

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

DIEGO MARQUES DOURADO

**CLASSIFICAÇÃO DA ATENÇÃO SELETIVA AUDITIVA EM
INTERFACE CÉREBRO-COMPUTADOR USANDO REDES NEURAIS
ARTIFICIAIS**

VIÇOSA
2014

DIEGO MARQUES DOURADO

**CLASSIFICAÇÃO DA ATENÇÃO SELETIVA AUDITIVA EM
INTERFACE CÉREBRO-COMPUTADOR USANDO REDES NEURAIS
ARTIFICIAIS**

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

Nesta página será inserida a ficha catalográfica correspondente à sua Monografia. Ela será elaborada pelo pessoal da Biblioteca Central da UFV.

A priori deixa a página em branco.

DIEGO MARQUES DOURADO

**CLASSIFICAÇÃO DA ATENÇÃO SELETIVA AUDITIVA EM
INTERFACE CÉREBRO-COMPUTADOR USANDO REDES NEURAIS
ARTIFICIAIS**

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 25 de Abril 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. B.Sc. Paulo Fábio Figueiredo Rocha - Membro
Universidade Federal de Viçosa

“Fizeste-nos, Senhor, para ti, e nosso coração anda inquieto enquanto não descansar em ti.”

(Santo Agostinho)

Dedico este trabalho à minha família.

Agradecimentos

Agradeço a Deus por estar sempre presente em minha vida e, acima de tudo, por me dar forças para vencer barreiras.

Aos meus brilhantes pais Izonel Francisco Dourado e Silvone Marques Dourado por terem insistido e confiado em mim, onde somente eles conhecem os capítulos mais importantes dessa história.

Ao meu irmão e ídolo Patrick Marques Dourado por me incentivar e apoiar nos momentos mais difíceis, aquele que mesmo distante, esteve sempre perto, aonde às lembranças vem mostrar como é digno ter lealdade.

Á minha namorada Thaynara Emanuelle Carrion Trindade por estar sempre presente e, apesar das dificuldades, acreditou e mostrou que tudo é possível quando sonhamos.

Ao meu primo Deibes Pereira Marques que esteve sempre presente como um irmão.

Ao professor Leonardo Bonato Felix por ser um grande orientador e amigo.

Aos meus amigos da república Jason Cardoso, Filipe Perez, José Francisco, Vinicius Gadioli e Julio Freitas por formar uma grande família durante todo este tempo, uma verdadeira lição de vida.

Aos meus amigos da Engenharia Elétrica que contribuíram na minha formação cultural e profissional, e digo que jamais conseguiria sem eles.

Agradeço a todas as pessoas que se disponibilizaram voluntárias durante a coleta de dados para realização do trabalho.

E finalmente, agradeço ao PIBIC/CNPq pelo apoio financeiro do projeto.

Resumo

Este projeto propõe o desenvolvimento de técnicas computacionais para classificação de estímulos auditivos utilizando Redes Neurais Artificiais (RNAs). Os estímulos foram recolhidos por eletroencefalograma (EEG), que pode ser usado para uma interface cérebro-computador (ICC), onde o sistema permite que alguma pessoa controle um computador usando suas ondas cerebrais. O objetivo é desenvolver um sistema de ICC explorando os efeitos de atenção nas respostas auditivas de regime permanente (ASSRs), no qual o usuário faça escolhas binárias. Este sistema promove a classificação *online* de sinais de EEG registrados em resposta a dois estímulos auditivos simultâneos. Na coleta de sinais, o indivíduo deve focar a atenção em um dos dois estímulos auditivos expostos. Para os estímulos auditivos, são gerados tons de amplitude modulada (AM) com diferentes combinações de portadoras e moduladoras. A realização do treinamento do classificador no modo *offline* é de suma importância, pois será avaliado o melhor treinamento e parâmetros de desempenho que serão inseridos no modo *online*. A classificação é realizada após o tratamento do sinal, seguido da redução de dimensão dos dados utilizando análise dos componentes principais – PCA (do inglês *Principal Component Analysis*) e extração de características baseado no modelo autoregressivo (AR). O plano de trabalho aborda uma forma de avaliar as ASSRs para classificar se o indivíduo encontra-se focando a atenção no estímulo produzido no ouvido esquerdo ou no ouvido direito. Utilizando-se de um banco de dados no modo *offline*, composto por 28 exames feitos nas frequências moduladoras e portadoras (32/38Hz – 500/2000Hz) respectivamente, os melhores resultados se encontram nos canais do EEG (T3, F3, P3, O1, T4, P4, O2, Fz e Pz) que representa uma taxa de acerto de 87,5%, com um tempo para classificação próximo de 20 segundos. Conclui-se, portanto, que as RNAs são eficientes na classificação da atenção seletiva auditiva.

Abstract

This project will develop computational techniques for classification of auditory stimuli using Artificial Neural Networks (ANN), with signals collected by electroencephalogram (EEG). The EEG can be used to design a brain-computer interface (BCI), where the system would allow a person to control a computer using their brain waves. The goal was to develop a system of BCI exploring the effects of attention on auditory steady state responses (ASSRs) in which the user make binary choices. This system promotes the *online* classification of EEG signals recorded in response to two simultaneous auditory stimuli. In the collection of signals, one must focus its attention on one of two auditory stimuli presented to him. For auditory stimuli, tones with amplitude modulation (AM) and different combinations of modulators and carriers are generated. The performance of the classifier in *offline* mode is of paramount importance as the best training will be classified and performance parameters are entered in the *online* mode. Classification is performed after treatment of the signal, followed by reduction of the data dimension using principal component analysis (PCA) and extraction of features based on autoregressive model (AR). The work plan addresses a way to assess the ASSRs to rate if the individual focuses his attention on the stimulus produced in the left or the right ear. Using a database in offline mode consisting of 28 tests performed in modulating and carriers frequencies (32/38Hz - 500/2000Hz) respectively, the best results are found in the channels of EEG (T3, F3, P3, O1, T4, P4, O2, Fz and Pz) which represents a success rate of 87.5%, with a rating around 20 seconds. Therefore, we conclude that the ANN are efficient in the classification of auditory selective attention.

