

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

MATHEUS JOSÉ SOUZA PEDROSA

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

**VIÇOSA
2014**

MATHEUS JOSÉ SOUZA PEDROSA

**CLASSIFICAÇÃO 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
2014

MATHEUS JOSÉ SOUZA PEDROSA

**CLASSIFICAÇÃO 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 08 de julho de 2014.

COMISSÃO EXAMINADORA

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

Prof. Dr. Alexandre Santos Brandão - Membro
Universidade Federal de Viçosa

Prof. Paulo Fábio Figueiredo Rocha - Membro
Universidade Federal de Viçosa

Dedico essa vitória a todos que de perto acompanharam a minha caminhada. Todos que nesses últimos anos me ajudaram, apoiaram, incentivaram e que nunca duvidaram do meu sonho e potencial. Em especial aos meus avôs JOSÉ e ASTROGILDA, hoje anjos, pelo exemplo e apoio incondicional, mas por decorrência dos destino não estão ao meu lado para celebrar essa vitória.

Agradecimentos

Agradeço primeiramente a Deus por sempre iluminar meu caminho e ter colocado pessoas maravilhosas à minha volta, também por ter me concedido força e entusiasmo para que eu conseguisse chegar até o final deste trabalho. Aos meus pais José e Márcia e ao meu irmão João Marcos pelo amor e confiança que sempre depositaram em mim. À Bárbara pelo apoio incondicional, inspiração e por sempre estar ao meu lado. Aos amigos do laboratório NIAS, onde pude desenvolver a minha pesquisa. Aos colegas do curso de Engenharia Elétrica da UFV pelas discussões e sugestões no desenvolvimento da pesquisa. Ao professor Leonardo Bonato Felix por ter me orientado sempre com muita paciência. A todas as pessoas que me ajudaram se disponibilizando como voluntários para coleta de dados, sem os quais não seria possível finalizar o projeto. Meus sinceros agradecimentos também aos meus amigos Fernando Ranaudo (Drepa), Diego Marques (Droguinha), Augusto Ferreira (Augustin), Paulo Fábio (Paulão) e Álvaro Furlani (Alvarenga) que muito ajudaram no desenvolvimento do projeto, se disponibilizando como voluntário e também coletando dados para mim. E finalmente, a FAPEMIG pelo apoio financeiro concedido, sem o qual esta pesquisa não teria sido possível.

“No meio da dificuldade encontra-se a oportunidade.”

Albert Einstein

Resumo

A atenção seletiva auditiva é uma capacidade do cérebro de selecionar informações importantes e ignorar informações irrelevantes, onde as informações selecionadas pareçam mais nítidas. A maior nitidez das informações é devido às respostas evocadas, as quais surgem a partir das atividades elétricas encontradas no cérebro, onde o processamento das mesmas permitira a classificação de padrões auditivos e assim seria possível o desenvolvimento de uma interface cérebro-computador (ICC) a qual explorasse os efeitos da atenção nas respostas evocadas em regime permanente. Este sistema foi baseado em eletroencefalograma (EEG), uma vez que os sinais foram coletados simultaneamente com dois diferentes tons de 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 respostas auditivas em regime permanente (ASSRs) tentando-se classificar se o individuo encontra-se focando atenção no estímulo produzido no ouvido direito ou esquerdo. A abordagem para classificação foi feita utilizando-se Máquinas de Vetores de Suporte (SVM). Por convenção e para fins comparativos adotou-se a utilização de 70% dos dados para treinamento e o restante para validação. O experimento partiu de duas abordagens diferentes, inicialmente analisando apenas grupos com mesmas frequências portadora e moduladora, as taxas de acerto máximas nessas configurações concentraram-se no intervalo de acima de 75%, chegando a casos onde o acerto foi máximo. Em seguida a utilização de um grupo composto por todas as possíveis combinações de frequências, nessa configuração o classificador obteve como melhor desempenho, um percentual de acerto de 72,73%, obtido por uma máquina de vetor de suporte composta por um modelo AR de sexta ordem. Tal resultado evidenciou a relativa capacidade de classificação de uma máquina de vetores de suporte.

Abstract

The auditory selective attention is a brain's ability to select relevant information and ignore irrelevant information, where the selected information seemed sharper, more intense. The greater clarity of information is due to the evoked responses, which arise from the electrical activity found in the brain, where they will allow the processing of auditory pattern classification and thus would be possible to develop a computer-brain interface (ICC) which explores the effects of attention on steady state evoked responses. The approach to classification was done using the support Vector Machine (SVM). This system was based on EEG, since signals were collected simultaneously with two different tones of AM. The classification process was performed after dimensionality reduction of data using principal component analysis (PCA) and feature extraction through autoregressive parameters (AR). It also discussed a new approach to assess the ASSRs, attempting to classify whether the individual focuses his attention on the stimulus produced on the right or left ear. By convention and comparison we adopted 70% of the data for training and the rest for validation. The experiment started from two different approaches, initially analyzing only groups with the same carrier and modulating frequencies, leading to success rates beyond 75%, even with cases where the rate was maximum. Then the use of a group composed of all possible combinations of frequencies, the classifier performed better, resulting in 72,73% of correct answers, which was obtained by a support vector machine composed of an AR model of 6th order. This result showed the relative ability classification of a support vector machine.

Sumário

Lista de Figuras

Lista de Tabelas

1	Introdução	11
1.1	A atividade elétrica cerebral	11
1.2	Respostas evocadas	12
1.2.1	Resposta auditiva em regime permanente	13
1.3	Interface cérebro-computador	14
1.4	O sistema auditivo humano	16
1.5	Objetivo Geral	18
2	Materiais e Métodos	19
2.1	Estimulação	19
2.2	Protocolo da Estimulação	21
2.3	Aquisição de Sinais	22
2.3.1	Sistema Internacional 10-20	22
2.3.2	Coleta de sinais de EEG	23
2.4	Processamento de sinais	24
2.4.1	Pré-processamento dos sinais	24
2.4.2	Análise de Componentes Principais	25
2.4.3	Autovetor e Autovalor	26
2.4.4	Coefficiente do Modelo AR	27

2.4.5	Máquinas de Vetor de Suporte	28
2.5	Validação cruzada	32
3	Resultados e Discussões	33
3.1	Sinais Coletados	33
3.2	Classificador SVM	34
4	Conclusões	40
	Referências	42

Lista de Figuras

1	Vista panorâmica do sistema auditivo humano[1].	16
2	Membrana Basilar [2].	17
3	GUI utilizada para gerar os estímulos e o sinal de trigger.[3]	20
4	Insert Earphone [4]	20
5	Circuito divisor de tensão. [3]	21
6	Linha do tempo para os estímulos auditivos. Estímulo da orelha esquerda (superior) e orelha direita (inferior) [5].	22
7	Sistema internacional 10-20 [6].	23
8	BrainNet BNT 36 [7]	24
9	Superfícies de decisão: (a) é linearmente separável e (b) é não linearmente separável [8]	30
10	Gráfico da variância e desvio padrão por componente principal e da variância acumulada.	34

Lista de Tabelas

1	Frequências de modulação do estímulo e seus respectivos valores corrigidos [3]	21
2	Combinações de frequências portadoras e moduladoras estimuladas e o número de indivíduos por combinação.	24
3	Resultados obtidos na classificação do SVM para todas as combinações de frequência moduladora e portadora separadamente, a partir das variações do número de componentes principais e a ordem do modelo AR, utilizando-se todos os canais do EEG 30% dos dados para validação	35
4	Resultados obtidos na classificação do SVM para apenas para a combinação de frequência moduladora (32/38) e portadora (500/2000) a partir das variações do número de componentes principais, da ordem do modelo AR, utilizando-se apenas os canais (F3, P3, O1, T4, P4, O2 e Fz) do EEG e 30% dos dados para validação.	36
5	Resultados obtidos na classificação do SVM para apenas para a combinação de frequência moduladora (32/38) e portadora (500/2000) a partir das variações do número de componentes principais e da ordem do modelo AR, utilizando-se todos os canais do EEG e 30% dos dados para validação.	37
6	Resultados obtidos na classificação do SVM para todo o conjunto de dados a partir das variações do número de componentes principais e da ordem do modelo AR, utilizando-se apenas os canais (F3, P3, O1, T4, P4, O2 e Fz) do EEG e 30% dos dados para validação.	38
7	Resultados obtidos na classificação do SVM para todo o conjunto de dados a partir das variações do número de componentes principais e da ordem do modelo AR, utilizando-se todos os canais do EEG e 30% dos dados para validação.	38

1 *Introdução*

1.1 A atividade elétrica cerebral

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 permitiram a medida de correntes elétricas cada vez menores, passaram a estudar com crescente detalhe as propriedades da atividade elétrica do sistema nervoso[9].

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[9].

A atividade elétrica cerebral em humanos começou a ser investigada sistematicamente em 1929, mas foi na década de 50, com o avanço dos dispositivos eletrônicos que foi 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. Esta integração possibilitou o estudo detalhado dos sinais elétricos cerebrais dentro de um panorama empírico quantitativo de causa-efeito. Ao registro gráfico da variação da amplitude da atividade elétrica cerebral

em função do tempo deu-se o nome de eletroencefalograma [10].

O padrão da atividade elétrica cerebral é determinado pelo nível da atividade encefálica no momento 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 de forma assíncrona contribuem com uma intensidade muito baixa no EEG [10].

