou os resultados visto que o modelo de ordem 6 teve resultados iguais aos modelos de ordem 7 e 8 e melhores que os de ordem 9 e 10.

Tabela 2: Melhores resultados obtidos após o treinamento de 70% do conjunto total de dados com o SVM, variando-se a ordem do modelo AR

Modelo AR	Taxa de acerto	Função Kernel
Ordem 03	73,66%	linear
Ordem 04	73,66%	linear
Ordem 05	74,73%	linear
Ordem 06	76,88%	polinomial
Ordem 07	76,88%	polinomial
Ordem 08	76,88%	polinomial
Ordem 09	76,34%	linear
Ordem 10	76,34%	linear

4.2.2 Casos para 1 indivíduo

A abordagem para 1 indivíduo consistiu em analisar o SVM para dois casos. Para o primeiro foram definidos duas classes que dividiam os dados de treinamento para os casos em que o voluntário não prestava atenção e quando ele prestava atenção no estímulo sonoro gerado. Já o segundo, o conjunto de informações foi separado em três classes sendo estas: *Nenhuma*, *Esquerda* e *Direita*. O SVM por ser um classificador binário há a necessidade de se utilizar técnicas de decomposição de problemas multi-classe. Entre os métodos mais conhecidos estão o *Método Todos-contra-todos*, o *Método Um-contra-todos* e o *Método por Códigos de correção de erros de saída*. Para esse trabalho definiu-se o método de Todos-contra-todos com votação por maioria, pois segundo [40] este é o melhor método ao se tratar de problemas multi-classes com SVM.

O método todos-contra-todos consiste em criar conjuntos de dados com todas as combinações possíveis das classes do problema original, juntado-as duas a duas. Para cada uma das combinações é gerado um modelo de decisão. Um problema multi-classe com k classes é transformado em k' problemas bi-classe, cada um com o seu modelo de decisão b , independente, onde

$$k' = \frac{k(k-1)}{2}, \quad (4.1)$$

Cada problema bi-classe é definido por um conjunto de treino constituído pelos exemplos de apenas 2 classes. No nosso caso, o problema original tem 3 classes (A,B,C) e por ter esse número reduzido de classes teremos 3 problemas bi-classe: A-B, A-C, B-C onde A, B e C são, respectivamente, as classes *Nenhuma*, *Esquerda* e *Direita*. O conjunto de treino A-B consiste apenas nos exemplos pertencentes às classes A e B. É aplicado um algoritmo de classificação a este conjunto, obtendo-se o classificador b_{ab} ; o conjunto de treino A-C tem apenas os exemplos das classes A e C e o algoritmo de classificação é aplicado apenas a esse conjunto, obtendo o classificador b_{ac} . O mesmo vale para o último caso onde teremos b_{bc} . De forma geral, cada modelo de decisão b_i é construído tendo por base um conjunto de treino de dimensão inferior ao conjunto de treino do problema multi-classe.

A partir dos classificadores criados, avaliamos um novo dado através da análise dos 3 classificadores gerados individualmente. A classe que obtiver mais votos será aquela em que o novo dado se encaixará. Um exemplo da aplicação encontra-se na TABELA 3. É apresentado um novo dado e o mesmo é classificado pelos SVM's criados. Nos dois primeiros ele é classificado como classe A e no último caso como C. Vemos, então, que ele obteve 2 votos para A e 1 para C. Logo, ele será classificado como *classe A*.

Tabela 3: Exemplo de um Classificador *todos-contra-todos* com votação por maioria

Classificador	Resultado
A-B	A
A-C	A
B-C	C

Caso 1 Nesse primeiro caso usamos 21 exames relacionados a um mesmo voluntário. Na tabela 4 encontramos os dados para este indivíduo onde fazemos a classificação de 2 classes. O intuito foi uniformizar os dados para facilitar a classificação dos mesmos. Para tal, os dados foram divididos, como no caso geral, em grupos de treinamento e validação, variando-se o tamanho destes. De acordo com a tabela 4 pode-se notar que o uso de ICCs usando esse tipo de RE não necessita de um treinamento rigoroso do usuário para a sua utilização. Outra constatação que pode ser assumida é que usando-se apenas 10% dos dados para treinamento em um total de 21, em qualquer dos casos, o acerto foi superior a 80%, lembrando que as combinações de frequências são diferentes. O que indica ainda que não é necessário treinar uma pessoa para um mesmo par de portadora e moduladora para

conseguir resultados expressivos. Com um pouco mais de dados para o treinamento, as respostas foram sempre corretas, o que nos mostra que o SVM é uma ferramenta efetiva para a classificação de ICCs [41].