Sumário

1	Introdução.....	14
1.1	Respostas Evocadas.....	14
1.1.1	Resposta Auditiva em Regime Permanente (ASSR).....	14
1.2	Atenção Seletiva Auditiva.....	16
1.3	A Audição Humana.....	16
1.3.1	Transmissão do Som na Cóclea.....	17
1.4	Interface Cérebro-Computador.....	18
1.4.1	Taxa de Transferência de Informação.....	19
1.5	Redes Neurais Artificiais.....	19
1.6	Objetivos.....	22
2	Materiais e Métodos.....	23
2.1	Protocolo Experimental.....	23
2.2	Estímulos.....	23
2.2.1	Protocolo de Estimulação.....	25
2.3	Aquisição de Sinais.....	26
2.3.1	Sistema Internacional 10 - 20.....	26
2.3.2	Coleta de Sinais de EEG.....	27
2.4	Processamento de sinais.....	28
2.4.1	Pré-processamento dos Sinais.....	28
2.4.2	Análise de Componentes Principais.....	29
2.4.3	Coeficientes do Modelo AR.....	31
2.4.4	Análise <i>offline</i> do Sinal.....	32
2.4.5	Validação Cruzada.....	33
2.4.6	<i>Software</i> para Classificação no Modo <i>online</i>	33
3	Resultados e Discussões.....	36
3.1	Avaliação <i>offline</i> na Condição de Atenção.....	36
4	Conclusões.....	39
	Referências Bibliográficas.....	40

Apêndice A – Carta de Aprovação..... 42

Apêndice B – Fluxograma do Sistema..... 43

Lista de Figuras

Figura 1 – Membrana timpânica (Modificado de [23]).....	17
Figura 2 – Propagação do som ao longo da membrana basilar (Fonte: [24]).....	17
Figura 3 – Esquema de um neurônio artificial (Modificado de [33]).....	20
Figura 4 – E-A-RTONE®5A Insert Earphone (Fonte: [34]).	24
Figura 5 – Linha do tempo para estímulos auditivos. Estímulo da orelha esquerda (superior) e orelha direita (inferior), com as frequências portadoras de 500 Hz e 2000 Hz, respectivamente (Fonte: [37]).	26
Figura 6 – Sistema internacional 10-20 (Modificado de [38]).	27
Figura 7 – BrainNet BNT 36 (Fonte: [40]).	28
Figura 8 – Gráfico da variância e desvio padrão por componente principal e da variância acumulada.	30
Figura 9 – Interface homem-máquina para classificação da atenção auditiva.	34
Figura 10 – Taxa de acerto percentual e ITR em função do tempo para classificar o estado da atenção auditiva, com os melhores parâmetros de treinamento: 3 PCAs e ordem 9 do modelo AR.	37

Lista de Tabelas

Tabela 1 – Frequência de modulação corrigida segundo o critério de número primo de oscilações para janela de 1024 pontos.	25
Tabela 2 – Parâmetros de estimulação AM usados em 14 voluntários.	25
Tabela 3 – Taxa de acerto percentual no conjunto de validação, com suas respectivas variações do modelo AR nos dados das PCAs e tempo de classificação próximo de 20 segundos.	36

1 Introdução

A ordem de grandeza de potenciais bioelétricos é, geralmente, de unidades a dezenas de microvolts; o que é considerado baixo quando comparado com as dezenas ou até mesmo centenas de microvolts do eletroencefalograma (EEG) de fundo e com as unidades de milivolts do eletrocardiograma. A atividade neural envolvida no processamento do estímulo sensorial pode ser indiretamente monitorada pela análise do estímulo do potencial evocado (PE) registrado no escalpo, em uma forma não-invasiva de monitoração de integridade de vias neurais. Após de algumas centenas de milissegundos da apresentação do estímulo, os sinais do PE são indistinguíveis da atividade elétrica basal do encéfalo [1].

1.1 Respostas Evocadas

De acordo com Chiappa [2], os PEs podem ser subdivididos em transitórios e de regime permanente. Na PE transitório, 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, o PE transitório tem um início e fim bem demarcados. Caso o estímulo for 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, um PE em regime permanente é alcançado.

Respostas evocadas são usadas de várias formas na clínica médica, por exemplo: avaliação de lesões na via auditiva primária através das respostas evocadas de tronco encefálico [2], audiometria usando respostas auditivas em regime permanente (ASSRs) [3], monitoração de cirurgia através de respostas evocadas somatosensíveis [4] e ativação do EEG em pacientes epiléticos [5].

1.1.1 Resposta Auditiva em Regime Permanente (ASSR)

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 [6]. As ASSRs foram inicialmente descritas por Moller [7], desde então, muitos estudos foram conduzidos sobre as suas principais características e os processos que levam a sua geração. A origem fisiológica dessas respostas reside na propriedade de tonotopia da membrana basilar e no mecanismo da cóclea ativa [8].

Em humanos, as ASSRs evocadas por tons AM mais estudadas são as com frequência de modulação entre 70 e 110 Hz [9], [10], bem como a 40 Hz [11]. Estas respostas a modulações de 40 Hz são amplamente estudadas, apresentando as seguintes características:

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

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 [15], tais respostas apresentam as seguintes vantagens:

- Muito menos afetadas pelo sono [16] e pelo despertar [10];
- Prontamente registradas em crianças [17].

Quando um tom puro modulado em amplitude (tom AM) atinge a cóclea, ocorre vibração da membrana basilar na frequência da portadora [8]. Consequentemente ocorre a deflexão dos cílios das células ciliadas externas, a movimentação da membrana tectória e a deflexão dos cílios das células ciliadas internas [18]. O potencial de ação é deflagrado a partir da movimentação dos cílios em um sentido de movimento. Esse padrão de disparo resulta em um processo de retificação do tom AM que apresentará uma componente espectral adicional na frequência modulante, essa componente será então captada pelo EEG. Dessa forma, o cérebro aparentemente funciona como um demodulador [18].

1.2 Atenção Seletiva Auditiva

O reconhecimento de sons é uma habilidade de identificar um estímulo. A identificação exata de um dado sensorial em termos de conhecimento previamente adquirido é um processo totalmente aprendido. A atenção seletiva implica em atender a alguma atividade mental em detrimento de outras e capacita o indivíduo a monitorar um determinado estímulo significativo, mesmo quando a atenção primária deva-se a outra modalidade sensorial, além de reagir a um determinado estímulo auditivo significativo e ignorar o ruído de fundo ([19], [20], [21]).

Os sentidos humanos captam uma enorme quantidade de informações do ambiente; a maior parte dessas informações, porém, não chega à consciência. A atenção seletiva tem sido alvo de pesquisas para desvendar o mecanismo que possibilita a administração dessas informações permitindo a seleção dos estímulos avaliados como relevantes em determinado momento aos quais o organismo deve responder de forma adequada [22].

1.3 A Audição Humana

A Figura 1 mostra o tímpano e os ossículos, que são responsáveis por conduzir o som da membrana timpânica através da orelha média, pelo qual chega à cóclea. Junto da membrana timpânica se encontra o cabo do martelo. O martelo está ligado à bigorna, de forma que, sempre que o martelo se movimenta a bigorna se move com ele. A extremidade da bigorna está articulada com o estribo, e a placa do estribo se situa contra o labirinto membranoso da cóclea na abertura da janela oval [23].

O centro da membrana timpânica é fixado à extremidade do cabo do martelo, de forma que, esta junta de ligação é puxada pelo músculo tensor do tímpano, que mantém a membrana timpânica tensionada. Tal mecanismo permite que as vibrações do som em todas as partes da membrana timpânica sejam transmitidas aos ossículos [23].

Por alguns ligamentos, os ossículos da orelha média ficam suspensos, de modo que a bigorna e o martelo atuam como uma alavanca, tendo seu fulcro aproximadamente na borda da membrana timpânica [23].