O EEG sugere que a atividade elétrica cerebral é oscilatória e contínua. Esta atividade oscilatória é dependente do nível de atividade do cérebro. Estas oscilações presentes no EEG são normalmente irregulares e nenhum padrão pode ser identificado considerando apenas a variação do EEG no tempo. Entretanto, podem ocorrer padrões no domínio do tempo em pessoas com algumas disfunções cerebrais como a epilepsia, ou em pessoas normais em alguns estados específicos, por exemplo, durante o sono [10].

Apesar desta característica predominantemente oscilatória do EEG, estudos mostram que outros tipos de comportamento podem ser observados no EEG em diferentes estados da dinâmica cerebral. Estes estudos mostraram que o sinal de EEG possui características de assimetria temporal, caóticas e não lineares [10].

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 [11], 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 (< 2 Hz) 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 (> 5 Hz), 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 na clínica médica, por exemplo: audiometria usando respostas auditivas em regime permanente (ASSRs) [12], avaliação de lesões na via auditiva primária através das respostas evocadas de tronco encefálico, também conhecido como BERA [11], monitoração de cirurgia através de REs somatosensíveis [13] e ativação do EEG em pacientes epiléticos [14].

1.2.1 Resposta auditiva em regime permanente

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 [15]. De acordo com [16], 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. De acordo com [17] 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 110 Hz [18] e [19], bem como a 40 Hz [20].

Estas respostas a modulações de 40 Hz são amplamente estudadas, apresentando as seguintes características:

- Sua amplitude decai consideravelmente durante o sono [21];
- É difícil de se registrar em crianças [22];
- É significativamente atenuada por anestesia [23].

Embora a amplitude da resposta a 70-110 Hz tenha uma intensidade 2 a 3 vezes menor que a resposta a 40 Hz durante vigília [24], tais respostas apresentam as seguintes vantagens:

- Muito menos afetadas pelo sono [25] e pelo despertar [19];
- Prontamente registradas em crianças [26].

Os estudos disponíveis sobre o efeito da atenção nas ASSRs são inconclusivos. Em [27] observaram diferenças na RE transitória durante atenção, porém nenhum efeito foi encontrado na amplitude e fase das ASSRs. Todavia, um aumento na amplitude da ASSR foi reportado em [28]. O experimento de *Linden* foi parcialmente reproduzido por em [29] usando magnetoencefalografia e um aumento na amplitude da ASSR evocada pelo estímulo focado foi observado entre 200 e 500 ms após o início do estímulo. Todos estes experimentos foram conduzidos por estímulos com moduladoras na faixa de 40 Hz.

1.3 Interface cérebro-computador

O EEG pode ser usado em uma interface cérebro-computador (ICC), onde um sistema permitiria que uma pessoa controlasse um computador usando apenas suas ondas cerebrais, esta abordagem pode ser útil, por exemplo, para a comunicação de pacientes portadores de deficiência motora. A paralisia, total ou parcial, pode ocorrer em consequência de derrame na região do tronco encefálico, paralisia cerebral, esclerose lateral amiotrófica etc. Além disso, foi demonstrado que pacientes em estado *locked in*, condição na qual o paciente está acordado e consciente, mas não consegue se mover ou comunicar devido à paralisia completa, aprenderam a se comunicar através de interface que interpreta os sinais EEG [30].

O EEG, bem como as REs, possui algumas limitações, tais como: pouca resolução espacial, isto é, não é possível associar de forma peremptória o sinal coletado no escalpo e seu gerador neural, e baixa relação sinal-ruído (SNR), devido às atividades de fundo e artefatos de movimento de olhos e músculos. Todavia, o EEG possui alta resolução temporal, se comparado com ferramentas de neuroimagem como fMRI (do inglês *Functional magnetic resonance imaging*) e PET (do inglês *Positron emission tomography*), além de portabilidade, facilidade no manuseio dos equipamentos e baixo custo de manutenção. Estas vantagens fazem do EEG uma ferramenta atrativa para implementação de sistemas de ICC. Além disso, estudos mostram que existem correlações entre sinais EEG e movimentos executados ou imaginados [31]. Como exemplo, citam-se as implementações de ICC que usam potenciais corticais lentos (SCPs) [32], atividades coletadas durante imaginação de movimento [31] e REs visuais, usando P300 o qual é um potencial evocado auditivo denominado potencial endógeno, (são os que obtêm maior troca de informações) [33].

A literatura mostra que as diversas possibilidades de ICC possuem vários níveis de

eficiência. Por exemplo, para alguns pacientes, a longa imobilidade e a degeneração das células piramidais do córtex motor pode dificultar a produção de sinais a partir de movimentos imaginados. Além disso, em situações onde os danos são bastante extensos, todo o sistema visual pode se tornar comprometido: se os olhos não puderem ajustar o foco, a fóvea não se moveria para inspecionar a cena visual; fato que rapidamente enfraqueceria as REs visuais [34]. Além disso, alguns métodos, como o de imaginação de movimentos, requerem algum treinamento anterior à utilização do sistema, o que pode incorrer em uma característica proibitiva para pacientes com expectativa de vida reduzida.

Assim, existe considerável motivação para a implementação de paradigmas alternativos para ICC, por exemplo, usando REs auditivos. Esta possibilidade pode ser explorada usando o efeito da atenção na resposta auditiva. Em [35] mostrou que a audição seletiva, isto é, focando atenção em um estímulo dentre dois, causa uma alteração quantificável na resposta medida. Desta forma, a implementação de um sistema de ICC auditiva poderia ser alcançada através da apresentação de sons diferentes ao indivíduo e coleta de sinais EEG. O indivíduo seria orientado a fazer uma escolha focando atenção em estímulo específico. Estes sinais seriam aplicados a um algoritmo de classificação/detecção de respostas e, assim, seria possível concluir qual estímulo o indivíduo focou atenção e, conseqüentemente, qual a informação ele desejaria passar.

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 torna-lo capaz de acionar um dispositivo externo com 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 que no domínio do tempo quanto da frequência. Dentre as técnicas e ferramentas matemáticas utilizadas nas ICC's, destacam-se: a Transformada Rápida de Fourier [35]; Transformada Wavelet [36]; modelagem paramétrica [37]; redes neurais [38]; componentes principais e componentes independentes [39] [40]; máquinas de vetor suporte [41] além de outros tipos de filtros como, por exemplo, filtros espaciais [35].

1.4 O sistema auditivo humano

O ouvido é essencialmente um mecanismo de recepção de ondas sonoras e de conversão de ondas sonoras em impulsos nervosos. Como pode ser observado na Figura 1, o ouvido é formado de três partes: o ouvido externo, ouvido médio e ouvido interno [38].



Figura 1: Vista panorâmica do sistema auditivo humano[1].

Após entrar no ouvido pelo meato, as ondas são guiadas pela parede deste canal até a membrana timpânica. O movimento desta membrana desloca os ossos do ouvido médio (na sequência de acionamento: martelo, bigorna e estribo), os quais são responsáveis pela condução de energia sonora até a orelha interna. A conexão entre a platina do estribo e a cóclea se dá através da janela oval [39].

De modo a otimizar a transferência de energia entre os ouvidos externo e médio, a membrana timpânica deve operar com a mesma pressão em ambas as faces. Essa equalização de pressão é realizada pela tuba auditiva, que liga o ouvido médio à nasofaringe e mantém a pressão atmosférica. Enquanto os ouvidos externo e médio são preenchidos de ar, a partir da janela oval o ouvido interno é preenchido por líquido (endolinfa), configurando uma interface ar-fluido que provocaria uma perda de energia por reflexão. Entretanto, devido à membrana timpânica ser maior do que a janela oval, a redução da área entre estas duas superfícies leva a um aumento na pressão (que equivale a força dividida pela área) na entrada da cóclea, funcionando como um amplificador mecânico e compensando as perdas ocorridas na interface ar-fluido. Este mecanismo acrescenta em média 25 dB à eficiência auditiva, enquanto o efeito de alavanca da cadeia ossicular contribui aumentando em 2,5 dB a amplificação sonora [39].

O órgão auditivo propriamente dito é a cóclea, uma estrutura em forma espiral com-

posta de duas voltas e meia nos seres humanos (aproximadamente 30 mm em adultos), localizada no interior do osso temporal. A cóclea consiste em uma câmara dividida em três compartimentos repletos de fluido, separados por duas membranas: a membrana de Reisner divide a câmara superior, a escala vestibular, da escala média, enquanto que a membrana basilar separa a escala média da escala timpânica. No ápice da cóclea, o helicotrema une as escalas vestibular e timpânica; assim estas duas câmaras compartilham o mesmo fluido, formando uma via de passagem da onda de pressão, ao modo de um tubo de extremidade aberta. Um deslocamento no estribo, relacionado ao estímulo acústico, produz uma movimentação do fluido dentro das duas espiras e meia da escala vestibular, transmitindo uma onda de compressão até o ápice da cóclea. Ao atingir o helicotrema, a direção da onda é invertida, e a energia retorna através da escala timpânica, provocando um movimento correspondente ao longo da membrana basilar. Sustentado por esta membrana, encontra-se o órgão de Corti, que é o principal da audição, onde se localizam as células ciliadas [40].

Devido à variação de reatância mecânica da membrana basilar, Figura 2, desde a base (próximo à janela oval) até o ápice (próximo ao helicotrema), o deslocamento produzido ao longo do comprimento da membrana torna-se específico em relação à frequência: estímulos de alta frequência provocam um máximo movimento na extremidade basal da membrana, enquanto estímulos de baixa frequência provocam máximo deslocamento na extremidade apical [40], estimulando assim apenas as células ciliadas que ali se encontram.

