

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

JASON BARBOSA CARDOSO

**MÁQUINA DE VETORES DE SUPORTE PARA
CLASSIFICAÇÃO DA ATENÇÃO SELETIVA
AUDITIVA - APLICAÇÃO EM INTERFACE
CÉREBRO-COMPUTADOR**

**VIÇOSA
2013**

JASON BARBOSA CARDOSO

**MÁQUINA DE VETORES DE SUPORTE PARA
CLASSIFICAÇÃO DA ATENÇÃO SELETIVA
AUDITIVA - APLICAÇÃO EM INTERFACE
CÉREBRO-COMPUTADOR**

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
2013

JASON BARBOSA CARDOSO

**MÁQUINA DE VETORES DE SUPORTE PARA CLASSIFICAÇÃO
DA ATENÇÃO SELETIVA AUDITIVA - APLICAÇÃO EM
INTERFACE CÉREBRO-COMPUTADOR**

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 Agosto de 2013.

COMISSÃO EXAMINADORA

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

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

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

Dedico ao meu Pai Antônio e minha Mãe Socorro e minhas Irmãs, pelo apoio e força dedicados a mim.

Agradecimentos

Quero agradecer primeiramente e eternamente aos meus pais Antônio e Socorro por ter me dado essa oportunidade de poder realizar um sonho, sempre estiveram comigo me apoiando, às vezes deixando seus desejos para depois, obrigado pai e mãe por ter depositado em mim suas confianças serei grato sempre a vocês. Amo vocês!!

Por sempre estarem ao meu lado agradeço as minhas irmãs Lauri e Nininha, por estarem me incentivando e não me deixando em momento algum fraquejar perante as dificuldades por mim encontradas. Meu muito obrigado amo vocês tb, quero lembrar da minha sobrinha Lauren por me proporcionar muitos momentos de alegria.

Agradeço ao Prof. Bonato por ter me oferecido essa oportunidade de poder está adquirindo conhecimentos, os quais carregarei sempre comigo. Valeu por ter confiado em mim e acreditar que seria possível realizar esse trabalho. Agradeço ao Fernando (Drepa) e meu grande amigo Tião por ter me ajudado muito nessa empreitada, foram muito importante, principalmente, sanando minhas dúvidas.

Quero agradecer imensamente aos meu familiares tias, primos e meus queridos Avôs Carmelita, Seu João, Tercília (in memoria) e Raimundo (in memória) por terem me ajudado nessa caminhada, que foi muito difícil chegar até aqui, valeu pelo apoio

Quero agradecer o pessoal da república o Chico, vulgo chico doido, a Filipim vulgo Zé da Pedra, Júlio vulgo grilo e Diego vulgo Tião do canavial, muito obrigado por dar muitas alegrias nas festança, nos estudos em tudo de bom que passamos esses anos juntos. Valeu galera, juntos formamos uma familia muito bom ter vocês como amigos.

Agradeço o pessoal do Gesep em especial o Heverton e Allan (Crazy) por ter me oferecido mais um caminho para eu poder adquirir mais conhecimento e vivencia de vida. Valeu galera da pelada pelos momentos de descontração, valeu Higor (Careca), grande amigo, por tá sempre me incentivando a ir.

E agradeço a CNPq pelo apoio financeiro concedido, sem o qual esta pesquisa não teria sido possível.

"Nas grandes batalhas da vida, o primeiro passo para a vitória é o desejo de vencer!"

Mahatma Gandhi

Resumo

Aqui se deve inserir uma breve descrição sobre o trabalho a ser desenvolvido, apresentando o tema, os objetivos, o caminho adotado para alcançá-los, os resultados obtidos e as conclusões pertinentes.

Abstract

Here the author should insert a brief description of the work to be developed, the theme, the objectives, the way taken to achieve them, the results and relevant conclusions.

Sumário

Lista de Figuras

Lista de Tabelas

1	Introdução	11
1.1	Revisão Bibliográfica	13
1.1.1	Respostas Evocadas	13
1.1.2	Potencial Evocado Auditivo (PEA)	14
1.1.3	Respostas Evocadas em Regime Permanente (ASSR)	14
1.1.4	Interface Cérebro Computador	15
1.1.5	Fisiologia do Ouvido Humano	17
1.2	Objetivo Geral	19
2	Materiais e Métodos	20
2.1	Aquisição de Sinais	20
2.2	Estimulação para Coleta de Dados	22
2.3	Pré-Processamento	25
2.4	Análise de Componente Principal	26
2.5	Modelo AR (Autorregressivo)	27
2.6	Máquina de Vetor de Suporte (SVM)	28
2.7	Processamento <i>Online</i>	31
3	Resultados e Discussões	34

3.1	Resultado para o classificador <i>Offline</i>	34
4	Conclusões	36
4.1	Trabalhos Futuros	36
	Referências	37

Lista de Figuras

1	Primeiro EEG do Berger em 1929	11
2	Gráfica para a resolução espacial e temporal para técnicas não invasiva.	16
3	Representação das partes do ouvido humano.	17
4	Membrana Basilar.	18
5	Córtex auditivo do ser humano, o córtex auditivo (3) localiza-se na parte pósterosuperior do lobo temporal (2), no interior do sulco lateral (1). [1]	19
6	Cada etapa que ocorre para o reconhecimento de padrão.	20
7	Representação do sistema 10-20.	21
8	Representação do sistema 10-20.	22
9	Interface para geração do sinal audiométrico.	23
10	Fone de inserção E-A-RTone 5A.	24
11	Linha do tempo para o estímulo do exame.	25
12	Indução de classificador em aprendizado supervisionado.	29
13	Indução de classificador em aprendizado supervisionado.	32
14	Figura 1- melhor treinamento, com PCA=4 e AR=5.	35

Lista de Tabelas

1	Algumas funções Kernel.	31
---	---------------------------------	----

1 *Introdução*

Em 1929, um psiquiatra alemão chamado Hans Berger, percebeu que era possível registrar as fracas correntes elétricas geradas no cérebro humano, sem a necessidade de abrir o crânio, e mostrá-las na forma de um registro em papel, e o mesmo denominou essa forma de registro de eletroencefalograma (EEG). Na Figura 1 pode notar o primeiro EEG feito por Berger. No entanto com este método não era possível discernir qual área do cérebro era ativada, devido o tamanho dos eletrodos, serem grandes. Mas no ano de 1936 um cientista britânico, W. Gray Walter conseguiu provar que se fosse usado um grande número de eletrodos pequenos colocados sobre a pele da cabeça, era possível identificar atividade elétrica normal e anormal em determinadas áreas do cérebro. Entusiasmado Gray inventou um toposcópio, um equipamento constituído por um conjunto de tubo de raios catódicos, cada um deles ligados por eletrodos a certa região da cabeça, e cada um desses tubos mostrava em sua tela a intensidade e a velocidade do EEG num região específica, com isso ele esperava gerar mapas bidimensionais de atividades de EEG na superfície do cérebro. Uma conclusão que os neurologistas chegaram que este aparelho era valioso para localizar focos epiléticos.

Desde o seu início até pouco tempo atrás, o estudo topográfico da atividade elétrica cerebral ficou estagnada, e somente veio a renascer quando mini- e microcomputadores pequenos, rápidos e baratos se tornaram disponíveis na década dos anos 80. Desta forma a topografia cerebral do EEG foi desenvolvida, e está desfrutando de grande utilização.



Figura 1: Primeiro EEG do Berger em 1929

Até então os EEGs registravam as atividades espontâneas do cérebro, ainda não era possível estudar fenômenos elétricos mais sutis, mas com o avanço da tecnologia os estudos dos potenciais evocados avançaram. Potenciais evocados são sinais elétricos característicos que ocorrem devido a estímulos específicos, eles são classificados quanto ao estímulo, que pode ser visual, auditivo ou sensorial. Não era possível detectá-los porque as atividades espontâneas os mascaravam, mas por volta de 1950 os primeiros registros de potenciais evocados foram percebidos por George Dawson, aplicando estimulações motoras e registrando a atividade elétrica sobre o córtex somatossensitivo. Os computadores ainda não eram acessíveis então ele desenvolveu um equipamento eletromecânico, chamado promediador [2], que tirava a média de sucessivos EEGs obtidos em resposta a um determinado estímulo, a média das variações espontâneas tendia à zero, sendo possível observar o potencial cortical relacionado ao estímulo [3].

Os Potenciais Evocados Auditivos (PEA), ou seja, as respostas desencadeadas pelo sistema nervoso em função de uma estimulação sonora podem ser classificados como transitórios ou de regime permanente de acordo com o tipo de estímulo utilizado [4]. Os PEA transitórios são obtidos com estímulos de curta duração quando apresentados em intervalos de tempo suficientes para que a resposta ocorra sem que haja sobreposição com a resposta ao estímulo anterior. Na clínica médica, este tipo de PEA é utilizado em um exame chamado *Brainstem Evoked Response Audiometry* (BERA), cujo principal objetivo é fazer uma avaliação geral dos limiares auditivos dos indivíduos [5].