Tabela 4: Resultados obtidos após o treinamento de 21 exames de um mesmo voluntário variando-se o número de elementos no grupo de treino e validação

Treinamento	Ordem 3	Ordem 5	Ordem 7
10%	83,33%	88,89%	94,44%
20%	87,50%	93,75%	100,00%
30%	92,31%	100,00%	100,00%
40%	91,67%	100,00%	100,00%
50%	100,00%	100,00%	100,00%
60%	100,00%	100,00%	100,00%
70%	100,00%	100,00%	100,00%
80%	100,00%	100,00%	100,00%
90%	100,00%	100,00%	100,00%

Dando prosseguimento a análise do classificador SVM, fez-se a classificação dos exames em três classes conforme explicado anteriormente. A tabela 5 mostra os resultados obtidos variando-se a ordem do modelo AR. Os valores encontrados exibem a grande eficiência das máquinas de vetor de suporte no reconhecimento de padrões. Com poucas informações ele foi capaz de acertar todas as informações em 2 dos modelos criados. Se tivéssemos alterado o algoritmo na modelagem auto-regressiva ou aumentado o número de componentes principais ou ainda alterado a função de kernel para o treinamento do SVM, o resultado poderia ter sido igual em todos os casos. É importante ressaltar que em caso de empate, ou seja, cada classe recebeu 1 voto, considerou-se que não foi possível classificar o vetor de entrada e ele é contabilizado como um erro.

Tabela 5: Melhores resultados obtidos após o treinamento de 30% dos 21 exames disponíveis com o SVM, variando-se a ordem do modelo AR.

Modelo AR	Taxa de acerto
ordem 3	90,48%
ordem 4	90,48%
ordem 5	95,24%
ordem 6	100%
ordem 7	95,24%
ordem 8	95,24%
ordem 9	100%
ordem 10	95,24%

Aqui é feita a mesma análise vista na seção anterior, porém ela é feita para um indivíduo diferente e, além disso, temos mais que o dobro de dados para fazer a classificação dos dados, 54 amostras. Na tabela 6 vemos os resultados obtidos e podemos notar que as taxas de acerto são semelhantes às encontradas no indivíduo anterior o que valida o método utilizado. É importante salientar, assim como no caso anterior, que todas as combinações de frequência são diferentes o que pode resultar em valores diferenciados. Experimentos de um mesmo indivíduo para uma mesma combinação de frequências poderia ser feita para analisar se a mudança das frequências portadoras e moduladoras no estímulo sonoro afetam o resultado final e, assim, compará-los com os números da tabela 6. Mas esse não é o escopo dessa monografia. Outra característica interessante que podemos observar é que a taxa de acerto se manteve constante independentemente do número de coeficientes do modelo AR usados para a classificação chegando em alguns casos a ter resultados melhores para um modelo AR de menor complexidade.

Tabela 6: Resultados obtidos após o treinamento de 54 exames de um mesmo voluntário variando-se o número de elementos no grupo de treino e validação

Treinamento	Ordem 3	Ordem 5	Ordem 7
10%	83,33%	85,42%	81,25%
20%	85,71%	88,10%	88,10%
30%	89,19%	91,89%	89,19%
40%	93,55%	93,55%	93,55%
50%	96,30%	96,30%	96,30%
60%	100%	100%	100,00%
70%	100%	100%	100%
80%	100%	100%	100%
90%	100%	100%	100%