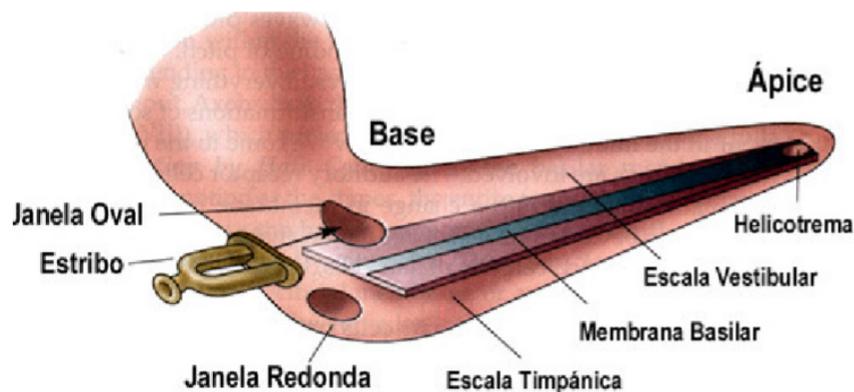


Figura 2: Membrana Basilar [2].

Em função do estímulo auditivo, a característica física de reatância da membrana basilar produz uma vibração característica, na forma de uma onda viajante. Desta forma, a membrana basilar pode ser modelada como uma série de filtros passa-faixa, agindo como um analisador de frequências para o sinal acústico de entrada [41]. A movimentação da membrana basilar altera a excitação das células ciliadas internas (CCI), modulando sua

frequência média de disparos e produzindo o impulso nervoso. As células ciliadas internas atuam como transdutores mecânico-neurais, quantificando o deslocamento da membrana basilar em informação para o sistema auditivo [42].

Praticamente toda a informação sensorial auditiva que segue para o sistema nervoso central provém das células ciliadas internas. Sabe-se que a quase totalidade das 30000 a 50000 fibras nervosas que se distribuem da cóclea para o sistema nervoso central fazem contato com as células ciliadas internas, mas somente uma pequena parte das fibras (5-10%) faz sinapse com as células ciliadas externas (CCE). Embora existam aproximadamente três vezes mais células ciliadas externas do que internas, parece que as células externas transmitem pouca informação sensorial para o sistema nervoso central através de fibras aferentes [40].

1.5 Objetivo Geral

Desenvolver um sistema de ICC explorando os efeitos de atenção nas ASSR's no qual 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 a atenção em um dos dois estímulos auditivos apresentados.

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

- Verificar a aplicabilidade das ASSR's como paradigma para ICC, através da variação de seus parâmetros de estimulação;
- Estudar o efeito da atenção nas ASSR's;
- Verificar a aplicabilidade do SVM para classificar a atenção seletiva auditiva;
- Comparar com os demais trabalhos já realizados na Universidade Federal de Viçosa.

2 *Materiais e Métodos*

2.1 Estimulação

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

$$s(t) = \frac{A}{(1 + \lambda)} \sin(2\pi f_c t)(1 + \lambda \sin(2\pi f_m t)) \quad (2.1)$$

Onde A é a amplitude do sinal, λ 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 (R20010a) que permite construir interfaces gráficas de interação com o usuário. Na GUI construída era possível selecionar as frequências das portadoras dos estímulos dos ouvidos esquerdo e direito, em 500, 1000 e 2000 Hz, e a intensidade sonora dos estímulos em 75,8, 71,2, 60,6, 44,7 e 34,7 dB. Estes valores não podem ser escolhidos livremente de acordo com a vontade do usuário, pois é necessário calibrar os fones para cada frequência e intensidade sonora desejada, dado que os valores de calibração dos fones para os valores citados acima, já estão estabelecidos [43].

A GUI apresenta 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 3 mostra a GUI utilizada.

Foi utilizado o fone de inserção E-A-RTone *5A da Aero Technologies* que é um dispositivo muito empregado em testes de audiometria. Consiste de um transdutor acústico que é introduzido no canal auditivo por meio de um tubo plástico flexível, com plugue de terminação macia [5], o mesmo é ilustrado na Figura 4.

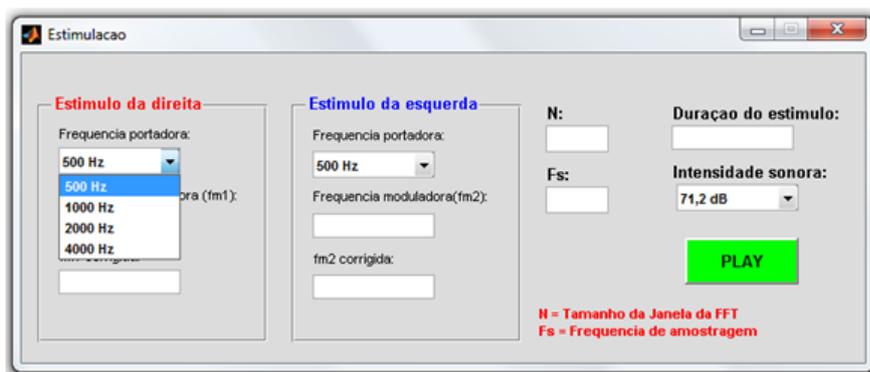


Figura 3: GUI utilizada para gerar os estímulos e o sinal de trigger.[3]



Figura 4: Insert Earphone [4]

Os níveis de tensão elétrica para calibração do fone, de acordo com o nível e intensidade sonora desejada, foram fornecidos pelo NEPEB (Núcleo de Estudos e Pesquisas em Engenharia Biomédica da UFMG), onde foi feita a calibração do equipamento utilizando um ouvido artificial acoplado a um medidor de níveis sonoros [5].

A GUI também gera um sinal de trigger para os estímulos que é mostrado em um dos canais DC do eletroencefalógrafo. Quando um estímulo é reproduzido, a GUI é responsável por pino 7 de controle, RTS (Request to Send), da porta serial DB9 do computador em +11V, e quando nenhum estímulo é reproduzido, o pino 7 fica em -11V. Como este nível de tensão é muito alto para os canais DC do eletroencefalógrafo, foi implementado um circuito divisor de tensão, Figura 5, com um diodo na entrada para colocar o sinal de trigger em nível zero quando nenhum estímulo estava sendo reproduzido e, em 0,48V durante a reprodução dos estímulos [3].

Os sinais de EEG dos indivíduos sob estímulos são analisados via FFT, assim, para diminuir o espalhamento, o valor da frequência de modulação escolhida para o estímulo foi corrigido para o valor mais próximo que apresentasse um número primo de ciclos da moduladora em cada janela. Esta correção foi realizada para a frequência de amostragem

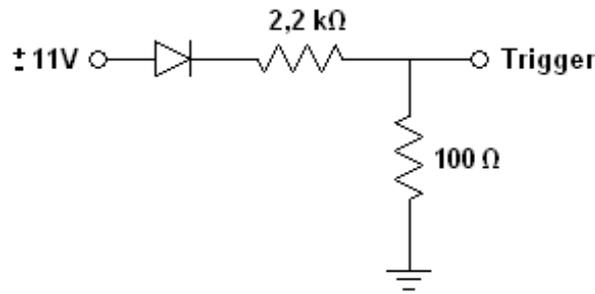


Figura 5: Circuito divisor de tensão. [3]

de 601,5 Hz, que é o valor real da frequência de amostragem do equipamento BNT-36 quando se seleciona a frequência de 600 Hz, e tamanho da janela para FFT de 1024 pontos. Assim, os estímulos eram gerados usando o valor corrigido da frequência de modulação, e estes também eram mostrados em um campo da GUI [3].

2.2 Protocolo da Estimulação

Para o estudo do efeito da atenção nas ASSR o protocolo de estimulação foi composto por três etapas de estimulação binaural, onde foram gerados tons AM com os parâmetros de estimulação mostrados na Tabela 1. Esses parâmetros foram definidos a fim de provocar a redução do espalhamento espectral, para isso foi utilizado o método de correção da frequência de estimulação aplicado a priori. Em [40] utilizaram a técnica proposta em simulações e dados experimentais, para mostrar que o vazamento espectral na detecção objetiva das ASSRs pode ser evitado através do ajuste da frequência de modulação do estímulo, de tal forma que cada janela de dados contenha número primo de ciclos do sinal, ou seja, frequência do estímulo é ajustada para garantir um número primo de oscilações em um trecho de comprimento fixo.

Tabela 1: Frequências de modulação do estímulo e seus respectivos valores corrigidos [3]

Frequência moduladora (Hz)	Frequência moduladora corrigida (Hz)
32	31,1323
34	34,6567
36	35,8315
38	39,356
41	41,7056

Os estímulos foram executados na faixa de 30 a 40Hz, pois nestas frequências as ASSR apresentam as maiores respostas, além de serem mais influenciadas pelo estado de atenção [24]; [27]; [44]. As etapas de estimulação binaural foram:

- Atenção ao estímulo da esquerda: os voluntários foram instruídos a focar a atenção no estímulo da esquerda e desprezar o estímulo da orelha direita;
- Atenção ao estímulo da direita: os voluntários foram orientados a focar a atenção no estímulo da direita e desprezar o estímulo da orelha esquerda;

Durante as etapas de estimulação os voluntários foram orientados a manter os olhos fechados, a fim de facilitar a concentração e evitar artefatos oculares [45].

Cada etapa de estimulação teve dois minutos e intervalos entre estimulação de trinta segundos. Antes de cada etapa na qual o individuo tivesse que focar a atenção em um determinado estímulo, era estimada apenas a orelha (monoaural) no lado do foco de atenção durante dez segundos, a fim de instruir e facilitar o individuo na tarefa cognitiva. A evolução das etapas de estimulação é ilustrada na Figura 6 [5].