As Respostas Auditivas de Regime Permanente (ASSR ou *Auditory Steady State Responses*) podem ser gravadas a partir do escalpo humano quando um som é apresentado a uma taxa suficientemente elevada, de modo que a resposta a qualquer som se sobrepõe a resposta ao estímulo sonoro anterior [6].

Um sinal modulado em amplitude (AM), aplicado ao ouvido humano como estímulo sonoro, evoca uma resposta em regime permanente. A ASSR evocada por tom AM é caracterizada por um aumento de energia na frequência da moduladora no espectro de potência do sinal registrado [5], [6].

As respostas evocadas, quando comparadas ao EEG de fundo, apresentam níveis de amplitude bem inferiores, o que torna difícil a avaliação da presença de resposta por uma simples inspeção visual do sinal no domínio do tempo. Por isso, técnicas de detecção objetiva de respostas (do inglês, *Objective Response Detection* ou ORD) [7], que são ferramentas de detecção automáticas precisam ser desenvolvidas para automatizar o processo de identificação de respostas a estímulos e lidar com a grande variabilidade de formas de

onda inter-indivíduos. Estas técnicas se baseiam em ferramentas estatísticas, nas quais a capacidade de detecção depende da baixa relação sinal/ruído (SNR) da resposta e da quantidade de dados disponíveis para o cálculo [5] [6].

A interface cérebro-computador (BCI, do inglês Brain Computer Interface) é uma forma de comunicação que não usa qualquer movimento muscular, como falar, escrever ou imitar, destina-se a indivíduos com comprometimento motor grave, sem nenhuma outra forma de comunicação, mas o entendimento dos indivíduos vai diretamente da mente. A maior parte do BCIs utiliza técnicas não invasivas inofensivas, tais como o EEG, capturando os assuntos, vontade e transformá-lo nas correspondentes ações sem a necessidade de músculos e nervos.

Neste contexto, pode utilizar varias técnica que seriam capazes de interpretar e tomar decisões. A máquina de vetor de suporte (SVM, do inglês *Support Vector Machine*) nos últimos anos vem sendo muito utilizada, devido ter abordagem baseada em kernel com uma sólida base teórica, daí tornou-se uma ferramenta popular para máquinas de aprendizagem que envolvam classificação e regressão. Sendo esse classificador utilizado em muitas aplicações, como, abranger identificação de faces, classificação de textos, bioinformática e mineração de dados [8]. Por fim, buscou mesclar componente principal, modelos AR (Auto Regressivo) e o SVM, para que possa obter um classificador eficiente.

1.1 Revisão Bibliográfica

1.1.1 Respostas Evocadas

No cérebro humano é possível captar sinais elétricos, e estes são decorrentes de correntes iônicas ocorridas por potencial de ação, devido a qualquer atividade sensorial, pensamento etc. O potencial evocado (PE) é uma atividade bioelétrica registrada em um organismo biológico desencadeada por um estímulo externo [9], [5]. A denominação para registrar as atividades cerebrais no escalpo é dada como eletroencefalograma (EEG). É de grande importância a aquisição de dados dos sinais de EEG, pois o mesmo apresenta informações a cerca do núcleo cerebral quando ativado e de vias neurais. A ordem de grandeza desses sinais de PE está em torno de microvolts, considerado pequeno quando comparada com outro sistema, como por exemplo, o eletrocardiograma, que tem sua grandeza por volta do milivolts. O processamento neural envolvido pelo estímulo sensorial pode ser indiretamente monitorado pela análise do estímulo do PE registrado no escalpo, como uma forma não invasiva de monitoração de integridade de vias neurais. Como essas re-

spostas são reduzidas e com baixa relação sinal ruído, em comparação com a atividade de fundo, técnicas de promediação e de processamento de sinais, são necessárias para revelar a atividade cerebral evocada [5] [6].

1.1.2 Potencial Evocado Auditivo (PEA)

No sentido melhorar o bem estar e a saúde de recém-nascido vários países tem elaborado leis que obriguem a implantação de programas de triagem auditiva. Nos últimos anos, o exame de PEA tem sido reconhecido como método de determinação do limiar de audição de recém-nascidos, crianças, e pacientes não habilitados a fornecer respostas comportamentais consistentes ou confiáveis, sendo atualmente considerado como exame de referência [10].

O método de obtenção dos potenciais evocados consiste na aplicação de um conjunto de estímulos e no registro das respostas elétricas a esses estímulos, ao longo de um determinado caminho nervoso. Os estímulos podem ser visuais, que consiste em estímulos visuais, auditivo, que é feito com estímulos nas orelhas ou somáticos, que é estímulos aplicados nos braços e pés.

Os potenciais evocados auditivos (PEA) refletem 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 [6]. Com a possibilidade de examinar pacientes sedados ou anestesiados de forma não invasiva aumentou ainda mais a aplicabilidade clínica deste procedimento [11].

1.1.3 Respostas Evocadas em Regime Permanente (ASSR)

As respostas auditivas de estado permanente (ASSRs, do inglês *auditory steady-state response*) foram inicialmente descritas por [12], desde então, muitos estudos foram conduzidos sobre as suas principais características e os processos que levam à sua geração.

A ASSR é a resposta elétrica do cérebro que gera regularmente estímulos auditivos [13]. E ela aparece quando a taxa de entrega de estímulo é suficientemente rápida para produzir a sobreposição das respostas às estímulos individuais. 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 [14]. A ASSR evocada por tom AM é caracterizada por um aumento de energia na frequência da moduladora (e seus harmônicos) no espectro de potência do sinal registrado. Foi comprovado 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 [15].

Em humanos, as ASSRs evocadas por tons AM mais estudadas são as com frequência de modulação entre 80 e 110 Hz [16] bem como a 40 Hz [17]. Essas respostas a modulações de 40 Hz são amplamente estudadas, apresentando as seguintes características: Sua amplitude decai consideravelmente durante o sono, são difíceis de se registrar em crianças, são significativamente atenuada por anestesia [18] e [19] também informou que a amplitude da ASSR às vezes aumentada durante sonolência induzida pelo álcool.

Para frequências de modulação abaixo dos 40Hz o córtex é responsável por gerar as ASSRs, para taxas entre 40 e 60Hz as regiões subcorticais são as responsáveis pela geração destas respostas. Já para frequências de modulação acima de 70Hz, as ASSRs são geradas no tronco encefálico [6].

Com o propósito de usar as ASSRs em aplicações audiológicas deve ser enfatizado que a presença deste potencial (em qualquer frequência de modulação) é, em boa parte, determinada pela integridade da cóclea e do nervo auditivo [20]. As variações neuropatológicas e constitucionais de cada indivíduo que afetam os PEA (potencial evocado auditivo) transitórios são esperadas afetar as ASSR da mesma forma [21]. Não surpreende o fato de que as baixas frequências de modulação sejam mais vulneráveis aos estados mentais do indivíduo do que as altas frequências, assim como os PEA-ML e PEA-LL (média e longa latência) [22].

1.1.4 Interface Cérebro Computador

Interface cérebro-computador (BCI, do inglês *Brain Computer Interface*) é fundamentalmente uma nova abordagem para restabelecer a comunicação e controle para pessoas com distúrbios motores graves, como amiotrófica esclerose lateral (ALS), derrame cerebral e paralisia cerebral [23] [24]. 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, aprendeu a se comunicar através de interface que interpreta os sinais EEG [25].

Os BCIs podem ser de dois tipos: dependentes, não usa as vias de saída normal do cérebro para levar a mensagem, mas a atividade nestas vias é necessária para gerar a atividade cerebral. Em contraste, um BCI independente não depende de qualquer forma

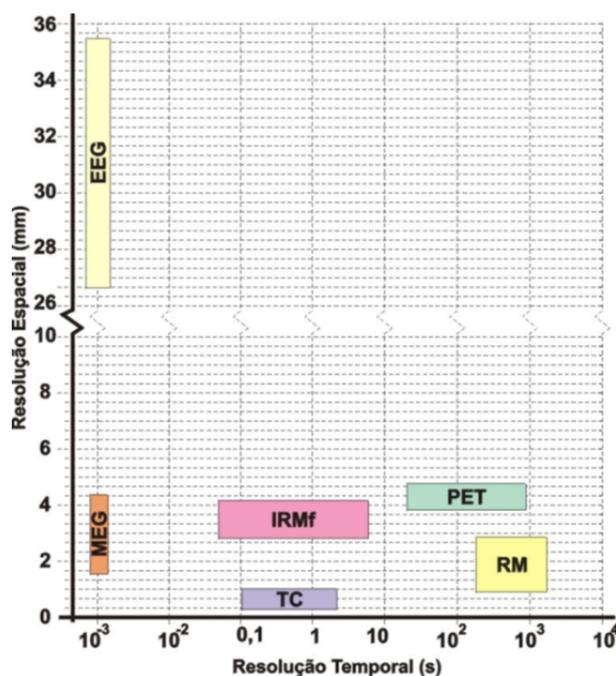


Figura 2: Gráfica para a resolução espacial e temporal para técnicas não invasiva.

sobre os percursos de saída normal do cérebro. A mensagem não é transportada por nervos periféricos e músculos, e, além disso, as atividades destas vias não são necessários para gerar a atividade cerebral.