Através da articulação do estribo com a bigorna, a janela oval e o líquido coclear são empurrados para frente a cada vez que a membrana timpânica se move para dentro, e que puxe de volta o líquido todas as vezes que o martelo se movimenta para fora [23].

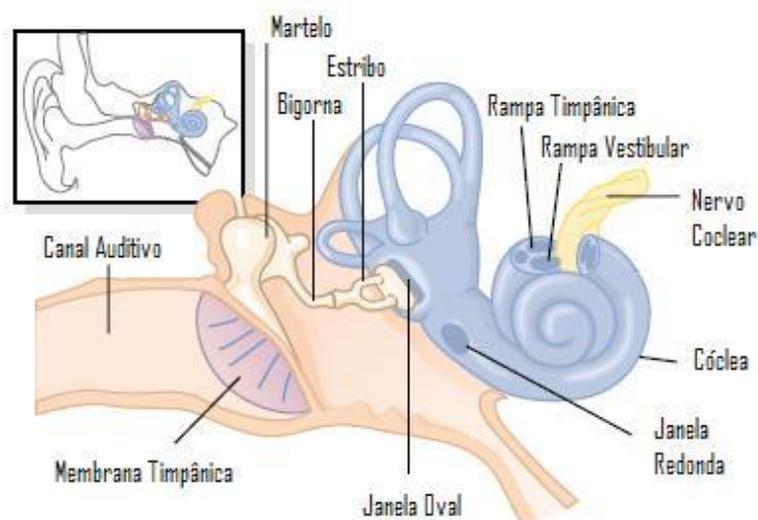


Figura 1 – Membrana timpânica (Modificado de [23]).

1.3.1 Transmissão do Som na Cóclea

Quando uma onda sonora entra na janela oval, faz com que a membrana basilar, na base da cóclea, curve-se na direção da janela redonda. Com esse efeito, cria-se uma tensão elástica nas fibras basilares, iniciando uma onda de líquido que “trafega” ao longo da membrana basilar em direção ao helicotrema. A Figura 2 mostra este efeito [23].

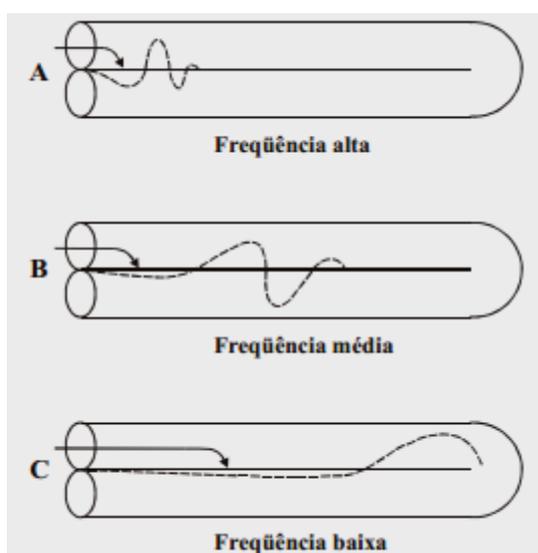


Figura 2 – Propagação do som ao longo da membrana basilar (Fonte: [24]).

A Figura 2 mostra diferentes formas de transmissão de onda sonora, onde cada onda a princípio é considerada relativamente fraca, mas tornam-se forte quando chega à parte da membrana basilar que possui frequência de ressonância natural igual à frequência do som. Neste instante a membrana basilar vibra para frente e para trás, dissipando a energia da onda e, conseqüentemente a onda deixa de existir e de se propagar pela distância restante ao longo da membrana basilar. Estudos da propagação ondulatória mostram que as ondas trafegam rapidamente ao longo do canal no início da membrana basilar, mas tornam-se lentas à medida que se afastam em direção à cóclea. A rapidez das ondas permite que sons de alta frequência cheguem longe o suficiente na cóclea para se propagarem e se separarem na membrana basilar [23].

1.4 Interface Cérebro-Computador

Uma Interface Cérebro-Computador (ICC) é um sistema de comunicação independente dos caminhos normais de saída do cérebro para nervos e músculos periféricos [25]. As ICCs objetivam fornecer uma comunicação direta e não-muscular, estabelecendo um canal de controle entre o cérebro humano e um computador [26]. A ICC pode ser definida como um sistema capaz de monitorar a atividade cerebral do usuário e traduzir sua intenção em comandos, sem ativar qualquer músculo ou nervo periférico [27].

O EEG pode ser usado em uma interface cérebro-computador, 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 [28].

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 [29].

Hillyard et al. [30] 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.

1.4.1 Taxa de Transferência de Informação

Capacidade de canal é a quantidade de informação transmitida/recebida pela interface por unidade de tempo, que é a medição padrão de sistemas de comunicação. Obermaier et al. [31], mostrou que esta taxa depende da precisão e da velocidade da interface. A capacidade de canal estima a taxa máxima teórica de transferência de informação do usuário para o sistema. Esta informação é uma estimativa matemática, e não informação real que a aplicação transmite. Essa taxa de bits, também conhecida como Taxa de Transferência de Informação (ITR, do inglês *Information Transfer Rate*), é utilizada para sistemas de comunicação em geral [32]. Para uma ICC com N comandos e s comandos sendo executados por minuto, onde cada comando é decodificado corretamente com probabilidade P , a taxa de transferência de informação, em bits/minuto, é dada por:

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

1.5 Redes Neurais Artificiais

Através de processadores biológicos que operam em paralelo, o cérebro humano consegue processar informações. O neurônio biológico é uma célula do sistema nervoso cerebral que conduz impulsos sob determinadas condições de operação. Baseado em estudos

do neurônio biológico, os neurônios artificiais utilizados em redes neurais artificiais são não-lineares e realizam funções simples [33].

McCulloch & Pitts (1943) propôs um modelo de neurônio que engloba as principais características de uma rede neural biológica. Este modelo é utilizado em diferentes arquiteturas de redes neurais artificiais, de modo que cada neurônio pode ser implementado de acordo com a Figura 3. As entradas dos sinais na rede são espelhadas pelo conjunto $\{x_1, x_2, x_3, \dots, x_m\}$, que são análogos aos impulsos elétricos externos captados pelos dendritos no neurônio biológico [33].

Os pesos sinápticos $\{w_{k1}, w_{k2}, \dots, w_{km}\}$ representam as ponderações exercidas por junções sinápticas de acordo com o neurônio biológico. Da mesma forma, cada entrada $\{x_i\}$ do neurônio é executada por meio de suas multiplicações pelos respectivos pesos sinápticos $\{w_{ki}\}$. Com isso é possível verificar que a saída do corpo celular artificial (v_k), é a soma ponderada de suas entradas [33].