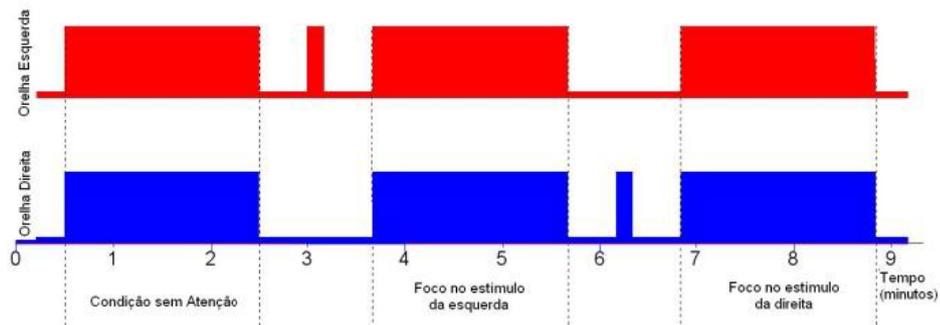


Figura 6: Linha do tempo para os estímulos auditivos. Estímulo da orelha esquerda (superior) e orelha direita (inferior) [5].

2.3 Aquisição de Sinais

2.3.1 Sistema Internacional 10-20

A disposição dos eletrodos na superfície do escalpo segue uma padronização internacional conhecida como sistema internacional 10-20. O sistema 10-20 tem como objetivo padronizar a disposição dos eletrodos em determinadas áreas da superfície do escalpo independentemente do tamanho do crânio [3].

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].

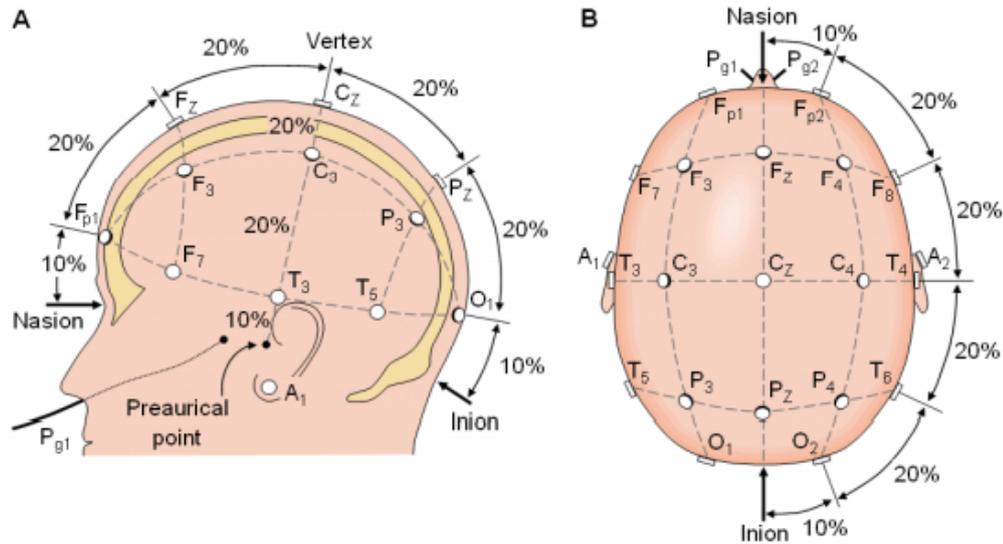


Figura 7: Sistema internacional 10-20 [6].

2.3.2 Coleta de sinais de EEG

Os sinais foram coletados usando o amplificador de sinais biológicos (BrainNet BNT-36), mostrado na Figura 8, com filtro passa-alta e passa-baixa de 0,1 e 100 Hz, respectivamente, e frequência de amostragem de 601,5 Hz. Foram utilizados todos os canais do Sistema Internacional 10-20 com referência biauricular. Os voluntários foram postos sentados dentro de uma cabine audiométrica e os estímulos gerados pela GUI foram levados para dentro da cabine através de um cabo blindado.

As combinações de frequências estimuladas foram definidas de maneira que se pudessem diferenciar os ruídos estimulados, logo facilitaria que o paciente conseguisse focar a atenção. Todos os sinais foram coletados de jovens entre 18 e 24 anos e sem problemas auditivos aparentes. Não ocorreu nenhum processo de seleção, qualquer voluntário poderia ser submetido a qualquer combinação de frequência, todo processo aconteceu de forma aleatória. Na Tabela 2 demonstra os pares de frequências (portadora e moduladora) os quais foram estimulados, bem como o número de indivíduos avaliados em cada combinação.

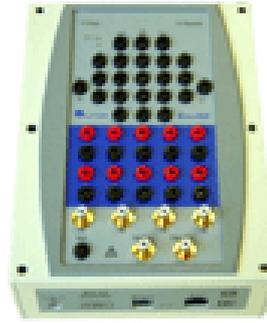


Figura 8: BrainNet BNT 36 [7]

Tabela 2: Combinações de frequências portadoras e moduladoras estimuladas e o número de indivíduos por combinação.

Moduladora	Portadora	
	500/1000	500/2000
32/36	9	8
32/38	8	14
32/41	8	8
34/38	8	8
34/41	8	8
36/41	8	8
38/41	9	8

2.4 Processamento de sinais

2.4.1 Pré-processamento dos sinais

O primeiro passo é pré-processar o sinal no domínio do tempo, essa etapa relaciona-se com a sincronização dos sinais de EEG com os instantes do estímulo. Isto é feito com o auxílio do sinal de Trigger, que foi enviado ao eletroencefalógrafo simultaneamente ao momento 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 60 Hz, para remover a componente espectral da rede elétrica, que geralmente apresenta elevado nível de potência [46]

Para a 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. Em [47] propuseram uma técnica de remoção automática de artefatos baseada no

desvio padrão do sinal de EEG sem ruídos, de 20 segundos de duração, tomando como referência. A técnica consiste em rejeitar um trecho de sinal caso este tenha mais de 5% de amostras contínuas ou mais 10% de quaisquer amostras coletas que excedam +3 desvios padrões.

Subsequentemente a rejeição de artefatos fez-se uma etapa de subtração dos sinais, onde tomou-se como referência a situação em que o paciente não estivesse focando a atenção a quaisquer estímulo. Esse passo foi realizado a partir da aquisição dos sinais onde não ocorreu o foco de atenção, logo todos os sinais processados foram definidos com o mesmo tamanho e deles eram subtraído o sinal de referência, ou seja, o sinal que representa atenção no estímulo esquerdo é composto pelo sinal coletado para o estímulo do lado esquerdo subtraído do sinal coletado para a situação de sem atenção, o mesmo procedimento foi feito para os estímulos do lado direito e assim para todo o conjunto de dados.

2.4.2 Análise de Componentes Principais

Descrita de forma independente por *Pearson* (1901) e *Hotelling* (1933), a Análise de Componentes Principais (PCA) é uma técnica estatística de análise multivariada, que transforma linearmente um conjunto de vetores de K variáveis levando a K novas variáveis, onde cada uma das novas variáveis é uma combinação linear das variáveis originais. A combinação é tal que as novas variáveis são não correlacionadas e concentram a maior variância possível nas primeiras P variáveis, denominadas componentes principais (CP). Essa transformação objetiva a redução da dimensionalidade dos dados sem que haja grande perda das informações, preservando ao máximo a variação presente nos dados [48].

Nessa análise, as K variáveis originais são transformadas em K novas variáveis, onde as primeiras P contabilizam a maior parte da variância do vetor original. Sendo $P \ll K$, torna-se possível desprezar as KP demais, promovendo-se uma redução da dimensionalidade dos dados. As variáveis resultantes correspondem as componentes principais. Geometricamente, os dados passam por um processo de deslocamento e rotação do sistema de coordenadas, através do procedimento de remoção da média de todos os pontos disponíveis, seguido da combinação linear das variáveis originais, para assim, produzir poucos vetores com variâncias não desprezíveis que descrevam a maior parte da variação do conjunto de dados originais. Esses vetores, chamados autovetores, são ordenados de acordo com variabilidade em que representam. A primeira componente principal é o autovetor que corresponde à maior variância, sendo as demais componentes principais ortogonais a

este, ordenados pela direção da maior variância dos resíduos da primeira componente principal. Portanto, as componentes principais não são correlacionados. Dando continuidade ao processo, uma fração significativa da variância dos dados se concentra em um conjunto reduzido de componentes principais ortogonais entre si, podendo-se então desprezar os demais [48].

A Análise de componentes principais possibilita assim, trabalhar com uma quantidade reduzida de variáveis empíricas que, no entanto, preservam a maior parte da variância dos dados originais, sem que seu desenvolvimento requeira um modelo estatístico predeterminado. Apesar das CPs não serem correlacionadas entre si, o que facilita seu processamento, o fato de cada componente principal representar a combinação linear de todas as variáveis originais dificulta a sua interpretação. A análise das componentes principais vem sendo aplicada há décadas a sinais biológicos. Nesse caso, um segmento de sinal com K amostras é interpretado como um único ponto em um espaço K -dimensional, ou de K variáveis [48].

2.4.3 Autovetor e Autovalor

Sendo D a matriz original com dados de N sujeitos representados por K variáveis, e S a matriz de covariância, cujos termos são calculados pela equação:

$$S_{ij} = \frac{1}{N-1} \sum_{k=1}^N (d_{ki} - \bar{d}_i)(d_{kj} - \bar{d}_j) \quad (2.2)$$

onde \bar{d}_j é a média da j -ésima variável dos dados originais, o cálculo dos componentes principais é dado pela seguinte equação:

$$S\vec{v} = \lambda\vec{v} \quad (2.3)$$

onde \vec{v} corresponde ao autovetor, λ ao correspondente autovalor, que representa a variância do componentes principais.