A maioria das BCIs utiliza sinais não-invasivos de Eletroencefalograma. Segundo [26] [6], a razão é que o EEG se torna prático quando se pensa em ampliar essa tecnologia a uma grande população. Outras técnicas não-invasivas, como a Tomografia Computadorizada (TC), Magnetoencefalografia (MEG), Tomografia de Emissão de Positron (PET), e Imagem de Ressonância Magnética e Magnética Funcional (MRI) e (fMRI), podem ser usadas para medir a atividade neural. Entretanto, pode-se observar na Figura 2, que apesar do PET, MRI, fMRI e TC apresentarem uma boa resolução espacial, atualmente, apenas os métodos de EEG e afins, que têm resolução temporal relativamente baixa, e pode funcionar na maioria dos ambientes, e requerem equipamento relativamente simples e barato, oferecem a possibilidade de uma nova comunicação não-muscular e canal de controle, um BCI prático.

O desenvolvimento de Interfaces baseadas na atenção seletiva auditiva tem como principal vantagem a aplicação para pacientes em estado locked-in, que apresentam dificuldades em controlar o movimento ocular, pois estes sistemas são independentes da visão (*Vision Free*) [27], além disso as BCIs auditivas utilizam uma tarefa cognitiva inerente a todos seres humanos, sem a necessidade de muito treinamento para a tarefa de atenção [28].

1.1.5 Fisiologia do Ouvido Humano

O ouvido é a parte do corpo em que percebe a vibração provocada pelo som, uma vez que esse se propaga através das agitações das partículas. Essas agitações podem ser percebidas por esse órgão humano. Na Figura 3, apresenta as principais divisões, envolvendo o ouvido externo, o ouvido médio e o ouvido interno.

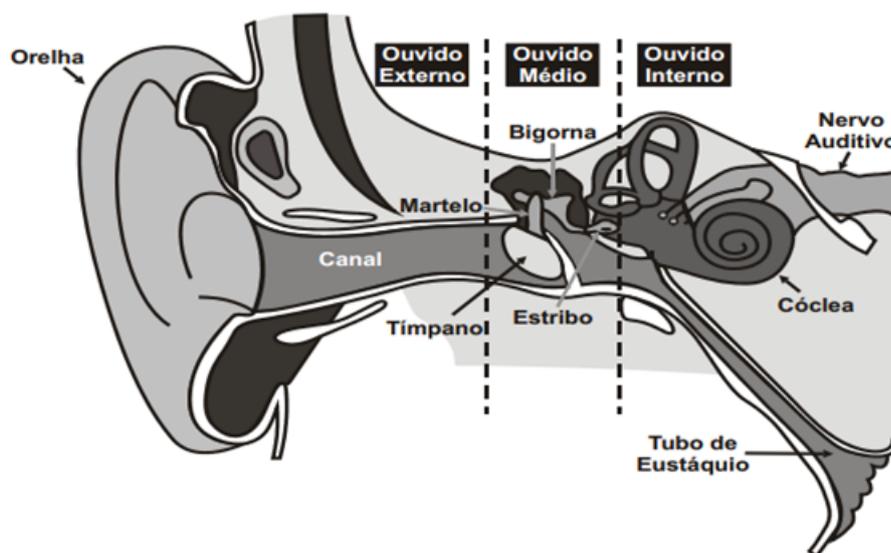


Figura 3: Representação das partes do ouvido humano.

Cada parte tem uma função específica, ouvido externo serve para coletar o som e levá-lo pelo canal ao ouvido médio, no ouvido médio ocorre a transformação da energia de uma onda sonora em vibrações internas da estrutura óssea do ouvido médio, estas vibrações, por sua vez, formam uma onda de compressão no ouvido interno, e esse transforma a energia da onda de compressão dentro de um fluido em impulsos nervosos que podem ser transmitidos ao cérebro.

A membrana timpânica possui a forma de um cone, sendo que o cabo do martelo está fixado ao centro da membrana timpânica. Na outra extremidade, o martelo está ligado à bigorna através de diminutos ligamentos, onde sempre que o martelo se mover a bigorna também se moverá com ele. A outra extremidade da bigorna está ligada ao cabo do estribo, e a platina do estribo ligada à extremidade do labirinto membranoso da cóclea, na abertura da janela oval.

A diferença no tamanho de alguns órgãos faz com que a força exercida sobre o líquido da cóclea seja equivalente a uma pressão 22 vezes maior do que a pressão exercida por uma onda sonora na membrana timpânica. Esse fato se dá em função do líquido possuir uma inércia muito maior que o ar, necessitando de maior pressão para causar a vibração no

líquido. Quando deixa o sistema ossicular e a membrana timpânica, as ondas sonoras ainda chegam até a cóclea pela janela oval através do ar, deslocando-se diretamente pelo ouvido médio, com isso, ocorre uma diminuição de cerca de 15 a 20 decibéis na sensibilidade de audição, por falta da transmissão ossicular, ou seja, 15 a 20 decibéis equivalem à diminuição do nível médio da voz para um nível pouco perceptível [29] [30].

Para que os movimentos da membrana basilar sejam transmitidos para o cérebro, eles devem ser transformados em impulsos nervosos. Este processo é feito pelas células do órgão de corti, que são pequenas células em forma de pêlos que disparam impulsos quando são dobradas pela ação do deslocamento da membrana basilar, que pode ser visto na Figura 4. Estes impulsos então são transmitidos pelos nervos conectados a essas células [29]. O deslocamento produzido ao longo do comprimento da membrana torna-se específico em relação à frequência.

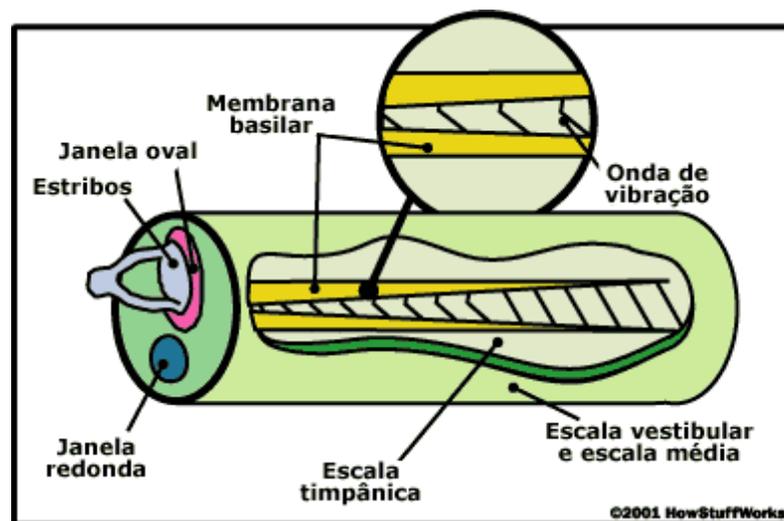


Figura 4: Membrana Basilar.

A via auditiva primária é curta, rápida (fibras grossas e mielinizadas) e termina no córtex auditivo primário. Esta via veicula informação codificada pela cóclea e cada núcleo efetua um trabalho específico de descodificação e interpretação que seguidamente transmite aos núcleos superiores. O córtex auditivo primário é o fim da via auditiva, onde a mensagem auditiva chega já largamente descodificada pelos núcleos inferiores, sendo aqui reconhecida, memorizada e possivelmente integrada numa resposta motora [1]. O córtex auditivo é visto na Figura 5.