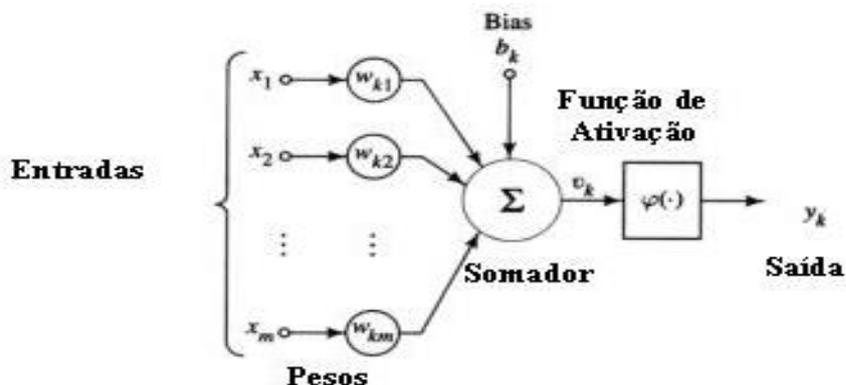


Figura 3 – Esquema de um neurônio artificial (Modificado de [33]).

A Figura 3 mostra que o neurônio artificial é constituído de sete elementos básicos, são eles:

- a) Sinais de entrada $\{x_1, x_2, x_3, \dots, x_m\}$

Representam os valores assumidos pelas variáveis do sistema. Geralmente, os sinais de entrada são normalizados para aumentar a eficiência computacional dos algoritmos de aprendizagem;

- b) Pesos sinápticos $\{w_{k1}, w_{k2}, \dots, w_{km}\}$

Servem para ponderar cada uma das variáveis de entrada do sistema, permitindo-se quantificar as suas relevâncias em relação à funcionalidade do respectivo neurônio;

c) Combinador linear $\{\Sigma\}$

Tem a função de agregar todos os sinais de entrada que foram ponderados pelos determinados pesos sinápticos a fim de produzir um valor de potencial de ativação;

d) Limiar de ativação $\{b_k\}$

Tem a função de especificar qual será o patamar ideal para que o resultado produzido pelo combinador linear possa gerar um valor de disparo em direção à saída do neurônio;

e) Potencial de ativação $\{v_k\}$

É a diferença de valor entre o combinador linear e o limiar de ativação. Se o resultado é positivo, ou seja, se $v_k \geq b_k$ então o neurônio produz um potencial excitatório; caso contrário, o potencial será inibitório;

f) Função de ativação $\{\varphi\}$

A função de ativação limita a saída do neurônio dentro de um intervalo de valores a serem assumidos pela sua própria imagem funcional;

g) Sinal de saída $\{y_k\}$

O sinal de saída é produzido pelo neurônio em relação a um determinado conjunto de sinais de entrada do sistema.

As equações 2 e 3 mostram o resultado produzido pelo neurônio artificial proposto por McCulloch & Pitts.

$$v_k = \sum_{i=1}^m w_{ki} \cdot x_i - b_k \quad (2)$$

$$y_k = \varphi(v_k) \quad (3)$$

Além do mais, o neurônio artificial segue um algoritmo de funcionamento, ou seja:

- Primeiro será apresentado as variáveis de entrada do neurônio [33];

- Seguido pela multiplicação de cada entrada do neurônio pelo seu respectivo peso sináptico [33];
- Logo, será obtido o potencial de ativação produzido pela soma ponderada dos sinais de entrada, subtraindo-se o limiar de ativação [33];
- Por fim, a aplicação de uma função de ativação, tendo-se como objetivo limitar a saída do neurônio [33];

1.6 Objetivos

Desenvolver técnicas computacionais para classificar os estados de atenção nas respostas evocadas de regime permanente de indivíduos sob estimulação binaural usando Redes Neurais Artificiais (RNA). 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 de eletroencefalograma, automaticamente, registrados em resposta a dois estímulos auditivos simultâneos através de Redes Neurais Artificiais. 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;
- Desenvolver um método de classificação *online* dos estados de atenção utilizando RNA, baseado nos achados fisiológicos da atenção seletiva auditiva.
- Avaliar o desempenho do classificador na aplicação em uma ICC auditiva.

2 *Materiais e Métodos*

2.1 *Protocolo Experimental*

Todos os exames foram realizados no Departamento de Engenharia Elétrica da Universidade Federal de Viçosa – MG (UFV), no Núcleo Interdisciplinar de Análise de Sinais (NIAS). A sala do experimento é dotada de uma cadeira inclinável confortável, sistema de refrigeração condicionado e uma cabine audiométrica.

Tais experimentos foram aprovados pelo comitê de Ética em Pesquisa com Seres Humanos da UFV, e está inserido no projeto de pesquisa intitulado “Investigação da atenção seletiva auditiva para interface cérebro-computador”. Segue carta de aprovação no Apêndice A.

2.2 *Estímulos*

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

$$S(t) = A \frac{1}{1 + \lambda} \sin(2\pi f_c t) (1 + \lambda \sin(2\pi f_m t)) \quad (4)$$

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.

Os estímulos foram gerados digitalmente pelo Matlab7.10.0 (R2010a) através da ferramenta GUI (Graphical User Interface). Tal ferramenta permite construir interfaces gráficas que podem interagir com o usuário. Na interface construída foi possível escolher variadas combinações de frequências moduladoras e portadoras para o estímulo sonoro. As frequências portadoras de 500, 1000 e 2000 Hz poderiam ser combinadas nos ouvidos esquerdo e direito do voluntário, com uma intensidade sonora de estímulo de 75,8, 71,2, 60,6, 44,7 e 34,7 dB. Os fones de ouvido foram calibrados para cada frequência e intensidade

sonora estabelecidos. A interface apresenta campos livres para escolha das frequências moduladoras de cada estímulo, número de pontos das janelas para o cálculo da FFT (Transformada rápida de Fourier) dos sinais, frequência de amostragem e o tempo desejado dos estímulos.

Na reprodução dos estímulos sonoros foram utilizados fones de inserção para audiometria E-A-RTONE®5A Insert Earphone, como mostrado na Figura 4. Estes fones funcionam como um sistema de entrega som, além de selarem os ouvidos do voluntário, atenua os ruídos em torno de 30 a 40 dB. O dispositivo consiste em um transdutor de dimensões pequenas que é introduzido no canal auditivo por meio de um tubo plástico flexível, com plugue de terminação macia.



Figura 4 – E-A-RTONE®5A Insert Earphone (Fonte: [34]).

Para que se pudesse reduzir o espalhamento espectral foi utilizado um método de correção da frequência de estimulação aplicado a priori. Felix et al. [35] mostrou que o vazamento espectral na detecção objetiva de 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 uma trecho de comprimento fixo.

De acordo com tal método, 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 $L.T_0$) deve ser um múltiplo inteiro do período de amostragem (T_s). Ou seja:

$$\frac{f_s}{f_m} = \frac{N}{L} \quad (5)$$

Onde N é o número de pontos de cada janela, f_s é a frequência de amostragem e f_m é a frequência da moduladora utilizada no estímulo. Neste estudo as frequências de estimulação foram 32 e 38 Hz corrigidas de acordo com a Equação (5). 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, ou seja, $f_s = 601,5$ Hz. Utilizaram-se janelas de 1024 pontos, de forma a se obter uma frequência de modulação mais próxima para um número inteiro de ciclos em cada janela. Os valores corrigidos para as frequências de estimulação são mostrados na Tabela 1.