Cada autovalor corresponde à fração de variância representada pelo respectivo autovetor. Sendo assim, a soma de todos os autovalores corresponde à variância total dos dados originais [48].

O autovetor de maior autovalor corresponde ao eixo para o qual os pontos apresentam maior variância, sendo, portanto a primeira componente principal. O segundo maior autovetor corresponde a segunda componente principal, e assim progressivamente [48].

Quando a ACP é aplicada a sinais, os autovetores têm a mesma estrutura temporal dos trechos de sinais originais. Assim, a representação desse vetor como um sinal contribui para a sua interpretação. Cada amostra do autovetor constitui um fator de carga correspondente à amostra do sinal original, com altos fatores de cargas (valores absolutos) sendo relacionados aos trechos de maior variância do sinal original [48].

Os Coeficientes do Componente Principal (CCP) representam a projeção de cada sujeito em cada eixo dos componentes principais. Os CCPs medem a contribuição dos CPs para cada sinal no domínio do tempo, através da transformação da curva original de cada indivíduo em um conjunto de coeficientes [48].

2.4.4 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 [49].

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 [49].

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 [50]. 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:

$$y(k) = a_1y(k-1) + a_2y(k-2) + \dots + a_p y(k-p) + a_t \quad (2.4)$$

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

A utilização do modelo auto regressivo se deve ao fato da necessidade de diminuição do volume de dados a ser trabalhado, uma vez que em processamento de sinais normalmente se encontra um grande volume de dados, logo processos de mineração sem perda de informação fazem-se necessários. Para fins comparativos criou-se modelos auto regressivos que variam desde a primeira até a décima ordem.

2.4.5 Máquinas de Vetor de Suporte

Fundamentada na Teoria da Aprendizagem Estatística, a Máquina de Vetores Suporte, do inglês Support Vector Machine, SVM foi desenvolvida por [51], com o intuito de resolver problemas de classificação de padrões.

A Teoria do Aprendizado Estatístico visa estabelecer condições matemáticas que permitam escolher um classificador, com bom desempenho, para o conjunto de dados disponíveis para treinamento e teste. Em outras palavras esta teoria busca encontrar um classificador levando em consideração todo o conjunto de dados, porém se abstendo de casos particulares, de acordo com [8].

Segundo [8] o desempenho desejado de um classificador f é que o mesmo obtenha o menor erro durante o treinamento, sendo o erro mensurado pelo número de predições incorretas de f . Sendo assim definimos como risco empírico $R_{emp}(f)$, como sendo a medida de perda entre a resposta desejada e a resposta real. A Equação 2.5 mostra a definição de risco empírico.

$$R_{emp}(f) = \frac{1}{n} \sum_{i=1}^n c(f(x_i), y_i) \quad (2.5)$$

Onde $c(\cdot)$ é a função de custo relacionada a previsão $f(x_i)$ com saída desejada y_i , onde um tipo de função de custo é a “perda 0 ou 1” definida pela Equação 2.6. O processo busca por uma função f' que represente um menor valor de R_{emp} é denominado de Minimização do Risco Empírico.

$$c(f(x_i), y_i) = \begin{cases} 1 & \text{se } y_i f(x_i) < 0; \\ 0 & \text{caso contrário} \end{cases} \quad (2.6)$$

Sobre a hipótese de que os padrões de treinamento (x_i, y_i) são gerados por uma distribuição de probabilidades $P(x, y)$ em $\mathbb{R}^N * \{-1, +1\}$ sendo P desconhecida. A probabilidade de classificação incorreta do classificador f é denominada de Risco Fundamental que quantifica a capacidade de generalização, conforme é mostrado na Equação 2.9, conforme [8].

$$R(f) = \int c(f(x_i), y_i) dP(x_i, y_i) \quad (2.7)$$

Durante o processo de treinamento, $R_{emp}(f)$, pode ser facilmente obtido ao contrário de $R(f)$, pois em geral a distribuição de probabilidades P é desconhecida. A partir disto, um dado conjunto de dados de treinamento (x_i, y_i) com $x_i \in \mathbb{R}^N$ e $y_i \in \{-1, +1\}$, $i = \{1, 2, \dots, n\}$, sendo x_i o vetor de entrada e y_i o rótulo da classe [8].

O objetivo então é estimar uma função $f : \mathbb{R}^N \rightarrow \{-1, +1\}$. Caso nenhuma restrição seja imposta na classe de funções em que se escolhe a estimativa f , pode ocorrer que a função obtenha um bom desempenho no conjunto de treinamento, porém não tendo o mesmo desempenho em padrões desconhecidos, sendo este fenômeno denominado de “*overfitting*”. Em outras palavras a minimização apenas do risco empírico não garante uma boa capacidade de generalização, sendo desejado um classificador f^+ tal que $R(f^+) = \min_{f \in F} R(f)$, onde F é o conjunto de funções f possíveis [8].

Segundo [52] 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. A Figura 9 ilustra tais situações.

A não linearidade representa um problema para o processo de classificação, a solução

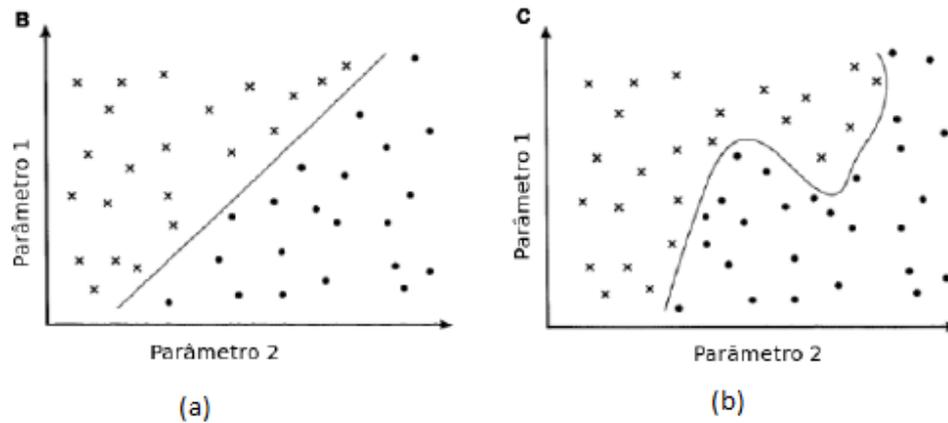


Figura 9: Superfícies de decisão: (a) é linearmente separável e (b) é não linearmente separável [8]

veio a partir do teorema de Cover que afirma que um problema não linear tem maior probabilidade de ser linearmente separável, em um espaço de mais alta dimensionalidade. A partir disso, o SVM não linear realiza uma mudança de dimensionalidade, por meio das funções Kernel, caindo então em um problema de classificação linear, podendo fazer uso do hiperplano [8].

Uma função Kernel recebe dois dados de entrada x_i e x_j e calcula o produto interno destes dados no espaço característico

$$\kappa(x_i, x_j) = (\phi(x_i) * \phi(x_j)) \quad (2.8)$$

Sendo necessário que a função $\phi(\cdot)$ pertença a um domínio, onde seja possível o cálculo do produto interno. Funções estas que satisfazem as condições do Teorema de Mercer. O Teorema de Mercer diz "uma função é dita ser uma função de Kernel, se a matriz κ é positivamente definida", onde κ é obtido por:

$$\kappa = \kappa_{x_j} = \kappa(x_i, x_j) \quad (2.9)$$

A matriz é positivamente definida, se seus autovalores são maiores que zero, logo as funções Kernel que satisfazem as condições do Teorema de Mercer são chamadas de Kernels de Mercer [8].

Durante a realização do trabalho, por caracterizar o problema como linearmente separável, adotou-se a utilização de somente funções Kernel do tipo linear, logo não houve a necessidade por conta do SVM em trabalhar em espaços de alta dimensionalidade.

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 essa propriedade desejável seguindo uma abordagem fundamentada na teoria da aprendizagem estatística. Mais precisamente, a máquina 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 zero para o primeiro termo e minimiza o segundo. Conseqüentemente, 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 [52].

Uma noção que é a 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) [52]:

- Máquinas de aprendizagem polinomial;
- Redes de função 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 [52].

2.5 Validação cruzada

A validação cruzada é uma ferramenta padrão para análise e é um importante recurso para ajudar a desenvolver e ajustar os modelos de mineração de dados. Você utiliza a validação cruzada depois de criar uma estrutura de mineração e os modelos de mineração relacionados para assegurar a validade do modelo [53].

O método de validação cruzada utilizado foi o método denominado k-partições (do inglês k-fold cross-validation). Realiza-se aqui a divisão do conjunto total de amostras em k partições sendo que (k-1) delas serão usadas para compor o subconjunto de treinamento, ao passo que a partição restante constituirá o subconjunto de teste, conforme [54].

Por conseguinte, o processo de aprendizado se repete k vezes até que todas as partições tenham sido utilizadas como subconjunto de teste. O valor do parâmetro k está atrelado à quantidade total de amostras disponíveis. O desempenho global de cada topologia candidata será agora também obtido em função da média entre os desempenhos individuais observados quando da aplicação das k partições [54].