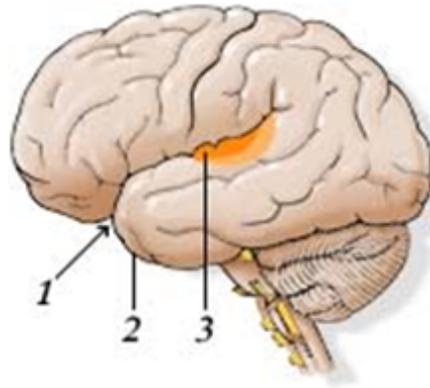


Figura 5: Córtex auditivo do ser humano, o córtex auditivo (3) localiza-se na parte pósterosuperior do lobo temporal (2), no interior do sulco lateral (1). [1]

1.2 Objetivo Geral

Desenvolver técnicas computacionais para classificar, *online*, os estados de atenção nas respostas evocadas de regime permanente de indivíduos sob estimulação binaural usando Máquina de Vetor de Suporte (SVM). O sistema de interface cérebro-computador terá que explorar os efeitos da atenção nas respostas auditivas no qual o usuário faça escolhas binárias. Este sistema fará a classificação de sinais EEG, automaticamente, registrados em resposta a dois estímulos auditivos simultâneos através do SVM. 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 a aplicação da máquina de vetor de suporte na atenção seletiva auditiva;
- Desenvolver um método de classificação *online* dos estados de atenção utilizando SVM, baseado nos achados fisiológicos da atenção seletiva auditiva;
- Avaliar o desempenho do classificador na aplicação em uma ICC auditiva; e,
- Publicar os resultados obtidos em periódicos relevantes na área.

2 *Materiais e Métodos*

Nesta seção encontra-se metodologia usada e os materiais adotados para a realização desse projeto. Primeiramente, fez um estudo geral de cada parte do mesmo para um melhor entendimento a posteriori. A Figura 6 mostra de forma clara como é o desenvolvimento deste projeto. Ela facilita o entendimento das etapas seguidas resumindo-as em um fluxograma. O primeiro bloco é o (EEG), que consiste em registrar os sinais biológicos dos indivíduos através do eletroencefalógrafo, e esses exames foram feitos no laboratório do Núcleo Interdisciplinar de Análise de Sinais (NIAS), no Departamento de Engenharia Elétrica da Universidade Federal de Viçosa-MG (UFV), seguindo o protocolo, que consiste em um sistema de refrigeração, uma cabine audiométrica e uma cadeira ajustável, de modo a deixar o voluntário mais a vontade. Depois de feito a coleta dos dados, é feito um pré-processamento dos mesmos em que o sinal é filtrado para excluir a frequência da rede de 60 Hz. Além disso, é feito uma varredura nos canais dos eletrodos para a remoção de artefatos, tais como engolir saliva, movimentos musculares, ect. 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 do qual são retirados os parâmetros que serão os vetores de entrada para o classificador.



Figura 6: Cada etapa que ocorre para o reconhecimento de padrão.

2.1 Aquisição de Sinais

Para a aquisição de sinais no EEG foi utilizado o sistema 10-20. Este sistema é utilizado no mapeamento das posições onde serão fixados os eletrodos para registrar os

sinais do Eletroencefalograma, como mostrado na Figura 7.

O sistema internacional 10-20 utiliza 21 pontos que são marcados dividindo o crânio em proporções de 10% ou 20% do comprimento das distâncias entre os pontos de referência, nasion e inion no plano medial e os pontos pré-auriculares no plano perpendicular ao crânio. A nomenclatura dos pontos é dada de acordo com a região em que estão localizados, Fp = frontal polar, F = frontal, T = temporal, C = central, P = parietal e O = occipital. Os pontos localizados sobre a linha média são indexados pela letra "z", de "zero", os pontos localizados do lado esquerdo da linha média por índices ímpares e à direita por índices pares. Na determinação das posições são usados dois pontos de referência, o nasion localizado no topo do nariz entre as sobrancelhas e o inion que fica na base do crânio atrás da cabeça. A distância desses dois pontos é medida e a partir deles são marcados os pontos sobre a linha mediana do crânio, Fpz e Oz com 10% da distância entre o nasion e o inion e os pontos Fz, Cz e Pz com 20% desta distância. Dois outros pontos imaginários situados nas regiões pré-auriculares são utilizados, traça-se uma linha entre estes pontos passando pelo ponto Cz, localizado no centro do crânio sobre a linha média, e utilizamos esta distância para marcarmos os pontos T3 e T4 situados a 10% e os pontos C3 e C4 situados a 20% desta distância. Em seguida traçamos uma linha entre os pontos Fpz e Oz passando pelo ponto T3, medimos esta distância e marcamos os pontos Fp1 e O1 com 10% e os pontos F7 e T5 com 20% desta distância, com este mesmo procedimento marcamos os pontos Fp2, F8, T6 e O2 do lado direito. Os pontos F3, F4, P3 e P4 são localizados de forma equidistante dos pontos vizinhos.

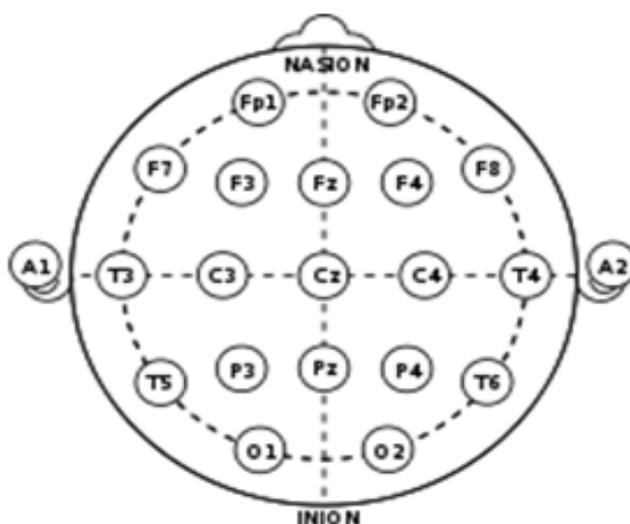


Figura 7: Representação do sistema 10-20.



Figura 8: Representação do sistema 10-20.

Para captação do sinal do EEG utilizou-se 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 601,5. Na ato da coleta de dados o paciente foi colocado dentro de uma cabine audiométrica sentado em uma cadeira confortável, depois é colocado os eletrodos de acordo com o sistema 10 – 20, para evitar interferência no exame a pessoa deve ficar com os olhos fechados, ficar quieta, pois pode gerar muitos artefatos.

Esses exames foram feito com apenas uma combinação de frequência portadora e moduladora, a frequência portadora de 32/38 Hz e frequência moduladora de 500/2000 Hz. Os Sinais de EEG foram coletados de 14 indivíduos adultos (todos homens) com idade entre 19 e 28 anos, sem sinais de patologias neurológicas. Na triagem auditiva todos foram diagnosticados pela especialista com "Limiares auditivos dentro dos padrões de normalidade bilateralmente".

2.2 Estimulação para Coleta de Dados

Os estímulos auditivos foram feitos puramente com som Modulado em Amplitude (AM), e gerados de acordo com 2.1, 2.2 e 2.3.

$$c(t) = \text{sen}(2\pi ft). \quad (2.1)$$

$$m(t) = 1 - a0.5(\cos(2\pi f_m t) + 1). \quad (2.2)$$

$$s(t) = c(t) * m(t). \quad (2.3)$$

Na geração dos estímulos utilizou-se uma ferramenta chamada GUI (*Graphical User Interface*) para gerar uma interface de fácil interação para o usuário. Nessa pode alterar os valores das frequências moduladora e portadora, frequência de amostragem, que deve ser a mesma selecionada no equipamento BNT-36 (EMSA, Brasil, www.emsamed.com.br), os tempos de estimulação, tamanho da janela, intensidade sonora e a sequência do exame para cada ouvido. A Figura 9 mostra a interface gráfica.

Utilizou-se os fones de inserção para audiometria E-A-RTONE®5A Insert Earphone, da E-A-R Auditory Systems, como mostra a Figura 10, para que o voluntário possa ouvir o som produzido com as características da interface. As espumas em amarelo é um bloqueador de som, não deixando que ruídos externos possam influenciar no áudio do exame. Ela também oferece uma melhoria com relação: sistema de entrega de som, maior atenuação transcraniana, o que evita a estimulação contralateral e melhor acoplamento auricular, minimizando perdas de energia acústica [31] [6].