Em seguida, fizemos a classificação de 3 classes e os resultados podem ser conferidos na tabela 7. Nessa tabela foram acrescentadas informações sobre os dados que não foram enquadrados em nenhuma das classes. Eles mostram que o classificador não é perfeito e que algumas alterações em alguma das etapas no processamento ou na classificação solucionassem essa *indecisão* do SVM. Diferentemente da tabela 5 em que obteve-se acertos superiores a 90%, nesse caso, o melhor resultado obtido foi 83,33% o que pode demonstrar que o classificador tem problemas em generalizar o problema ou, ainda, o número de combinações de frequências portadoras e moduladoras diferentes influenciou de forma negativa nos resultados finais e para uma classificação melhor seria necessário, como dito no parágrafo anterior, fazer experimentos sem variar as frequências.

Tabela 7: Melhores resultados obtidos após o treinamento de 30% dos 54 exames disponíveis com o SVM, variando-se a ordem do modelo AR

Modelo AR	Taxa de acerto	Resposta inconclusiva
ordem 03	83,33%	7,41%
ordem 04	81,48%	7,41%
ordem 05	81,48%	9,26%
ordem 06	79,63%	5,56%
ordem 07	77,78%	9,26%
ordem 08	81,48%	5,56%
ordem 09	83,33%	1,85%
ordem 10	81,48%	7,41%

4.2.3 Caso Especial

Esta seção aborda o caso onde tenta-se analisar se o classificador SVM consegue generalizar os resultados para diferentes indivíduos, porém com uma mesma combinação de frequências. Para esse teste utilizamos 12 exames de 4 voluntários diferentes sendo, como nos casos anteriores, 1 exame onde o paciente é induzido a não prestar atenção no estímulo sonoro, 1 estímulo onde ele deve prestar atenção no ouvido esquerdo e outro no ouvido direito. Devido ao número reduzido de amostras, optou-se por fazer apenas uma classificação binária onde a máquina criada dirá se o indivíduo está prestando, ou não, atenção no estímulo reproduzido em seu ouvido. A tabela 8 mostra os resultados encontrados nas simulações.

Tabela 8: Resultados obtidos após o treinamento de 12 exames para uma mesma combinação de frequências variando-se o número de elementos no grupo de treino e validação

Treinamento	Ordem 3	Ordem 5	Ordem 7
10%	70,00%	70%	80,00%
20%	77,78%	77,78%	77,78%
30%	85,71%	85,71%	100,00%
40%	100%	83,33%	83,33%
50%	100%	83,33%	83,33%
60%	100%	100,00%	100%
70%	100%	100,00%	100%
80%	100%	100,00%	100%
90%	100%	100,00%	100%

As taxas de acerto se assemelham bastante às encontradas para apenas 1 indivíduo o que mostra que pode-se usar indivíduos saudáveis para treinar uma determinada frequência e depois utilizá-la em paciente em estado *locked-in* ou afetados por esclerose lateral amiotrófica. Assim, estes pacientes poderiam responder perguntas simples, como sim e

não, focando atenção em um dos dois estímulos apresentados, sendo que seria pré-definido qual estímulo representaria o sim e qual representaria o não.

5 *Conclusões*

Ao final deste trabalho, podemos fazer algumas observações pertinentes acerca das máquinas de vetor de suporte. Esta tem a habilidade inerente de resolver um problema de classificação de padrões de uma forma *próxima do ótimo* para o problema de interesse. Além disso, ela é capaz de alcançar este desempenho notável sem qualquer conhecimento do domínio do problema incorporado no projeto da máquina. Entretanto, deve-se levar em consideração o custo que o seu uso acarreta. O desempenho de classificação quase perfeito é alcançado à custa de uma demanda significativa em complexidade computacional.

Para o caso geral, viu-se a complexidade que está inerente a avaliação da atenção seletiva. Neste projeto conseguiu-se uma taxa de acerto de 76,88% dos dados utilizando a função kernel polinomial e um modelo de ordem 6. As amostras utilizadas envolveram 120 diferentes combinações de frequências. Caso tivesse sido feito uma mineração dos dados, esse resultado pudesse se assemelhar aos resultados para os casos com exames, teoricamente, mais uniformes.