Tabela 1 – Frequência de modulação corrigida segundo o critério de número primo de oscilações para janela de 1024 pontos.

Frequência de modulação (Hz)	Frequência de modulação corrigida (Hz)
32	31,132
38	39,356

2.2.1 Protocolo de Estimulação

Neste projeto utilizou-se de 14 voluntários, onde todos foram submetidos a três etapas de estimulação binaural, submetidos a estímulos gerados por tons AM, como mostra a Tabela 2.

Tabela 2 – Parâmetros de estimulação AM usados em 14 voluntários.

	Moduladora (Hz)	Portadora (Hz)
Ouvido Esquerdo	31,132	500
Ouvido Direito	39,356	2000

Os estímulos foram executados na faixa de 30 a 40 Hz, pois nestas frequências as ASSR apresentam as maiores respostas, além de serem mais influenciadas pelo estado de atenção ([12], [15], [36]). As etapas de estimulação binaural foram executadas conforme as instruções mostradas abaixo:

- **Indivíduo não foca atenção:** Os indivíduos foram orientados a não focar a atenção a nenhum dos estímulos.
- **Indivíduo foca atenção no ouvido direito:** Os indivíduos foram orientados a focar a atenção no estímulo do ouvido direito e desprezar o estímulo do ouvido esquerdo.
- **Indivíduo foca atenção no ouvido esquerdo:** Os indivíduos foram orientados a focar a atenção no estímulo do ouvido esquerdo e desprezar o estímulo do ouvido direito.

Durante o procedimento, a estimulação de cada indivíduo durou 2 minutos com intervalos entre estimulações de 30 segundos. Antes de cada etapa na qual o indivíduo tivesse que focar a atenção em um determinado estímulo, era estimulada apenas a orelha (monoaural) no lado do foco de atenção durante dez segundos, a fim de instruir e facilitar o indivíduo na tarefa cognitiva. A linha do tempo para estímulos auditivos em 14 voluntários é ilustrada na Figura 5.

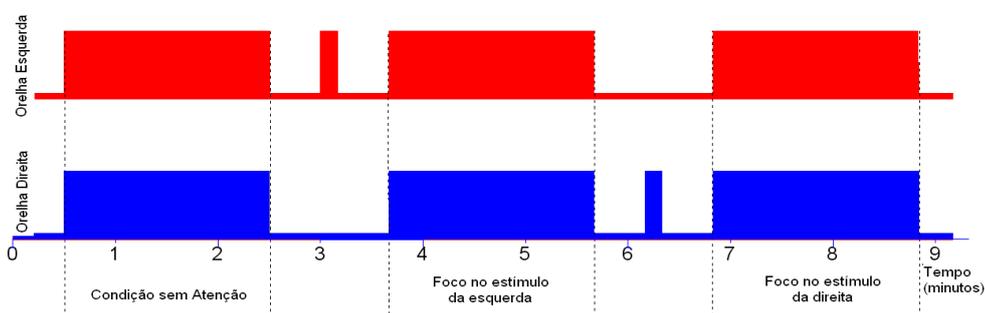


Figura 5 – Linha do tempo para estímulos auditivos. Estímulo da orelha esquerda (superior) e orelha direita (inferior), com as frequências portadoras de 500 Hz e 2000 Hz, respectivamente (Fonte: [37]).

2.3 *Aquisição de Sinais*

2.3.1 Sistema Internacional 10 - 20

Na coleta de sinais de EEG utilizou-se o sistema internacional 10-20. Este sistema padroniza o posicionamento dos eletrodos que são colocados no escalpo de cada voluntário.

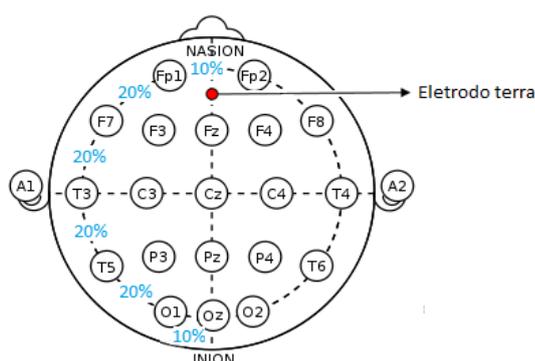


Figura 6 – Sistema internacional 10-20 (Modificado de [38]).

A realização de um eletroencefalograma deve seguir algumas normas técnicas para uma boa coleta de sinais. Utilizando o sistema internacional 10-20, o couro cabeludo deve estar limpo e seco e os cabelos devem ter sido lavados na noite anterior. O paciente não pode utilizar nenhum tipo de produto no cabelo, como por exemplo, gel fixador e laquê, pois aumentam a impedância e dificultam a fixação dos eletrodos no escalpo [39].

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 [39].

2.3.2 Coleta de Sinais de EEG

Os sinais foram coletados usando o amplificador de sinais biológicos (BrainNet BNT-36), mostrado na Figura 7, 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 19 e 28 anos e sem problemas auditivos aparentes.



Figura 7 – BrainNet BNT 36 (Fonte: [40]).

2.4 Processamento de sinais

2.4.1 Pré-processamento dos Sinais

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

Posteriormente, os sinais são condicionados a processos de filtragem e remoção de artefatos. A cada trecho adquirido será aplicado um filtro passa-faixa, observando a frequência da moduladora, bem como um filtro rejeita-faixa de 60 Hz, para remover a componente espectral da rede elétrica, que geralmente apresenta elevado nível de potência [37].

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.

Infantosi et al. [41] 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. Todos os sinais processados foram definidos com o mesmo tamanho, e deles eram subtraídos o sinal de referência Oz.

2.4.2 Análise de Componentes Principais

Uma das dificuldades inerentes da estatística multivariada é o problema de visualização de dados. Felizmente, em conjuntos de dados com muitas variáveis, grupos de variáveis, muitas vezes se movem juntos. Uma razão para isto é que mais do que uma variável pode estar medindo o mesmo princípio de condução que regula o comportamento do sistema. A instrumentação permite medir dezenas de variáveis do sistema. Quando isso acontece, pode-se aproveitar essa redundância de informações. Pode-se simplificar o problema, substituindo um grupo de variáveis por uma única variável nova.

A análise dos componentes principais – ACP ou PCA (do inglês *Principal Component Analysis*) é um método que tem por finalidade básica, a análise dos dados usados visando sua redução, eliminação de sobreposições e a escolha das formas mais representativas de dados a partir de combinações lineares das variáveis originais.

A PCA é um dos métodos estatísticos de múltiplas variáveis mais simples, e é considerada a transformada linear ótima, dentre as transformadas de imagens, sendo muito utilizada pela comunidade de reconhecimento de padrões.