Os sinais de EEG dos indivíduos que passa por estimulação são analisados via FFT,

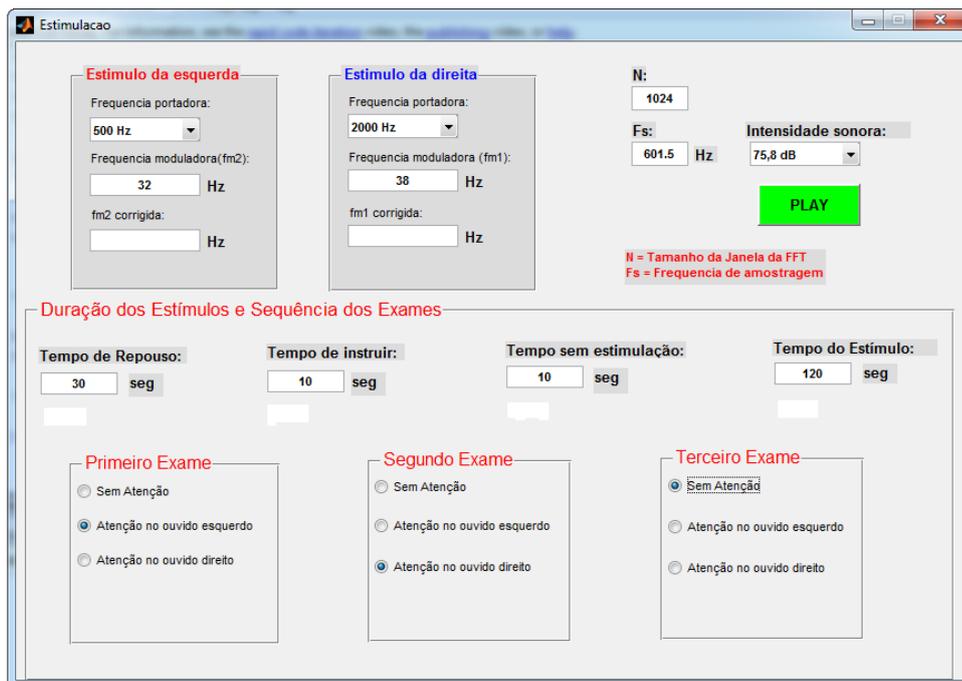


Figura 9: Interface para geração do sinal audiométrico.



Figura 10: Fone de inserção E-A-R-Tone 5A.

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 [32]. Tendo em vista esta metodologia, deve haver um número inteiro de oscilações (L) do sinal a ser detectado, onde cada ciclo tem um período T_0 , e o comprimento da janela (que é $L \cdot T_0$) deve ser um múltiplo inteiro do período de amostragem (T_s). Ou seja, esta correção é determinada por 2.4, que foi realizada para a frequência de amostragem (f_s) 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 (N) para FFT de 1024 pontos. Dessa forma, na interface pode notar os valores corrigidos para frequência de estimulação 32 e 38 Hz, que são 31,13 e 39,36 Hz, respectivamente.

$$\frac{f_s}{f_m} = \frac{N}{L} \quad (2.4)$$

Em que f_m é a frequência moduladora utilizada no estímulo.

Neste projeto com o intuito de estudar o efeito da atenção nas ASSR o protocolo de estimulação foi composto por três etapas de estimulação binaural. Na Figura 11 encontra-se a etapa de estimulação para o exame. Em que a condição sem atenção: os voluntários foram orientados a não focar a atenção em nenhum dos estímulos. A atenção no estímulo do ouvido esquerda: os voluntários foram instruídos a focar a atenção no estímulo da esquerda e desprezar o estímulo da orelha direita. A atenção no estímulo da direita: os voluntários foram orientados a focar a atenção no estímulo da direita e desprezar o estímulo da orelha esquerda. A instrução tem por finalidade orientar o paciente em qual

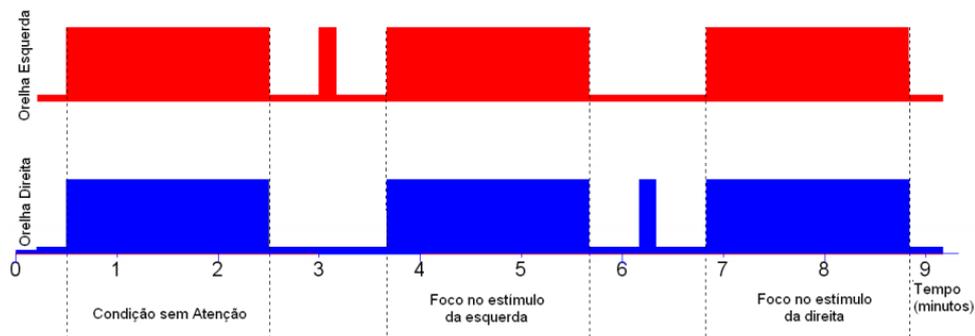


Figura 11: Linha do tempo para o estímulo do exame.

ouvido deve focar ou não a atenção.

2.3 Pré-Processamento

O pré-processamento é um tratamento dos dados após os exames. Uma vez que os exames são obtidos com a extensão `.EDF` é feita uma conversão para a extensão `.mat`, para que os dados possam ser trabalhados no software MATLAB.

É feito um pré-processamento no domínio do tempo, que consiste na extração dos sinais de Trigger, que é enviado ao eletroencefalógrafo no instante em que o estímulo é aplicado ao voluntário.

Posteriormente, os dados são passados por um processo de filtragem e rejeição de artefatos, que são resposta em frequência que não é estabelecida. É aplicado um filtro rejeita faixa, de modo a remover a frequência de 60 Hz, que é a componente espectral da rede elétrica, pois a mesma apresenta elevado nível de energia.

Estudos apresentam técnicas para descartar trechos de sinais coletados que contenham variações elevadas na amplitude do sinal em curto intervalo de tempo. O método de rejeição de artefatos consiste em rejeitar um trecho de sinal que tenha mais de 5% de amostras contínuas ou mais de 10% de quaisquer amostras coletadas, estiverem fora do intervalo de confiança estipulado. Para padronização de tamanho entre todas derivações sempre que um trecho for detectado como portador de artefato, este será rejeitado em todas as derivações. Dessa forma, o número total de trechos restantes após o processo de rejeição automática de artefato será igual ao número de trechos onde não seja observada presença de artefato em nenhuma das derivações [6].

2.4 Análise de Componente Principal

A análise das componentes principais (PCA- do inglês Principal Component Analysis) é um dos métodos estatísticos de múltiplas variáveis mais simples. Ela é considerada a transformação linear ótima, dentre as transformadas de imagens, sendo muito utilizada pela comunidade de reconhecimento de padrões. 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 representativa de dados a partir de combinações lineares das variáveis originais.

Para o cálculo das componentes principais são seguidos alguns 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 x n;
- Calcular os autovalores e auto vetores da matriz de covariância;
- Arranjar a matriz da Transformada de Hotelling (cujas linhas são formadas a partir dos autovetores da matriz de covariância arranjados de modo que a primeira linha, o elemento (0,0), seja o autovetor correspondente ao maior autovalor, e assim sucessivamente até que a última linha corresponda ao menor autovalor).

Por sua vez, a covariância sempre é medida entre duas dimensões. A matriz de covariância é calculada por 2.5.

$$cov(X, Y) = \sum_{n=1}^n \frac{[(X_i - \bar{X}) \cdot (Y_i - \bar{Y})]}{n}, \quad (2.5)$$

Em que, X e Y são listas de dados, sendo X a primeira e Y a segunda dimensão. Os elementos barrados são as médias das listas. E n representa o número de itens de dados obtidos. A diagonal principal da matriz contém as variâncias e as demais posições a correlação entre as direções. Essa matriz é simétrica e real, de modo que é sempre possível encontrar um conjunto de autovetores ortonormais [33]. A matriz de transformação utilizada para o cálculo da PCA consiste em uma matriz cujas linhas são os auto vetores da

matriz de covariância estimada dos dados[34]. apesar das técnicas de análise multivariada terem sido desenvolvidas para resolver problemas específicos, principalmente de Biologia e Psicologia, podem ser também utilizadas para resolver outros tipos de problemas em diversas áreas do conhecimento, como por exemplo na área da biomédica. A análise de componentes principais é a técnica mais conhecida, contudo é importante ter uma visão conjunta de todas ou quase todas as técnicas da estatística multivariada para resolver a maioria dos problemas práticos [35] [36]. 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 informações dos dados iniciais.

2.5 Modelo AR (Autorregressivo)

A análise clínica do EEG é geralmente baseada na inspeção visual de um conjunto de traçados, visando o reconhecimento de padrões, um processo subjetivo, sendo, portanto altamente dependente da experiência e treinamento do eletroencefalografista. Apesar da utilização de parâmetros objetivos, tais como a frequência, a ênfase metodológica ainda está na análise morfológica efetuada pelo especialista [37].

A análise quantitativa do EEG, através do uso de métodos computadorizados e técnicas de processamento de sinais visa possibilitar a utilização mais eficiente e objetiva das informações usadas na análise convencional qualitativa, além de possibilitar a investigação da existência de outras informações clinicamente significantes, não óbvias à inspeção visual [37]. A metodologia quantitativa objetiva auxiliar o eletroencefalografista na análise e interpretação dos resultados, acelerar e aumentar a precisão do processo de diagnóstico.

Para análise quantitativa, geralmente analisa espectralmente, pode utilizar a transformada de Fourier (FFT), porém para alguns casos é melhor utilizar o modelo AR para análise espectral, uma vez que a FFT é limitada para algumas aplicações [37] A estimação espectral através do modelo AR é mais adequada que a FFT na detecção de mudanças rápidas e de curta duração no EEG. Isto se deve a dois fatores: melhor resolução espectral que a FFT, requerendo uma menor quantidade de dados para estimativas aceitáveis; o outro fator é a possibilidade da obtenção de uma estimativa espectral de uma senóide quando os dados incluem menos que um ciclo da mesma, permitindo assim a estimação espectral de ondas muito lentas, enquanto a FFT, por sua vez, necessita de segmentos contendo tipicamente cinco períodos do sinal para produzir estimadores espectrais confiáveis

[38].