3 *Resultados e Discussões*

Neste capítulo serão mostrados os resultados das duas distintas abordagens realizadas para com a utilização do SVM como classificador de padrões. A primeira, avaliou-se o classificador SVM para um conjunto de dados de 28 amostras de diferentes voluntários e com mesmas combinações de frequências moduladora e portadora. Em um segundo momento avaliou-se um classificador SVM com 228 amostras, obtidas a partir de diferentes voluntários e diferentes combinações de frequências moduladoras e portadoras. Nesses classificadores avaliou-se a capacidade de detectar através do conjunto de dados se o indivíduo está prestando atenção no estímulo gerado do lado esquerdo ou direito.

3.1 *Sinais Coletados*

Posteriormente a coleta do EEG, têm-se todo um processo computacional de filtragem. Tal filtragem consiste em filtrar a frequência da rede (60 Hz) do local do experimento, isso se deve ao fato de durante o processo de aquisição o filtro *Notch* do *BraiNet* estar inoperante, uma vez que a faixa de corte desse filtro engloba as frequências utilizadas no trabalho. Logo a retirada da componente da rede do espectro de frequências é feito a partir de filtros digitais.

Com o intuito de minimizar o aparecimento de frequência indesejadas é realizado uma filtragem para a remoção de artefatos. Os canais escolhidos para a filtragem são os que ficam mais próximos do centro superior da cabeça, ou seja, os eletrodos Cz, Fz, Pz, F3, C3, P3, F4, C4 e P4.

Sequencialmente têm-se a mineração dos dados a partir da utilização das PCA's e em a criação dos vários modelos AR, onde a partir dos coeficientes do modelo AR tem-se os vetores de entrada do SVM. Utilizando-se do método da PCA que consiste na reorganização dos dados de forma mais representativa, pode-se a partir da análise da Figura 10, que representa a variância por componente principal e a variância acumulada das PCA's, perceber que com as 4 primeiras componentes principais tem-se pelo menos

90% dos dados iniciais.

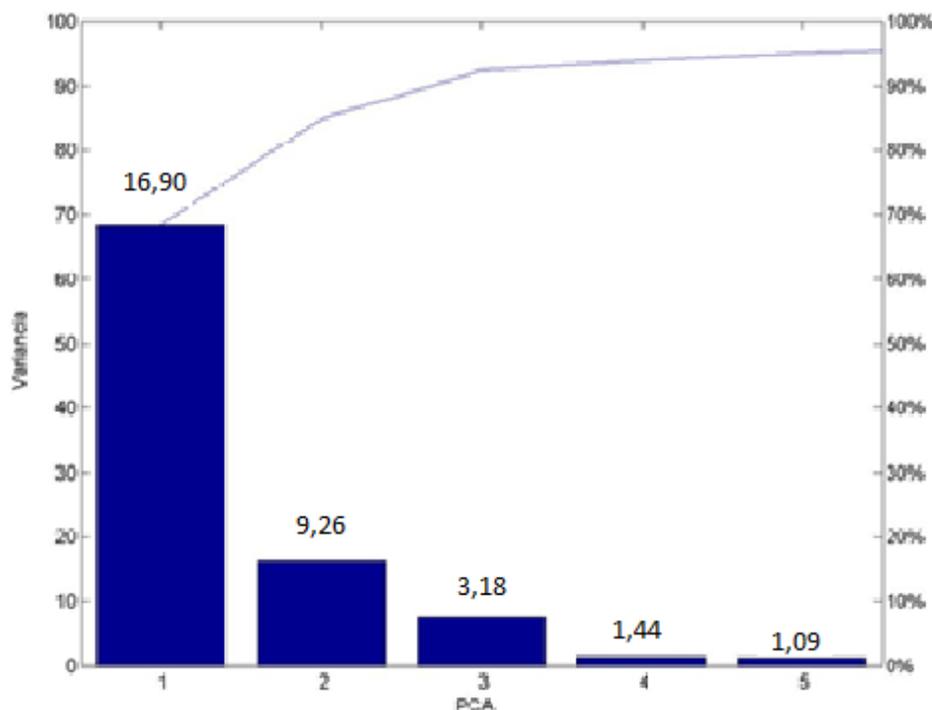


Figura 10: Gráfico da variância e desvio padrão por componente principal e da variância acumulada.

Sobre cada barra representada no gráfico encontra-se o respectivo desvio padrão para a cada componente em relação ao total de exames.

3.2 Classificador SVM

Os sinais foram distribuídos em classes de acordo com os exames, as duas classes criadas foram *Esquerda e Direita* fazendo menção a atenção dada no instante do registro. Como o SVM é um classificador binário o que facilitou o método de classificação uma vez que trabalhou-se com apenas duas classes. Durante o processo de classificação, variou-se o conjunto de dados que compunham o conjunto de validação e treinamento, o número de canais utilizados para fornecer as informações coletadas no EEG, a ordem do modelo AR e o número de componentes principais. Essas variações têm como objetivo observar o comportamento de generalização do SVM.

Buscando uma análise mais vasta analisou-se as taxas de acerto percentual para todas as combinações de frequências no conjunto de amostras, na Tabela 3 estão ilustradas as maiores taxas de acerto para cada combinação e também a devida composição do SVM, dentro de cada chave está indicado a ordem do modelo AR e o número de componentes

principais respectivamente, tendo assim uma ampla análise dos resultados obtidos com tais combinações.

Tabela 3: Resultados obtidos na classificação do SVM para todas as combinações de frequência moduladora e portadora separadamente, a partir das variações do número de componentes principais e a ordem do modelo AR, utilizando-se todos os canais do EEG 30% dos dados para validação

taxa acerto {PCA AR}		
Moduladora	Portadora	
	500/1000	500/2000
32/36	100 {1,6}	100 {2,6}
32/38	100 {4,10}	100 {1,5}
32/41	100 {2,6}	100 {3,9}
34/38	100 {4,1}	100 {4,10}
34/41	100 {4,6}	75 {3,5}
36/41	75 {4,4}	100 {4,10}
38/41	100 {3,1}	75 {4,10}

Algumas particularidades podem ser observadas, em primeiro momento é notável que as taxas de acerto do classificador SVM considerando o processo de classificação em indivíduos dentro de um mesmo padrão é bastante constante, obtendo-se resultados sem muita variações conforme expresso na Tabela 3. Posteriormente vale ressaltar algumas tendências observadas durante o processo de validação. Considerando apenas as situações onde a taxa de acerto foi à máxima da classe tem-se que:

- A máquina de vetores de suporte que mais vezes atingiu o nível de acerto máximo era composta por 4 componentes principais e um modelo auto regressivo de ordem 10;
- As máquinas de vetores de suporte com quatro componentes principais apresentam um resultado melhor que as demais, concentrando-se nelas a maior quantidade de acertos máximos;
- As máquinas de vetores de suporte compostas por modelos AR de ordem 6 apresentam um maior nível de acerto máximo quando comparado as demais.

Em especial analisou-se a combinação moduladora (32/38) e portadora (500/2000) da Tabela 3, que segundo [46] representa a melhor combinação de frequências, sendo ela composta por 28 exames de 14 voluntários distintos.

Na Tabela 4 observa-se os resultados obtidos utilizando-se 30% dos dados para validação, variando-se a ordem do modelo AR, o número de componentes principais e utilizando-se apenas 7 canais do EEG (F3, P3, O1, T4, P4, O2 e Fz) os quais representaram a combinação com melhor resposta de acordo com [46].

Tabela 4: Resultados obtidos na classificação do SVM para apenas para a combinação de frequência moduladora (32/38) e portadora (500/2000) a partir das variações do número de componentes principais, da ordem do modelo AR, utilizando-se apenas os canais (F3, P3, O1, T4, P4, O2 e Fz) do EEG e 30% dos dados para validação.

Ordem AR	Taxa acerto(%)			
	Número de componentes principais			
	1	2	3	4
1 ^a	50	75	75	75
2 ^a	50	75	75	75
3 ^a	50	75	75	50
4 ^a	50	75	100	75
5 ^a	100	100	100	100
6 ^a	100	100	100	75
7 ^a	75	100	100	100
8 ^a	75	100	100	75
9 ^a	75	75	75	75
10 ^a	50	75	100	50

A partir da análise da Tabela 4 pode-se perceber uma a capacidade de generalização tendo em certas combinações de parâmetros 100% de acerto durante o processo de validação.

A Tabela 5 apresenta o resultado obtido a partir dos mesmo parâmetros, entretanto utilizando todos os canais do EEG o que tem por finalidade verificar se há a aquisição de dados que realmente não contenham informações relevantes a classificação, levando talvez a alterar a capacidade de classificação da máquina.

Pela análise da Tabela 5, observa-se que realmente utilizando-se todos os canais do EEG ocorre uma redução na taxa de acerto, o que se conclui que a introdução de toda essa informação prejudica no poder de decisão da máquina, dificultando o processo de aprendizagem e conseqüentemente a classificação, logo a seleção dos canais utilizados representa um artifício válido nesse tipo de análise.

Uma constatação importante a se fazer que em ambas as situações o classificador trabalhando com um modelo AR de ordem 5 obteve as melhores taxas de acerto, considerando esse contexto experimental.

Tabela 5: Resultados obtidos na classificação do SVM para apenas para a combinação de frequência moduladora (32/38) e portadora (500/2000) a partir das variações do número de componentes principais e da ordem do modelo AR, utilizando-se todos os canais do EEG e 30% dos dados para validação.