Da perspectiva de reconhecimento estatístico de padrões, o valor prático da análise de componentes principais é que ela fornece uma técnica efetiva para a redução de dimensionalidade. Em particular, podemos reduzir o número de características necessárias para a representação efetiva de dados descartando aquelas combinações lineares que têm variâncias pequenas e retendo apenas aqueles termos que têm variâncias grandes [42].

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

- Obter os dados ou as M amostras de vetores de dimensão n ;
- Calcular a média ou o vetor médio destes dados;
- Subtrair a média de todos os itens dos dados;

- Calcular a matriz de covariância usando todas as subtrações. Ela é o resultado da média do produto de cada subtração por ela mesma e terá dimensão $n \times n$;
- Calcular os autovalores e autovetores 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).

As etapas foram seguidas de forma a reduzir o grande volume dados contidos nos exames. Após o pré-processamento, onde um filtro passa-faixa foi utilizado, e onde foram removidos artefatos, definiu-se que seriam usadas as quatro primeiras componentes analisadas, pois estas correspondiam em todos os casos quase que 90% das informações contidas nos dados.

Utilizando-se do método da PCA no grupo de informações contido em todos os eletrodos do EEG, obteve-se uma nova matriz, onde se poderia escolher o número de componentes principais. Analisando a Figura 8, que representa a variância por componente principal e a variância acumulada das PCAs, pode-se perceber que as quatro primeiras componentes explicam cerca de 90% da variabilidade total nas avaliações padronizadas, de modo que isto pode ser um caminho razoável para reduzir as dimensões, a fim de visualizar os dados.

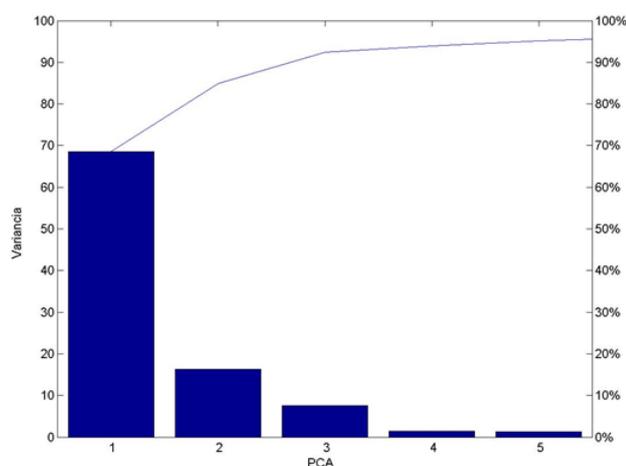


Figura 8 – Gráfico da variância e desvio padrão por componente principal e da variância acumulada.

Esse processo seleciona as principais características contidas no grupo de informações analisadas. O que se fez foi à seleção de características, ou seja, o espaço de dados é transformado em um espaço de características que, em teoria, tem exatamente a mesma dimensão que o espaço original de dados. Porém, selecionamos apenas as características efetivas, ou seja, aquelas que realmente carregam informações relevantes sobre o registro feito.

2.4.3 Coeficientes do Modelo AR

Modelagem matemática é a área do conhecimento que estuda maneiras de desenvolver e implementar modelos matemáticos de sistemas reais. Na modelagem caixa branca é necessário conhecer a fundo o sistema a ser modelado e estar bem familiarizado com o sistema, além de conhecer as relações matemáticas que descrevem os fenômenos envolvidos. 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 [43].

Identificação de sistemas é uma área do conhecimento que estuda técnicas variadas de modelagem matemática. Uma das principais características desse tipo de técnica é que pouco ou nenhum conhecimento prévio do sistema é necessário. Tais métodos são também referidos como modelagem (ou identificação) caixa preta. Em muitos casos será preferível usar técnicas de identificação de sistemas [43].

O modelo auto-regressivo (AR do inglês *autoregressive*) é um modelo estocástico e é útil na representação de um grande número de séries temporais. Este modelo corresponde a um filtro que tem como entrada o ruído branco de média 0 e desvio padrão 1 e como saída o sinal desejado [43]. 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:

$$y(k) = a_1 y(k-1) + a_2 y(k-2) + \dots + a_p y(k-p) + a_t \quad (6)$$

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

Após compactação das informações utilizando PCA, usou-se o modelo AR nas informações contidas nas PCAs com o objetivo de reduzir ainda mais o conjunto de dados. O modelo AR criado varia da ordem 1 até a ordem 10, e seus coeficientes foram utilizados para treinamento e validação do classificador.

2.4.4 Análise *offline* do Sinal

Neste modo utilizou-se 28 exames de 14 indivíduos adultos (todos homens) com idade entre 19 e 28 anos, sem sinais de patologias neurológicas submetidos as mesmas frequências moduladoras e portadoras (32/38Hz – 500/2000Hz) respectivamente. No algoritmo feito em MATLAB fizeram-se testes variando-se o número de PCA ($m = 1$ até $m = 4$) como explica a subseção 2.4.2, e ao mesmo tempo, variou-se a ordem do modelo AR ($n = 1$ até $n = 10$) para extração de características na matriz de dados PCA, utilizando seus coeficientes. Essas variações têm como objetivo observar o comportamento de generalização da RNA. O tamanho da entrada para treinamento do classificador foi de 70% dos dados de uma matriz $E_{(m,n) \times Exames}$ referente a atenção no ouvido esquerdo mais 70% dos dados de uma matriz $D_{(m,n) \times Exames}$ referente a atenção no ouvido direito, onde m e n denotam o número de PCA e ordem do modelo AR respectivamente, e $Exames$ denota o número de exames utilizados no processo. Os 30% dos dados não utilizados destas matrizes serviram para o classificador no processo de validação. O alvo do classificador visa distinguir a atenção no ouvido esquerdo e a atenção no ouvido direito.

No processo de classificação, adotou-se uma composição de rede simples, *feedforward network*, cuja função de formação foi baseada na otimização de *Levenberg-Marquardt*, no qual se fez sucessivas simulações, adotando sempre uma camada neural escondida e variando-se o número de neurônios que a compunham de 1 até 10. A função de transferência adotada foi à hiperbólica sigmóide, seguida de uma camada de saída que foi ativada por uma função de transferência linear.

Durante o treinamento foi realizado o processo de validação cruzada, a qual é uma ferramenta útil no processo de mineração dos dados.

2.4.5 Validação Cruzada

Uma das técnicas estatísticas mais utilizadas para seleção das melhores topologias candidatas é a validação cruzada (*cross-validation*), cujo propósito é avaliar a aptidão de cada uma quando aplicadas a um conjunto de dados que seja diferente daquele usado no ajuste de seus parâmetros internos.

Um método de validação cruzada utilizada para dimensionamento estrutural de redes neurais é denominado de *k*-partições (*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. Por conseguinte, o processo de aprendizado se repete *k* vezes até que todas as partições tenham sido utilizadas como subconjunto de teste [33].