O método proposto para classificar sinais cerebrais estimulados por frequências específicas onde tentava-se apenas detectar se a pessoa estava focando ou não sua atenção mostrou-se bastante eficiente, pois em vários casos alcançou resultados expressivos, em outras palavras, acertou 100% das informações provenientes das ASSRs. Isso ocorreu para todos os modelos AR sendo que para o caso 1, seção 4.2.2, os coeficientes de ordem 7 classificaram todos os dados corretamente com apenas 20% dos dados para treinamento. Pode-se comparar os resultados com os obtidos em [42] sendo que os pesquisadores utilizaram 128 canais de EEG e não os 20 aqui usados. Conclui-se assim que a abordagem aqui descrita é mais eficiente.

No caso em que tratamos o uso das SVMs como classificadores multi-classe observamos sua eficácia onde obteve-se 100% acerto para o caso 1, 4.2.2 onde utilizou-se um modelo AR de ordem 6. Porém não temos até a presente data desta monografia alguma referência para comparar os resultados aqui obtidos. É, claro, que estudos mais profundos devem

ser feitos, mas os números conseguidos neste trabalho são bastante significativos pois há respostas com totalidade de acerto como pode ser visto na TABELA 5.

Como estudo futuro, dever-se-á fazer um classificador SVM que funcione online, ou seja, que tente informar em tempo real qual a situação do paciente onde seria feita a avaliação se ele está prestando atenção no estímulo sonoro ou não e em qual dos estímulos está o seu foco. Outras sugestões seriam a aplicação desse método em uma situação em que envolva a resposta sendo enviada para algum tipo de máquina e que a mesma execute o que o usuário indicar através do seu foco. Finalmente, a análise de um mesmo par de frequências para um único indivíduo como forma de treinamento.

Referências

- [1] SABBATINI, R. M. E. Mapeando o cérebro. *Cérebro & Mente*, April-September 1997.
- [2] COSTA, E. J. *Estudo da atividade elétrica cerebral em humanos e bovinos usando processamento digital de sinais e instrumentação eletrônica*. Tese (Doutorado) — USP, SP, 2005.
- [3] FERNANDES, A. G. Dissertação (Mestrado) — Faculdade de Medicina de Lisboa, Portugal, 2007.
- [4] CHIAPPA, K. H. *Evoked Potentials in Clinical Medicine*. New York: Raven Press, 1997.
- [5] DIMITRIJEVIC, A. et al. Estimating the audiogram using multiple auditory steady-state response. *J. Am. Acad. Audiol.*, v. 13, p. 205–224, 2002.
- [6] SCHWARTZ, M. L. et al. Somatosensory evoked potential monitoring during carotid surgery. *Cardiovascular Surgery*, v. 4, p. 77–80, 1996.
- [7] CELESIA, G. Visual evoked potentials and electroencephalograms. *Electroencephalography - Basic principles, Clinical Applications and Related Fields*, 1998.
- [8] PACHECO, E. A. Dissertação (Mestrado) — Tese de Mestrado, COPPE, UFRJ, 2003.
- [9] KUWADA, S.; BATRA, R.; MAHER, V. I. Scalp potentials of normal and hearing-impaired subjects in response to sinusoidally amplitude modulated tones. *Hear. Res.*, v. 21, n. 2, p. 179–192, 1986.
- [10] NICACIO, L. R.
Investigação da atenção seletiva auditiva para interface cérebro-computador usando magnitude quadrática de coerência, 2011.
- [11] JORIS, P. X.; SCHREINER, C. E.; REES, A. Neural processing of amplitude modulated sounds. *Physiol. Rev.*, v. 84, n. 1, p. 541–577, 2004.
- [12] LINDEN, R. D. et al. Human auditory steady-state potentials during sleep. *Ear Hearing*, v. 6, n. 1, p. 167–174, 1985.
- [13] STAPPELLS, D. R. et al. Inconsistency of auditory middle latency and steady-state responses in infants. *Electroenceph. Clin. Neurophysiol.*, v. 71, n. 4, p. 289–295, 1985.
- [14] PLOURDE, G.; PICTON, T. W. Human auditory steady-state response during general anesthesia. *Anesth. Analg.*, v. 71, n. 5, p. 460–468, 1990.