Ordem AR	Taxa acerto(%)			
	Número de componentes principais			
	1	2	3	4
1 ^a	50	50	50	50
2 ^a	25	50	50	50
3 ^a	50	50	50	50
4 ^a	25	50	75	50
5 ^a	100	75	75	75
6 ^a	50	50	50	50
7 ^a	50	50	50	50
8 ^a	75	75	50	50
9 ^a	75	75	50	50
10 ^a	25	50	50	75

Nesse momento fez-se uma abordagem do classificador SVM avaliando-se nesta situação o caso em que foram utilizados os 240 exames disponíveis para análise. Esses exames possuem diferentes frequências portadoras e moduladoras. Tal situação tenta mostrar a capacidade de generalização do SVM ao trabalhar com um grande número de parâmetros e com tantas variáveis a serem analisadas.

Durante o processo de classificação, variou-se o número de canais utilizados para fornecer as informações coletadas no EEG, a ordem do modelo AR e o número de componentes principais. Essas variações têm como objetivo observar o comportamento de generalização do SVM.

Na Tabela 6 mostra os resultados obtidos utilizando-se 30% dos dados para validação, variando-se a ordem do modelo AR, o número de componentes principais e utilizando-se apenas 7 canais do EEG (F3, P3, O1, T4, P4, O2 e Fz).

Pela análise da Tabela 6 nota-se que o processo de classificação torna-se difícil considerando um grande espaço amostral, entretanto um fator decisivo que possa justificar esse baixo índice de acerto pode estar diretamente ligado ao fato de existir exames com diferentes combinações de frequências o que seria um agravante durante o processo de aprendizagem.

A Tabela 7 mostra os resultados obtidos utilizando os mesmos parâmetros descritos anteriormente, entretanto utilizando-se de todos os canais do EEG, verificando assim a

Tabela 6: Resultados obtidos na classificação do SVM para todo o conjunto de dados a partir das variações do número de componentes principais e da ordem do modelo AR, utilizando-se apenas os canais (F3, P3, O1, T4, P4, O2 e Fz) do EEG e 30% dos dados para validação.

Ordem AR	Taxa acerto(%)			
	Número de componentes principais			
	1	2	3	4
1 ^a	53,03	53,03	53,03	53,03
2 ^a	56,06	57,58	50	51,52
3 ^a	51,52	63,64	50	50
4 ^a	50	50	50	53,03
5 ^a	60,61	50	50	53,03
6 ^a	48,48	63,64	72,73	62,12
7 ^a	56,06	56,06	51,52	50
8 ^a	53,03	53,03	51,52	50
9 ^a	48,48	57,58	50	58
10 ^a	48,48	51,52	50	50

Tabela 7: Resultados obtidos na classificação do SVM para todo o conjunto de dados a partir das variações do número de componentes principais e da ordem do modelo AR, utilizando-se todos os canais do EEG e 30% dos dados para validação.

Ordem AR	Taxa acerto(%)			
	Número de componentes principais			
	1	2	3	4
1 ^a	50	51,52	51,52	53,03
2 ^a	45,45	53,03	54,55	46,97
3 ^a	42,42	51,52	51,52	50
4 ^a	50	50	48,48	45,45
5 ^a	53,03	50	50	50
6 ^a	48,48	57,58	50	50
7 ^a	50	53,03	53,03	50
8 ^a	53,03	50	51,52	50
9 ^a	48,48	50	50	45,45
10 ^a	51,52	46,97	56,06	51,52

influência na capacidade de generalização quando se usa um maior volume de informações durante o processo de aprendizagem.

Analisando a Tabela 6 percebe-se que a maior taxa de acerto é de 72,73%, já na Tabela 7 a maior taxa de acerto foi de 57,58%, se comparados aos valores máximos encontrados, observa-se que realmente quanto maior a quantidade de parâmetros de entrada maior é a dificuldade de generalização e conseqüentemente a capacidade de classificação.

Uma observação a ser feita que conforme o aumento nos parâmetros de entrada,

nessa situação, maior a quantidade de dados fornecidos a máquina, pior foi tendendo a sua capacidade de classificação, entretanto é notável que mesmo que trabalhando com um conjunto grande de dados e com características diferentes, se utilizados os artifícios corretos é possível obter padrões de classificação relevantes, conforme foi observado no processo de classificação para grupos de mesma frequências portadoras e moduladoras.

Além da própria dificuldade de classificação por parte de erros durante o processamento e aprendizagem alguns outros fatores podem ter contribuído para dificultar ainda mais o processo, tais fatores podem ser inerentes do processo de aquisição de dados como, por exemplo:

- A duração de tempo dos estímulos, pois nem todas as pessoas começam a responder a estímulos no mesmo instante, algumas necessitam de um tempo maior para apresentar resposta;
- Estes indivíduos podem apresentar algum distúrbio de atenção, o que os impediu focar atenção nos estímulos;
- Pode-se ter cometido algum erro durante a coleta dos dados, como por exemplo, eletrodos mal conectados ao couro cabeludo;
- Os indivíduos poderiam estar em estado de sonolência durante a coleta, o que enfraqueceu a amplitude de resposta.

Talvez uma etapa de treinamento pudesse melhorar o desempenho das respostas dos indivíduos aos estímulos e conseqüentemente a qualidade do sinal adquirido, o que poderia refletir posteriormente numa melhor resposta ao processo de classificação. Sendo este treinamento constituído de uma série de repetições do procedimento. Onde o indivíduo que a ele estivesse submetido, ao longo das várias repetições, seria capaz e hábil a realizar o experimento sem qualquer instrução.

4 *Conclusões*

Ao final deste trabalho, pode-se fazer algumas observações pertinentes acerca das máquinas de vetor de suporte sobre principalmente a sua capacidade de generalização, os métodos usados durante o processo de aprendizado e inferir sobre o desempenho de classificação para problemas com muitas variáveis.

A análise seguiu um caminho visando mostrar a capacidade da SVM em trabalhar com um problema de classificação binário, variando os parâmetros de entrada, acarretando assim diferentes quantidades de dados usados durante a classificação, esse método foi escolhido a fim de testar a eficácia do processo de classificação quando utiliza-se essa ferramenta como solução.

No primeiro momento fez-se uma classificação entre grupos que apresentavam mesma frequência portadora e moduladora, utilizando sempre 30% dos dados para a validação. Tentou-se realizar a avaliação da atenção seletiva, nesse caso diferenciar se o paciente estava focando a atenção ao estímulo direito ou esquerdo. Para essa configuração em muitas combinações obteve-se taxas de acertos de 100% evidenciando um real poder de decisão da máquina e conseqüentemente a capacidade de separação dos dados. Pode-se perceber que a máquina com maior repetição em taxas de acertos máximas foi um SVM composto pela utilização de 4 componentes principais e um modelo auto regressivo de ordem 10, o que representa o caso com a maior quantidade de dados de entrada, tal fato mostra que o SVM consegue assimilar e generalizar grandes quantidades de dados. Em especial a ordem que concentrou a maior quantidade de acertos máximos foi a sexta ordem, independente do número de componentes principais. As Máquinas compostas por quatro componentes principais foram as que concentraram a maior quantidade de acertos máximos, independente da ordem do modelo auto regressivo.

Em especial analisou-se a combinação de (32/38) para as frequências moduladoras e (500/2000) para frequências portadoras, tal combinação foi escolhida principalmente por representar o maior conjunto amostral. Durante a análise a fim de tentar realizar uma

mineração dos dados fez-se uma escolha de analisar o sinal coletado por 7 eletrodos conforme definido por [46], tal técnica reduziria a quantidade de dados e descartaria informações irrelevantes para a classificação, o resultado pode ser observado na Tabela 4 onde nota-se que para diferentes configurações do SVM obteve-se taxas de acertos iguais a 100%. Já para a situação onde usou todos os eletrodos do EEG, seguindo o mesmo procedimento de aquisição e processamento, apenas a configuração de uma componente principal e modelo AR de ordem 5 acertaram todos os exames do grupo de validação conforme expresso na Tabela 5, o que evidencia que realmente durante o processo de aquisição dos sinais coletava-se muita informação irrelevante para o processo de classificação, levando até a confundir a decisão da máquina.

O mesmo procedimento foi feito, entretanto nessa situação todos os 240 exames foram utilizados. Novamente selecionou-se os canais utilizados e os resultados foram expressos na Tabela 6 nota-se que a taxa máxima de acerto foi de 72,73% para um SVM com três componentes principais e modelo AR de ordem 6 o que foi um pouco menor se comparado com a situação com apenas uma combinação de frequências. Já para o caso em que utilizou-se todos os eletrodos a melhor taxa de acerto foi de 57,58% para um SVM composto por duas componentes principais e modelo AR de ordem 6, foi também menor quando comparado a situação com apenas uma combinação de frequências.

Conclui-se assim, que em ambos os casos a abordagem que utiliza apenas os 7 canais do EEG mostrou-se mais eficiente e que processos de classificação com uma grande quantidade de dados pode ocasionar erros indesejados durante o processo de aprendizado e consequentemente uma decisão errada por parte da máquina, levando a taxa de acertos inferiores.