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. Utiliza-se a validação cruzada depois de criar uma estrutura de mineração e os modelos de mineração relacionados para assegurar a validade do modelo [44]. O método de validação foi aplicado antes do treinamento do classificador, ou seja, na entrada da rede neural composta pelos coeficientes do modelo AR, assegurando ainda mais a validade da classificação e evitando falsos positivos.

2.4.6 Software para Classificação no Modo *online*

No processamento dos dados adquiridos durante a realização dos exames, foi necessário desenvolver um software de comunicação com o Eletroencefalógrafo (Brainnet-36). A comunicação do aparelho com o computador é feita por um cabo tipo par trançado para rede padrão Ethernet. O protocolo de comunicação usado pelo Brainnet-36 é o UDP (do inglês, *User Datagram Protocol*). O Brainnet-36 envia ao computador um pacote com os dados a cada 20 amostras coletadas, ou seja, o datagrama enviado tem 720 amostras (20 amostras para cada um dos 36 canais). Os sinais do Brainnet-36 são digitalizados com resolução de 16 bits, onde as amostras são divididas em dois conjuntos de 720 bytes (8 bits cada amostra).

Este sistema possui uma plataforma de aquisição e processamento de dados, onde foi incorporado à função de classificação da atenção auditiva utilizando-se os parâmetros de treinamento extraídos no modo *offline*. A Figura 9 mostra a interface desenvolvida para comunicação do usuário com o computador.

Durante a coleta de dados do EEG, o software de comunicação realiza todo o procedimento de pré-processamento e processamento do sinal da mesma forma feita no modo *offline*, onde a classificação da atenção auditiva é realizada de acordo com o critério de parada proposto. O critério de parada 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.

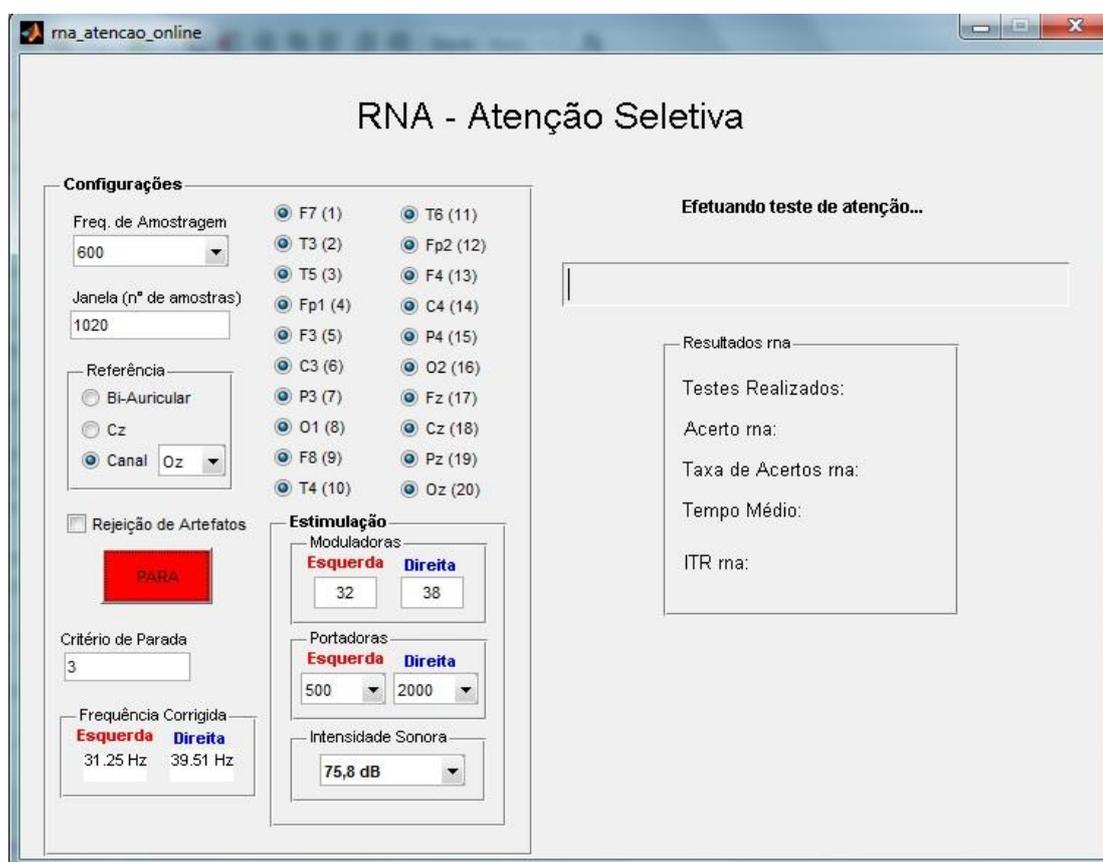


Figura 9 – Interface homem-máquina para classificação da atenção auditiva.

Na interface desenvolvida 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

3.1 Avaliação offline na Condição de Atenção

Na Tabela 3 observam-se os resultados obtidos após o processo de validação do classificador, utilizando as combinações de frequências moduladoras e portadoras (32/38Hz – 500/2000Hz) respectivamente, feito em 14 voluntários.

Os valores representam a taxa de acerto percentual no conjunto de validação para cada composição da RNA, variando-se o número de componentes principais e a ordem do modelo AR, onde o tempo de classificação foi de 20 segundos. Foram utilizados 30% dos dados para validação e nove canais do EEG, sendo eles T3, F3, P3, O1, T4, P4, O2, Fz e Pz os quais representam a combinação com melhor resposta de acordo com [37].

Tabela 3 – Taxa de acerto percentual no conjunto de validação, com suas respectivas variações do modelo AR nos dados das PCAs e tempo de classificação próximo de 20 segundos.

Componentes Principais (m)	Ordem do modelo AR (n)						
	4	5	6	7	8	9	10
1 ^a	75	62,5	75	75	75	62,5	75
1 ^a e 2 ^a	75	62,5	75	75	62,5	62,5	62,5
1 ^a , 2 ^a e 3 ^a	62,5	62,5	75	62,5	62,5	87,5	87,5
1 ^a , 2 ^a , 3 ^a e 4 ^a	75	62,5	75	75	75	87,5	87,5

Ao decorrer das variadas simulações entre o número de PCA, o número de coeficientes do modelo AR e o número de neurônios artificiais, adotou-se uma configuração de RNA onde se observou a estagnação na taxa de acerto e no erro proposto na rede a partir de um número de neurônios na camada escondida. Analisando a Tabela 3 percebe-se que o modelo definido para o classificador foi uma RNA constituída de 1 neurônio artificial na camada neural escondida, dotada de um número de componentes principais igual a 3 e ordem do modelo AR igual a 9, com uma taxa de acerto de 87,5%. É importante ressaltar que os resultados validados com o modelo AR de ordem 1 até a ordem 3 foram insignificantes, logo foram descartados do projeto.