- [15] AOYAGI, M. et al. Optimal modulation frequency for amplitude modulation following response in young children during sleep. *Hear. Res.*, v. 65, n. 1-2, p. 253–261, 1993.
- [16] RICKARDS, F. W. et al. Auditory steady-state evoked potential in newborns. *Brit. J. Audiol.*, v. 28, n. 6, p. 327–337, 1994.
- [17] LINDEN, R. D. et al. Human auditory steady-state evoked potentials during selective attention. *Electroencephalogr Clin Neurophysiol.*, v. 66, 1987.
- [18] TIITINEN, H. T. et al. Selective attention enhances the auditory 40-hz transient response in humans. *Nature*, v. 6432, n. 364, p. 59–60, 1993.
- [19] ROSS, B. et al. The effect of attention on the auditory steady-state response. *Neurology and Clinical Neurophysiology*, v. 22, 2004.
- [20] FILHO, S. A. *Magnitude Quadrática da Coerência na Detecção da Imaginação do Movimento para Aplicação em Interface Cérebro-Máquina*. Tese (Doutorado) — UFMG, Belo Horizonte, MG, 2010.
- [21] LEUTHARDT, E. et al. A brain-computer interface using electrocorticography signals in humans. *ournal of Neural Engineering*, v. 1, 2004.
- [22] KREPKIA, R. et al. Brain computer interface the hci communication channel for discovery. *International Journal of Human-Computer Studies*, v. 65, n. 5, p. 460–477, 2007.
- [23] BANG-HUA, Y. et al. Adaptive subject based feature extraction in brain computer interfaces using wavelet packet best basis decomposition. *Med. Eng. & Physics*, v. 29, 2007.
- [24] VIADAURRE, C. et al. Fully online adaptive bci. *IEEE Trans. Biomed. Eng.*, v. 53, n. 6, p. 1214–1219, 2006.
- [25] PICCIONE, F. et al. P300-based brain computer interface Reliability and performance in healthy and paralysed participants. *Clin. Neurophys.*, v. 117, n. 3, p. 531–537, 2006.
- [26] BRAGA, E. Q. et al. Potencial evocado a estímulo elétrico senoidal de 2kHz usando wavelets. In: *Anais do CBEB 2006*. [S.l.: s.n.], 2006.
- [27] CHIAPPA, S.; BARBER, D. Eeg classification using generative independent component analysis. *Neurocomputing*, v. 69, 2006.
- [28] OSKOEI, M. A.; GAN, J. Q.; HU, H. Adaptive schemes applied to online svm for bci data classification. In: *31st Annual International Conference of the IEEE EMBS*. Minneapolis, Minnesota, USA: [s.n.], 2009.
- [29] FELIX, L. B. *Detecção Objetiva de Respostas Auditivas em Regime Permanente: aplicação em exames audiológicos*. Tese (Doutorado) — UFMG, Belo Horizonte, MG, 2006.