Como estudo futuro deve-se:

- Implementar ferramentas que facilitem o aprendizado da máquina;
- Desenvolver um classificador SVM que funcione online, ou seja, tente informar em tempo real qual a situação do paciente onde seria feita a avaliação de que em qual estímulo sonoro ele estaria prestando a atenção;

Referências

- [1] STRES'SNET. *O aparelho auditivo*. 2014. Disponível em: <<http://musicaeadoracao.com.br/55785/o-aparelho-auditivo/>>.
- [2] BRAINCONNECTION. *Sistema Auditivo*. 2012. Disponível em: <http://dc387.4shared.com/doc/mC3_FpeN/preview.html>.
- [3] NICACIO, L. R. *Investigação da atenção seletiva auditiva para interface cérebro-computador usando magnitude quadrática de coerência*. Viçosa, Minas Gerais, 2011.
- [4] ETYMOTIC. *Insert Earphones For Audiometry*. 2000. Disponível em: <<http://www.etymotic.com/pro/er5a-acc.aspx>>.
- [5] PEDROSA, M. J. S.; DOURADO, D. M.; FELIX, L. B. Investigação da atenção seletiva auditiva usando máquinas de vetor de suporte e redes neurais artificiais. *Anais do XIX Congresso Brasileiro de Automática, CBA.*, v. 19, p. 1371–1377, 2012.
- [6] NEUROSCIENZE. *Sistema Internacional 10-20*. 2012. Disponível em: <<http://it.wikipedia.org/wiki/Portale:Neuroscienze>>.
- [7] LYNX. *Equipamentos Médicos*. 2012. Disponível em: <<http://www.lynxtec.com.br/medica.htm>>.
- [8] RICARDO, A. G. *Máquinas de Vetores de Suporte*. Dissertação (Mestrado) — UNICAMP, 2008.
- [9] SABBATINI, R. M. *Mapeando o cérebro*. São Paulo: Cérebro & Mente, 1997.
- [10] KOZMA, R.; FREEMAN, W. J. Classification of eeg patterns using nonlinear neurodynamics and chaos. *IEEE Trans. Biomed. Eng.*, v. 44, p. 1107–1112, 2002.
- [11] CHIAPPA, K. H. *Evoked Potentials in Clinical Medicine*. Londres: Raven Press, 1997.
- [12] DIMITRIJEVIC, A. et al. Estimating the audiogram using multiple auditory steady-state response. *J. Am. Acad. Audiol.*, v. 13, p. 205–224, 2002.
- [13] SCHWARTZ, M. L. et al. Somatosensory evoked potential monitoring during carotid surgery. *Cardiovascular Surgery*, v. 4, p. 77–80, 1996.
- [14] CELESIA, G. *Visual evoked potentials and electroencephalograms*. New York: Niedermeyer, 1998.
- [15] KUWADA, S.; BATRA, R.; MAHER, V. I. Scalp potentials of normal and hearing-impaired subjects in response to sinusoidally amplitude modulated tones. *US National Library of Medicine National Institutes of Health*, v. 21, p. 179–192, 1986.

- [16] DOLPHIN, W. F.; MOUNTAIN, D. C. The envelope following response, scalp potentials elicited in the mongolian gerbil using sinusoidally am acoustic signals. *Hearing Research*, v. 58, p. 70–78, 1992.
- [17] JORIS, P. X.; SCHREINER, C. E.; REES, A. Neural processing of amplitude modulated sounds. *Physiol*, v. 84, p. 541–577, 2004.
- [18] COHEN, L. T.; RICKARDS, F. W.; CLARK, G. M. A comparison of steady-state evoked potentials to modulated tones in awake and sleeping humans. *J. Acoust. Soc. Am*, v. 5, p. 2467–2479, 1991.
- [19] LEVI, E. C.; FOLSON, R. C.; DOBIE, R. A. Amplitude modulation following response (amfr) - effects of modulation rate, carrier frequency, age and state. *Hearing Research*, v. 68, p. 42–52, 1993.
- [20] GALAMBOS, R.; MAKEIG, S.; TALMACHOFF, P. J. A 40 hz auditory potential recorded from the human scalp. *P. Natl. Acad. Sci-Biol.*, v. 4, p. 2643–2647, 1981.
- [21] LINDEN, R. D. et al. Human auditory steady-state potentials during sleep. *Hearing Research*, v. 1, p. 167–174, 1985.
- [22] STAPELSS, D. R. et al. Inconsistency of auditory middle latency and steady-stae responses in infants. *Electroenceph. Clin. Neurophysiol*, v. 4, p. 289–295, 1988.
- [23] PLOURDE, G.; PICTON, T. W. Human auditory steady-state response during general anesthesia. *Anesth. Analg*, v. 5, p. 460–468, 1990.
- [24] JOHN, M. S. et al. Multiple auditory steady-state responses (master): Stimulus and recording parameters. *Audiology*, v. 1, p. 59–82, 1998.
- [25] AOYAGI, M. et al. Optimal modulation frequency for amplitude modulation following response in young children during sleep. *Hearing Research*, v. 1, p. 253–261, 1993.
- [26] RICKARDS, F. W. et al. Auditory steady-state evoked potential in newborns. *Brit. J. Audiol*, v. 6, p. 327–337, 1994.
- [27] LINDEN, R. D. et al. Human auditory steady-state evoked potenciales during selective attention. *Electroencephalogr Clin Neurophysiol*, v. 1, p. 145–159, 1987.
- [28] TIITINEN, H. T. et al. Selective attention enhances the auditory 40-hz transient response in humans. *Nature*, v. 1, p. 59–60, 1993.
- [29] ROSS, B. et al. The effect of attention on the auditory steady-state response. *Neurology and Clinical Neurophysiology*, v. 22, p. 1–4, 2004.
- [30] ROSS, B. et al. N. birbaumer and a. kubler and n. ghanayim and t. hinterberger and j. perelmouter and j. kaiser and i. iversen and b. kotchoubey and n. neumann and h. flor. *IEEE Transactions on Rehabilitation Engineering*, v. 8, p. 190–193, 2000.
- [31] WOLPAW, J. R. et al. Brain-computer interfaces for communication and control. *Clinical Neurophysiology*, v. 113, p. 767–791, 2002.

- [32] KUBLER, A. et al. Brain-computer communication: self-regulation of slow cortical potentials for verbal communication. *Arch Phys Med*, v. 82, p. 1539–1555, 2001.
- [33] DONCHIN, E.; SPENCER, K. M.; WIJESHINGLE, R. The mental prosthesis: Assessing the speed of a p300-based brain-computer interface. *IEEE Transactions on Rehabilitation Engineering*, v. 8, p. 174–179, 2000.
- [34] RIGGS, L. A. et al. The disappearance of steadily fixated visual test objects. *Journal of the Optical Society of America*, v. 6, p. 495–501, 1953.
- [35] HILLYARD, S. A. et al. Electrical signs of selective attention in the human brain. *Science*, v. 182, p. 174–179, 1973.
- [36] SOUZA, M. L. *Cérebro humano*. 2012. Disponível em: <http://pt.wikipedia.org/wiki/Cérebro_humano>.
- [37] TEIXEIRA, C. *Os Lobos Cerebrais*. 2008. Disponível em: <<http://psinet12ab.blogspot.com/2008/01/os-lobos-cerebrais.html>>.
- [38] FRANCISCO, P. S. *Audição*. 2010. Disponível em: <<http://www.portalsaofrancisco.com.br/alfa/corpo-humano-sistema-sensorial/audicao-18.php>>.
- [39] GINSBERG, I. A.; WHILE, T. P. *Considerações otológicas em audiologia*. Berlim: Ed. Manole Ltda, 1999.
- [40] FELIX, L. B. *Detecção objetiva de respostas auditivas em regime permanente: aplicação em exames audiológicos*. Tese (Doutorado) — UFMG, Belo Horizonte, MG, 2006.
- [41] GEISLER, C. D. Coding of acoustic signals on the auditory nerve. *IEEE Engineering in Medicine and Biology Magazine*, v. 6, p. 22–28, 1987.
- [42] PARKINS, C. W. Cochlear implant: a sensory prosthesis frontier. *IEEE Engineering in Medicine and Biology Magazine*, v. 2, p. 18–26, 1983.
- [43] FERREIRA, A. C. F. *Investigação da atenção seletiva auditiva para interface cérebro-computador usando máquinas de vetor de suporte*. Viçosa, Minas Gerais, 2011.
- [44] ROSS, B.; DRAGANOVA, R.; PICTON, T. W. Frequency specificity of 40-hz auditory steadystate response. *Hearing Research*, 2003.
- [45] KIM, D. W.; HWANG, H. J.; LIM, J. H. Classification of selective attention to auditory stimuli: Toward vision-free brain computer interfacing. p. 180–185, 2011.
- [46] RANAUDO, F. S. *Sistema de reconhecimento de locutor utilizando redes neurais artificiais*. Dissertação (Mestrado) — COPPE, Universidade Federal do Rio de Janeiro, 2010.
- [47] 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, p. 1593–1603, 2006.

-
- [48] RENATA, G. *Análise de componentes principais da iniciação da marcha em pacientes com síndrome de Parkinson*. Dissertação (Mestrado) — COPPE - Universidade Federal do Rio de Janeiro, 2012.
- [49] AGUIRRE, L. A. *Introdução à identificação de sistemas, Técnicas lineares e não-lineares aplicadas a sistemas reais*. Belo Horizonte: Ed. UFMG, 2004.
- [50] SILVA, J. R. S. Estudo das variações sazonais de hotéis de aracaju. *Encontro Regional de Matemática Aplicada e Computacional*, 2008.
- [51] VAPNIK, V. *the nature of statistical learning theory*. Moscow: Springer-Verlag, 1995.
- [52] HAYKIN, S. *Sinais e Sistemas*. Ottawa: Ed. Bookman, 2002.
- [53] VIADAURRE, C. Fully online adaptive bci. *IEEE Trans. Biomed. Eng.*, v. 53, p. 1214–1219, 2006.
- [54] SILVA, I. N. *Redes Neurais Artificiais para engenharia e ciências aplicadas*. São Paulo: Artliber, 2010.