O modelo AR é um modelo estocástico e é útil na representação de um grande número de séries temporais. Na análise AR de um sinal, estima-se um filtro linear recursivo, que quando aplicado um ruído branco resulta num sinal com espectro equivalente ao do sinal original. O modelo AR é definido por 2.6:

$$x(k) = a_1x(k-1) + a_2x(k-2) + \dots + a_px(k-p) + e(k) \quad k = 1, 2, \dots, N, \quad (2.6)$$

Onde $x(k)$ é o sinal auto regressivo, $e(k)$ em geral é um ruído branco, a_1, a_2, \dots, a_p são coeficientes de um filtro recursivo e p a ordem do modelo. A dificuldade de determinar os parâmetros para o modelo AR está no fato de que ao escolher um valor alto ou baixo, isso pode trazer uma resposta ruim para o espectro. Para esse trabalho implementou-se uma rotina de forma que tanto o modelo AR quanto a PCA variasse os parâmetros, com isso era possível fazer a escolha do melhor resultado que será entregue ao sistema *online*, uma vez que esse sistema precisa de apenas um parâmetro do modelo AR e um parâmetro para a PCA.

2.6 Máquina de Vetor de Suporte (SVM)

As Máquinas de Vetores de Suporte (SVMs, do Inglês *Support Vector Machines*) constituem uma técnica de aprendizado que vem recebendo crescente atenção da comunidade de Aprendizado de Máquina (AM). Os resultados da aplicação dessa técnica são comparáveis e muitas vezes superiores aos obtidos por outros algoritmos de aprendizado, como as Redes Neurais Artificiais (RNAs) [39] [40] [41].

As técnicas de aprendizado de máquina (AM) empregam um princípio de inferência denominado indução, no qual se obtém conclusões genéricas a partir de um conjunto particular de exemplos. Esse processo de indução de um classificador a partir de uma amostra de dados é denominado treinamento. O aprendizado indutivo pode ser dividido em dois tipos principais: supervisionado e não supervisionado.

Os conceitos referentes à geração de um classificador a partir do aprendizado supervisionado são representados de forma simplificada na Figura 12. Tem-se nessa figura um conjunto com n dados. Cada dado x_i possui m atributos, ou seja, $x_i = (x_{i1}; \dots; x_{im})$. As variáveis y_i representam as classes. A partir dos exemplos e as suas respectivas classes, o

algoritmo de AM extrai um classificador. Pode-se considerar que o modelo gerado fornece uma descrição compacta dos dados fornecidos [42]. A obtenção de um classificador por um algoritmo de AM a partir de uma amostra de dados também pode ser considerada um processo de busca.

As SVMs são embasadas pela teoria de aprendizado estatístico, desenvolvida por Vapnik [43]. A Teoria de Aprendizado Estatístico (TAE) estabelece condições matemáticas que auxiliam na escolha de um classificador \hat{f} particular a partir de um conjunto de dados de treinamento. O problema do Aprendizado Supervisionado consiste em, dada uma série de observações do sistema $(\tilde{x}_i, y_i)_{i=1}^N$ (pares ordenados de entrada e saída desejada), com função geradora $y = f(\tilde{x})$, encontrar a função $F(\tilde{x}, \tilde{w})$ que melhor aproxima a função geradora $f(\tilde{x})$, onde \tilde{w} é o vetor de pesos. Dessa forma, surge no processo de aproximação da função geradora a necessidade de definição de uma medida de discrepância ou perda, dada por $L(y, F(\tilde{x}, \tilde{w}))$, a qual indica o quanto a saída obtida $F(\tilde{x}, \tilde{w})$ difere da saída esperada y [44]. Uma função comumente empregada como medida de discrepância é o erro quadrático, dado por 2.7:

$$L(y, F(\vec{X}, \vec{Y})) = (y - F(\vec{X}, \vec{Y}))^2 \quad (2.7)$$

Sendo $P(\tilde{x}, y)$ a distribuição de probabilidade das amostras do problema de aprendizado que se deseja resolver, o valor esperado para o erro da máquina de aprendizagem obtida é definido pelo Risco Funcional 2.8:

$$R(f) = \int c(f(x_i), y_i) dP(x_i, y_i) \quad (2.8)$$

Dado um conjunto de N amostras de um sistema $(\tilde{x}_i, y_i)_{i=1}^N$, originadas da mesma distribuição de probabilidade $P(\tilde{x}, y)$ desconhecida, define-se o Risco Empírico através de 2.9:

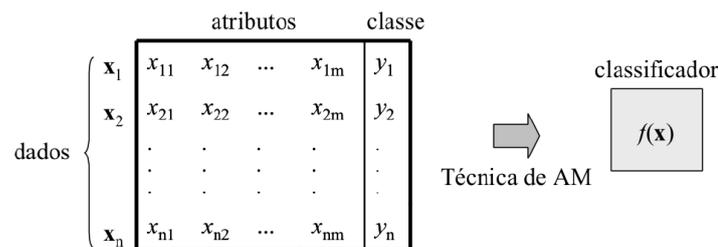


Figura 12: Indução de classificador em aprendizado supervisionado.

$$R_{empirico}(\vec{w}) = \frac{1}{N} \sum_{i=1}^N (y_i - F(\vec{x}_i, \vec{w}))^2 \quad (2.9)$$

As SVMs surgiram pelo emprego direto dos resultados fornecidos pela TAE. A primeira formulação, mais simples, envolve com problemas linearmente separáveis. Essa formulação foi posteriormente estendida para definir fronteiras lineares sobre conjuntos e dados mais gerais [45] [43].

Para este trabalho será usado o problema não linearmente separáveis. O uso desse procedimento é motivado pelo teorema de Cover [40]. Dado um conjunto de dados não linear o espaço de entradas X , esse teorema afirma que X pode ser transformado em um espaço de características no qual com alta probabilidade os dados são linearmente separáveis. Para isso duas condições devem ser satisfeitas. A primeira é que a transformação seja não linear, enquanto a segunda é que a dimensão do espaço de características seja suficientemente alta.

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 [41].

Uma função Kernel recebe dois dados de entrada x_i e y_j e calcula o produto interno destes dados no espaço característico como mostra 2.10.

$$k(x_i, y_i) = \langle \Phi(x_i) \cdot \Phi(x_j) \rangle \quad (2.10)$$

Sendo necessário que a função 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 K é positivamente definida", onde K é obtido por 2.11:

$$K = K_{ij} = k(x_i, y_i) \quad (2.11)$$

Uma matriz é positivamente definida, se seus autovalores são maiores que zero. As funções Kernel que satisfazem as condições do Teorema de Mercer são chamadas de Kernels de Mercer [48]. Algumas dessas funções, comumente utilizadas como funções de Kernel, são a RBF, a polinomial e a sigmoideal (ou MLP do inglês *Multi-Layer Perceptron*). Que são vistas na Tabela 1. Neste trabalho foi utilizado a função Kernel MLP, e na seção

seguinte será dado mais informações de como foi utilizado esta para o treinamento do classificador.

Tabela 1: Algumas funções Kernel.

Função de Kernel	Expressão para $K(x_i, x_j)$	Parâmetros
RBF	$e^{-\ x_i - x_j\ ^2 / 2\sigma^2}$	σ^2
Polinomial	$(x_i^T x_j + a)^2$	a, b
Sigmóide	$\tanh \beta_0 x_i^T x_j + \beta_1$	β_0, β_1

Após a implementação do classificador, foi determinado a taxa de acerto 2.12, que é a soma de todos os acertos, tanto para o ouvido esquerdo quanto para o ouvido direito, dividido por todos os elementos acertados e não acertados. Como se pode notar em 2.13, percebe-se que a taxa de transmissão de informação sofre influência da taxa de acerto. Essa Taxa de Transferência de Informação (ITR, do inglês Information Transfer Rate), também conhecida como taxa de bits, é utilizada para sistemas de comunicação em geral [6], que na verdade é a quantidade de informação transmitida pela interface por unidade de tempo.

$$taxadeacerto = (\text{valores} - \text{acertados}) * 100 / (\text{todos} - \text{valores} - \text{acertado}) \quad (2.12)$$

$$IRT = s[\log_2 N + P \log_2 P + (1 - P) \log_2 \left(\frac{1 - P}{N - 1}\right)] \quad (2.13)$$

Equação 2.13 mostra que para uma dada taxa de acerto P, a ITR aumenta com o aumento do número de comandos N. Ou ainda, para um número determinado de comandos N, quanto maior a taxa de acerto, maior a ITR do sistema. Quanto menor o tempo para se classificar um comando maior poderá ser o alcance de sua ITR, mas na prática isso acarreta também uma diminuição da taxa de acerto do sistema. Então para obter uma BCI com resposta adequado é necessário relacionar o número de comandos e a taxa de acerto.