- [30] BEAR, M. F.; CONNORS, B. W.; PARADISO, M. A. *Os sistemas auditivo e vestibular In: Neurociências: desvendando o sistema nervoso*. [S.l.: s.n.].
- [31] RANAUDO, F. S. Dissertação (Mestrado) — COPPE, Universidade Federal do Rio de Janeiro, 2010.
- [32] CELESIA, G. G.; BRIGELL, M. G. Auditory evoked potentials. *In: Niedermeyer, E., Lopes da Silva, F. H (Eds.), Electroencephalography - Basic principles, Clinical Applications and Related Fields*, 2005. Cap. 53.
- [33] PÁGINA na internet acessada no dia 10. jun. 2011. Disponível em: <<http://www.etymotic.com/pro/er5a-acc.aspx>>.
- [34] PÁGINA na internet acessada no dia 10. jun. 2011. Disponível em: <<http://it.wikipedia.org/wiki/Portale:Neuroscienze>>.
- [35] INFANTOSI, A. F. C.; MELGES, D. B.; TIERRA-CRIOLLO, C. J. Use of magnitude-squared coherence to identify the maximum driving response band of the somatosensory. *Braz. J. Med. Biol. Res.*, v. 39, n. 12, p. 1593–1603, 2006.
- [36] HAYKIN, S. *Redes Neurais - Princípios e prática*. [S.l.]: Bookman, 2002.
- [37] AGUIRRE, L. A. *Introdução À identificação de sistemas - Técnicas lineares e não-lineares aplicadas a sistemas reais*. [S.l.]: UFMG, 2004.
- [38] SILVA, J. R. S. et al. Estudo das variações sazonais de hotéis de aracaju - se. In: *8º Encontro Regional de Matemática Aplicada e Computacional*. Natal, RN: [s.n.], 2008.
- [39] VAPNIK, V. *The nature of statistical learning theory*. New York: Springer-Verlag, 1995.
- [40] HSU, C. W.; LIN, C. J. A comparison of methods for multi-class support vector machines. *IEEE Transactions on Neural Networks*, v. 13, n. 2, p. 415–425, 2002.
- [41] ARBABI, E.; SHAMSOLLAHI, M. B.; SAMENI, R. Comparison between features used for the bayesian and the svm classifiers in bci. In: *Engineering in Medicine and Biology 27th Annual Conference*. [S.l.: s.n.], 2005.
- [42] LOPEZ, M. A. et al. Signal processing and perceptrons in an auditory based brain-computer interface. In: *Eighth International Conference on Hybrid Intelligent Systems*. [S.l.: s.n.], 2008.

ANEXO A – Algoritmos do SVM

Algoritmo 1

Determinação do hiperplano ótimo para conjuntos linearmente separáveis:

1: Para cada conjunto de treinamento linearmente separável $S = (x_1, y_1), \dots, (x_n, y_n)$;

2: Seja $a^* = (a_1, \dots, a_n)$ a solução do seguinte problema de otimização com restrições:

3: Maximizar: $\sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n y_i y_j \alpha_i \alpha_j x_i \cdot x_j$;

4: Sob as restrições:
$$\begin{cases} \sum_{i=1}^n y_i \alpha_i = 0 \\ \alpha_i \geq 0, i = 1, \dots, n \end{cases}$$

5: O par (w, b) apresentado a seguir define o hiperplano ótimo;

6: $w^* = \sum_{i=1}^n \alpha_i^{y_i x_i}$;

7: $b^* = -\frac{1}{2} \left[\max_{\{i|y_i=-1\}} (w \cdot x_i) + \min_{\{i|y_i=1\}} (w \cdot x_i) \right]$.

Algoritmo 02

(Hiperplano ótimo para padrões linearmente não-separáveis) Determinação do hiperplano ótimo no espaço de características:

1: Para cada conjunto de treinamento linearmente separável $\Phi(S) = (\Phi(x_1), y_1), \dots, (\Phi(x_n), y_n)$;

2: Seja $a^* = (a_1, \dots, a_n)$ a solução do seguinte problema de otimização com restrições:

3: Maximizar: $\sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n y_i y_j \alpha_i \alpha_j \Phi(x_i) \cdot \Phi(x_j)$;

4: Sob as restrições:
$$\begin{cases} \sum_{i=1}^n y_i \alpha_i = 0 \\ \alpha_i \geq 0, i = 1, \dots, n \end{cases}$$
 5: O par (w, b) apresentado a seguir

define o hiperplano ótimo;

6: $w^* = \sum_{i=1}^n \alpha_i^{y_i \Phi(x_i)}$;

7: $b^* = -\frac{1}{2} \left[\max_{\{i|y_i=-1\}} (w \cdot \Phi(x_i)) + \min_{\{i|y_i=1\}} (w \cdot \Phi(x_i)) \right]$.