2.7 Processamento *Online*

No processamento das respostas evocados de forma *Online* desenvolveu-se um software que se comunicasse diretamente com o Eletroencefalógrafo (Brainnet-36). A comunicação do equipamento com o computador foi realizada via cabo tipo par trançado, com

conectores RJ45, para rede padrão Ethernet. O protocolo de comunicação usado pelo Brainnet-36 é o UDP (do inglês, *User Datagram Protocol*), que é um protocolo simples e permite que a aplicação escreva um datagrama (pacote de dados) encapsulado num pacote IP [46].

O equipamento utilizado envia ao computador um pacote com os dados a cada 20 amostras coletadas. Dessa forma, o datagrama enviado tem 720 amostras (20 amostras para cada um dos 36 canais).

Os sinais do Brainnet são digitalizados com uma resolução de 16 bits, as amostras são divididas em dois conjuntos de 720 bytes (8 bits cada amostra). A ordem com que as amostras são dispostas no datagrama foi fornecida pela LYNX, possibilitando assim a adequada recepção dos dados no sistema desenvolvido.

Após realizar a classificação *offline*, alguns parâmetros de treinamento dessa fase será utilizada para a fase *online*. A Figura 13 mostra a interface desenvolvida. No ato da execução do exame o software de comunicação realiza todo o procedimento de pré-processamento e processamento do sinal da mesma forma feita no modo *off-line*. É usado um critério de parada, que é um parâmetro pré-definido antes do início do programa, onde o usuário poderá escolher o número de acertos do classificador para saber se a classificação foi realizada ou não.

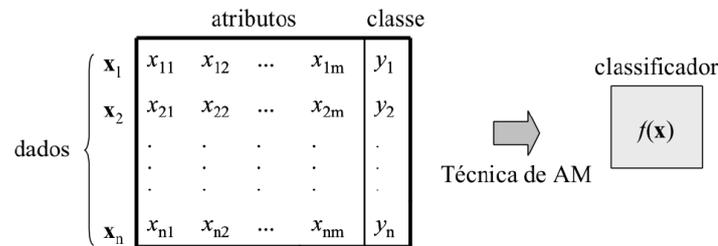


Figura 13: Indução de classificador em aprendizado supervisionado.

Na interface desenvolvida, como mostra a Figura (INTERFACE), o usuário pode definir alguns parâmetros antes de iniciar o exame, como:

- **Nº de amostras:** Permite a definição do número de amostras a ser trabalhado;
- **Rejeição de artefatos:** Opção que ativa o algoritmo para rejeição automática de artefatos;
- **Estimulação:** Define os parâmetros de estimulação e gera o sinal que estimulará o paciente.

O sistema incorpora também uma análise final dos resultados do exame realizado, como: número de acertos, número de testes realizados, taxa percentual de acerto e taxa de transferência de informação.

3 *Resultados e Discussões*

Nesta seção serão mostrados os resultados mencionados na seção anterior. Primeiramente fez-se o pré-processamento dos sinais, que era filtrar e rejeitar artefatos, e com o intuito de diminuir as dimensões das matrizes utilizou-se a ferramenta análise das componentes principal (PCA), que era obtido os autovetores e esse representava de forma simplificada a matriz dos sinais como um todo. O modelo AR é uma técnica utilizada pra obter as características da PCA, de forma que possa diminuir ainda mais a matriz. Diante disso realizou-se uma variação da PCA de 1 a 4 e para o modelo AR de 1 a 7. Isso foi feito pra que possa encontrar o melhor resultado tanto para a taxa de acerto como também para taxa de transmissão de informação e o melhor valor encontrado foi PCA=4 e AR=5, e isso foi feito utilizando todos os eletrodos. Esses valores serão úteis para realizar a classificação *online*.

3.1 Resultado para o classificador *Offline*

Para essa parte da pesquisa foi usados um banco de dado de 14 indivíduos, sendo que cada exame é feito para o ouvido direito e esquerdo, totalizando um conjunto de dado de 28 elementos. Para determinar o melhor classificador, o treinamento foi feito com 70% dos dados, ou seja, foram utilizados 20 exames para isso. Os outros 30% foi utilizada para validação do classificador, ou seja, restaram 8 exames para validar. Para realização de um bom treinamento fez-se uso da função Kernel e a função utilizada foi *Multilayer Perceptron* (MLP), e essa necessita de dois parâmetros de acordo com a equação da Tabela 1, sendo β_0 e β_1 [1 -1], respectivamente, o método para a separação do hiperplano foi o dos mínimos quadrados. Com isso a Figura 14 foi o resultado obtido para esse treinamento.

A escolha desse resultado se deve ao seguinte, ao analisá-lo percebeu-se que passados os primeiros 5s de exame houve uma boa taxa de acerto próximo a 90% com uma taxa de transmissão de informação (TTI) por volta de 5.5 (bits/minuto), isso quer dizer que não preciso esperar os 2 min de exame para que seja classificado, bastam os segundos iniciais

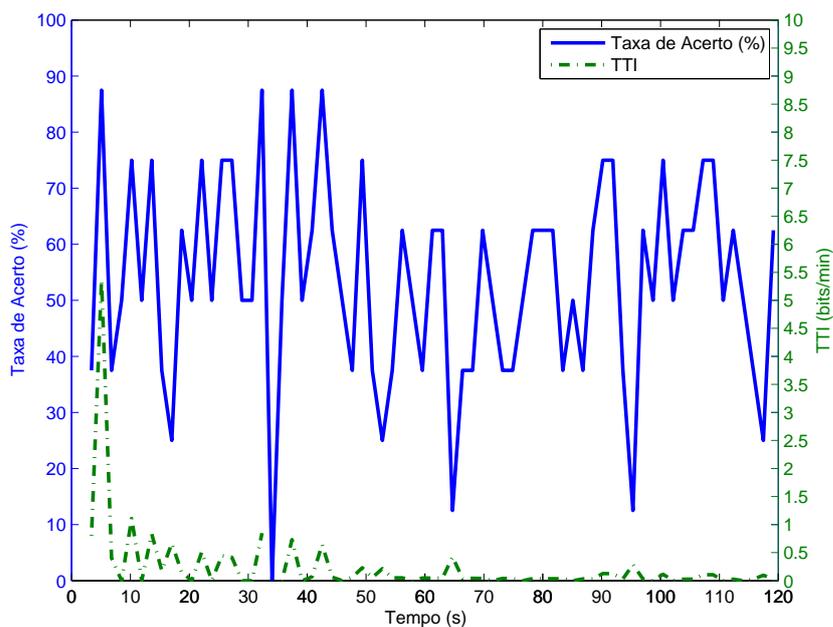


Figura 14: Figura 1- melhor treinamento, com PCA=4 e AR=5.

para que isso aconteça.

Para a realização do treinamento do classificador deparou-se com dificuldades que ocorrem devidos alguns erros de parâmetros. Pode citar algumas dessas dificuldades como: os voluntários podem estar sonolentos, pode ocorrer do indivíduo possuir algum déficit de atenção, etc.

4 *Conclusões*

Ao término desse projeto é possível levantar alguns questionamentos a respeito da máquina de vetor de suporte (SVM) sobre sua capacidade e o processo de aprendizado, do mesmo. Apesar da complexidade computacional desse sistema foi possível obter um desempenho arrojado para o classificador.

Com o intuito de testar esse classificador binário fizeram-se várias mudanças de parâmetros para obter um classificador com uma taxa de acerto relevante, que foi de aproximadamente 90%, como mostra a figura TAL. Esses testes foram feitos com a intenção de analisar a atenção auditiva, tentando avaliar se o voluntário está focando a atenção no ouvido direito ou esquerdo. Foram levadas em consideração as frequências moduladora (32/38), portadora (500/2000) com um banco de dados de 14 exames.

A análise *online* teve como parâmetro um modelo AR igual a 5 e a PCA igual a 4, uma vez, que essa combinação teve melhor resultado, tendo uma taxa de acerto de 87.5% e taxa de transmissão de informação de 5.5 (bits/min) e essa classificação ocorreu para um tempo menor que dois minutos, ou seja, não é necessário realizar o exame inteiro.

Dessa forma, percebe-se que é de grande importância a variação de informações, pois ao variar os parâmetros do classificador é possível chegar aos melhores resultados. O SVM foi uma ferramenta capaz de detectar as ASSR, o que torna esse parâmetro para a criação de uma ICC.

4.1 **Trabalhos Futuros**

Para trabalhos futuros, com os conhecimentos aqui adquiridos, é interessante aprimorar a mineração de dados e escolha de parâmetros, para que o SVM torne mais eficiente. Como por exemplo fazendo escolhas de outras frequências moduladoras e portadoras.

Referências

- [1] [HTTP://WWW.COCHLEA.EU/PO/CEREBRO-AUDITIVO](http://www.cochlea.eu/po/cerebro-auditivo). [S.l.], 2013.
- [2] WAKEFIELD, G. S.; HALLIDAY. *Cerebral evoked potentials in patients with dissociated sensory loss*. Dissertação (Mestrado) — J. Neurol. Neurosurg. Psychiat, 1963.
- [3] ASSIS, O. M.; PASA, G. <http://neuroengenharia-proc-bio.blogspot.com.br/p/eeg.html>. [S.l.], 2012.
- [4] JOHN M.; PICTON, T. W. *Human auditory steady-state responses to amplitude-modulated tones: phase and latency measurements*. [S.l.]: Hearing, 2000. 57-79 p.
- [5] FELIX, L. B. Detecção objetiva de respostas auditivas em regime permanente: aplicação em exames audiológicos. 2006.
- [6] RANAUDO, F. D. S. *Classificação em tempo real da atenção seletiva auditiva usando potenciais evocados em regime permanente e coerência espacial*. 516-524 p. Dissertação (Mestrado).
- [7] DOBIE R. A.; WILSON, M. J. *Objective Response Detection in the Frequency Domain*. [S.l.], 1989. v. 10, 2-13 p.
- [8] GEISLER, C. D. Coding of acoustic signals on the auditory nerve. *IEEE Engineering in Medicine and Biology Magazine*, v. 6, n. 6, p. 22–28, 1987.
- [9] CHIAPPA, K. H. *Evoked Potentials in Clinical Medicine*. [S.l.]: New York: Raven Press, 1997.
- [10] RAMOS E.G.; ZAEYEN, E. S. D.; INFANTOSI, A. Detection of eeg auditory response in children, using frequency domain techniques. *Revista Brasileira de Engenharia Biomédica*, v. 16, n. 3, p. 127–137, 2000.
- [11] AZEVEDO, E. P. *Determinação da Banda de Máxima Resposta do Potencial Evocado Auditivo de Curta Latência por meio da Magnitude Quadrática da Coerência*. Dissertação (Mestrado), 2003.
- [12] MOLLER, A. R. No abstract responses of units in the cochlear nucleus to sinusoidally amplitude-modulated tones. In: . [S.l.]: *Exp Neurol.*, 2002. v. 45, n. 1, p. 105–117.
- [13] PICTON M. SASHA JOHN, D. W. P. T. W.; PLOURDE, G. Human auditory steady-state responses: The effects of recording technique and state of arousal. In: . [S.l.]: *Anesth Analg*, 2003. v. 97, p. 1396–1402.
- [14] KUWADA S., B. R. M. V. I. Scalp potentials of normal and hearing-impaired subjects in response to sinusoidally amplitude modulated tones. In: . [S.l.]: *Hear. Res.*, 1986. v. 21, n. 2, p. 179–192.

- [15] JORIS P. X., S. C. E. R. A. Neural processing of amplitude-modulated sounds. In: . [S.l.]: Physiol. Rev., 1986. v. 84, p. 541–577.
- [16] LEVI E. C., F. R. C. D. R. A. Amplitude modulation following response (amfr) - effects of modulation rate, carrier frequency, age and state. In: . [S.l.]: Hear. Res., 1993. v. 68, n. 1, p. 42–52.
- [17] GALAMBOS R., M. S. T. P. J. A 40 hz auditory potential recorded from the human scalp. In: . [S.l.]: P Natl Acad Sci-Biol, 1981. v. 78, n. 4, p. 2643–2647.
- [18] LINS O. G., P. T. W. Auditory steady-state responses to multiple simultaneous stimuli. In: . [S.l.]: Electroenceph. Clin. Neurophysiol., 1995. v. 96, p. 420–432.
- [19] S, T. S. P. The auditory steady-state response is not a suitable monitor of anesthesia. In: . [S.l.]: Anesth Analg, 2002. v. 95, p. 1318–1323.
- [20] LOPES, G. C. *Caracterização das Respostas Evocadas Auditivas em Regime Permanente no Mesencéfalo de Ratos Wistar*. Dissertação (Mestrado) — Instituto de Ciências Biológicas-UFMG, Belo Horizonte, MG,, 2011.
- [21] CONE-WESSON B., D. R. C. T. D. R. G. e. M. W. J. The auditory steady-state response: comparisons with the auditory brainstem response. In: . [S.l.]: J Am Acad Audiol, 2002. v. 13, n. 4, p. 173–187.
- [22] STACH, B. A. The auditory steady-state response: A primer. In: . [S.l.]: The Hearing Journal, 2002. v. 55, n. 9, p. 10–18.
- [23] R., W. J. Memory in neuroscience: rhetoric versus reality. In: . [S.l.]: Behav Cog Neurosci Rev1, 2002. p. 130–163.
- [24] R., W. J.; N., B. Brain computer interfaces for communication and control. In: . [S.l.]: InTextbook of Neural Repair and Rehabilitation; Neural Repair and Plasticity, 2006. p. 602–614.
- [25] BIRBAUMER A. KUBLER, N. G. T. H. J. P. J. K. I. I. B. K. N. N. N.; H, F. The thought translation device (ttt) for completely paralyzed patients. In: . [S.l.]: IEEE Transactions on Rehabilitation Engineering, 2010. v. 8, p. 190–193.
- [26] MILLÁN J. R., R. R. M.-P. G. R. Combining brain and computer interfaces and assistive technologies: State-of-the-art and challenges. In: . [S.l.]: Frontiers in Neuroscience, 2010. v. 4, p. 1–15.
- [27] KIM D. W., H. H. J.-L. J. H. Classification of selective attention to auditory stimuli: Toward vision-free brain computer interfacing. In: . [S.l.]: Journal Neurosc Methods, 2011. v. 197, n. 1, p. 180–185.
- [28] LOPEZ M. A., P. H. P.-F. Evidences of cognitive effects over auditory steady-state responses by means of artificial neural networks and its use in brain-computer interfaces. In: . [S.l.]: Neurocomputing, 2009.
- [29] LAZZARINI, V. E. P. *Elementos de Acústica*. [S.l.], 1998.
- [30] SPADA, A. L. *O Ouvido Humano*. [S.l.], 2006.

- [31] INSTRUCTIONS for the use of eartone 5A: Insert Earphones. [S.l.], 2010.
- [32] FELIX L. B., M. J. E.-M. D. S. A. M. F. L. Avoiding spectral leakage in objective detection of auditory steady-state evoked responses in the inferior colliculus of rat using coherence. *J. Neu-rosci. Meth.*, v. 144, n. 2, p. 249–255, 2005.
- [33] ANTON H., R. C. *Álgebra Linear com Aplicações*. [S.l.]: ed Bookman, 2004.
- [34] VASCONCELOS, S. *Tutorial para análise de componente principal*. [S.l.], 2006.
- [35] REGAZZI, A. *Análise multivariada*. [S.l.], 2000. v. 2.
- [36] VARELLA, C. A. A. *Análise Multivariada Aplicada as Ciências Agrárias*. [S.l.], 2008.
- [37] J.R. BOKEHI, D.; A.F.C. INFANTOSI. Análise espectral de sinais eeg utilizando modelagem auto-regressiva. *RBE*, v. 9, 1993.
- [38] SILVA J. R. S., R. S. L. F. M. L. A. L. S. Estudos das variações sazonais de hotéis de aracaju. VIII ERMAC, 2008.
- [39] BRAGA, A. C. P. L. F. C. A.; LUDERMIR, T. B. *Redes Neurais Artificiais: Teoria e Aplicações*. [S.l.]: Editora LTC, 2000.
- [40] HAYKIN, S. *Neural Networks - A Comprehensive Foundation*. [S.l.]: Prentice-Hall, 1999.
- [41] LORENA, A. C. P. L. F. d. C. A. C. Uma introdução às support vector machines. XIV, n. 2, p. 44–63, 2007.
- [42] BARANAUSKAS, J. A.; MONARD, M. C. *Reviewing some machine learning concepts and methods*. [S.l.], 2000.
- [43] CRUZ, A. J. R. d. *Data Mining via Redes Neuronais Artificiais e Máquinas de Vetores de Suporte*. Dissertação (Mestrado) — Escola de Engenharia, Universidade do Minho, 2007.
- [44] VAPNIK, V. Estimation of dependencies based on empirical data. Springer, 1982.
- [45] CORTES, C.; VAPNIK, V. N. Support vector networks. *Machine Learning*, 1995.
- [46] PARTRIDGE C., P. S. A faster udp. *IEEE-ACM TRANSACTIONS ON NETWORKING*, v. 1, p. 429–440, 1993.