A fim de avaliar a aplicação do método desenvolvido como classificador para uma ICC, foi calculada a taxa de transferência de informação de acordo com a Equação (1). A Figura 10 mostra um valor máximo de 1,6 bits/minuto para uma ITR com 17 segundos. Além do mais, essa taxa de transferência de informação está diretamente relacionada à taxa de acerto, pois como mostra a Equação (1), a ITR depende da precisão do classificador e do tempo para se obter uma resposta, observando-se uma redução da ITR com o passar do tempo.

Da Figura 10 se observa uma taxa máxima de acerto de 87,5% em algumas ocasiões de tempo durante dois minutos. Nota-se que cerca de 20 segundos já são suficientes na classificação da atenção auditiva, visto que o classificador terá máximo desempenho utilizando-se de uma menor quantidade de informações.

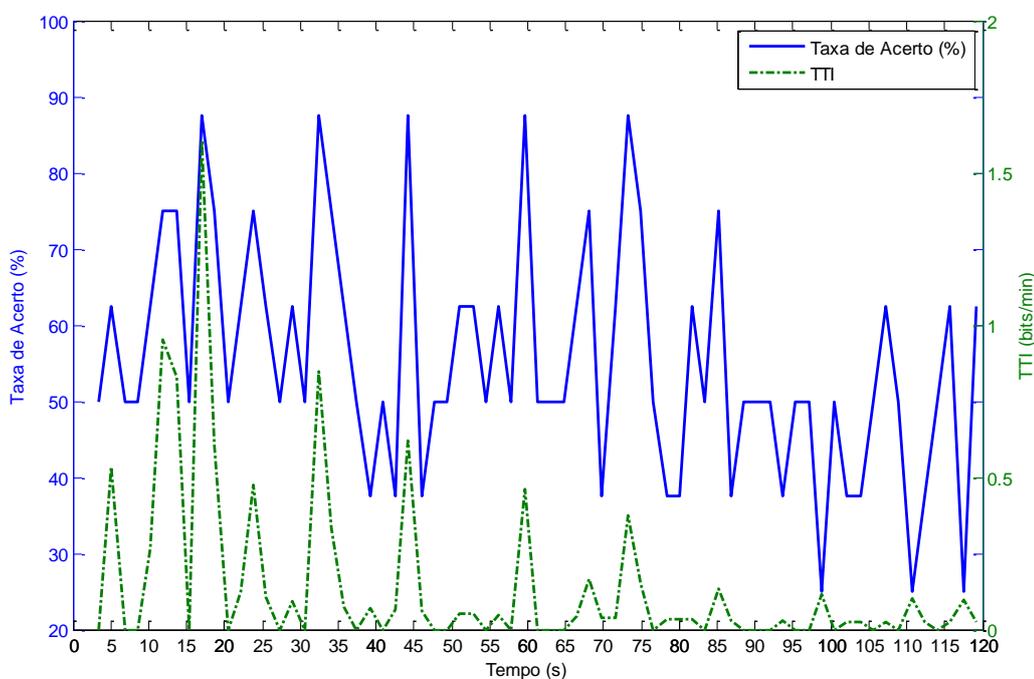


Figura 10 – Taxa de acerto percentual e ITR em função do tempo para classificar o estado da atenção auditiva, com os melhores parâmetros de treinamento: 3 PCAs e ordem 9 do modelo AR.

Durante o treinamento do classificador, observou-se dificuldade no processo de aprendizagem por parte de alguns erros na hora da escolha dos parâmetros. Além do mais, existem fatores que podem ter contribuído ainda mais no desempenho da RNA, são eles:

- Os voluntários poderiam estar com sono durante a coleta de dados, o que enfraqueceu a amplitude de resposta.
- Alguns indivíduos podem sofrer de algum distúrbio de atenção, o que impediu a concentração durante a coleta.

- Durante os exames de EEG alguns eletrodos poderiam estar mal conectados ao escalpo, o que dificultou na transmissão de dados.
- A duração do tempo dos estímulos, pois nem todos os voluntários começam a responder a estímulos no mesmo instante, alguns necessitam de maior tempo para apresentar resposta.

4 *Conclusões*

Pode-se fazer algumas observações acerca do uso de redes neurais artificiais no processo de classificação de padrões e sua capacidade de generalização durante o processo de aprendizado. O desempenho da RNA para problemas de classificação que envolve muitas variáveis é alcançado com custo significativo em complexidade computacional.

O caminho seguido mostra a capacidade da RNA em trabalhar com o problema de classificação, onde todos os parâmetros de entrada da rede neural foram variados, de modo que a quantidade de informações usadas durante o experimento pudesse testar a eficiência do processo de classificação.

No problema tentou-se avaliar a atenção seletiva auditiva, ou seja, avaliar se o indivíduo estava focando a atenção no estímulo do ouvido esquerdo ou do ouvido direito. Para um experimento feito em 14 voluntários, com as respectivas frequências moduladoras e portadoras (32/38Hz – 500/2000Hz) e uso dos canais T3, F3, P3, O1, T4, P4, O2, Fz e Pz do EEG, observou-se uma taxa máxima de acerto percentual de 87,5% em quatro dos vinte e oito parâmetros especificados na Tabela 3. A escolha de apenas uma destas quatro combinações foi feita baseada no custo computacional, visto que, no modelo escolhido com 3 PCAs e ordem 9 do modelo AR, exige um menor número de informações em relação aos outros três modelos, obtendo o mesmo resultado em um menor tempo de classificação.

Conclui-se assim a importância do processo de mineração das informações, de modo a variar os parâmetros do classificador durante o treinamento e observar o melhor desempenho. O uso de RNA é uma técnica capaz de detectar o efeito da atenção no estímulo que evoca ASSR, o que possibilita o uso de ASSRs como paradigmas para ICC.

Referências Bibliográficas

- [01] L. B. Felix (2006). Detecção Objetivas de Respostas Auditivas em Regime Permanente: aplicação em exames audiológicos. Tese de Doutorado, UFMG. 14
- [02] K. H. Chiappa (1997). Evoked Potentials in Clinical Medicine, New York: Raven Press, 2nd edition, 1997. 14
- [03] A. Dimitrijevic, M. S. John, P. Van Roon, D. W. Purcell, J. Adamonis, J. Ostroff, J. M. Nedzelski, and T. W. Picton (2002). Estimating the audiogram using multiple auditory steady-state response. *J. Am. Acad. Audiol.*, 13: 205-224, 2002. 14
- [04] M. L. Schwartz, T. F. Panetta, B. J. Kaplan, A. D. Legatt, W. D. Suggs, K. R. Wengerter, M. L. Marin, and F. J. Veith (1996). Somatosensory evoked potential monitoring during carotid surgery. *Cardiovascular Surgery*, 4:77-80, 1996. 14
- [05] G. Celesia (1998). Visual evoked potentials and electroencephalograms. In: Niedermeyer, E., Lopes da Silva, F. H (eds), *Electroencephalography – Basic principles, Clinical Applications and Related Fields*, 1998. Cap. 10. 14
- [06] S. Kuwada, R. Batra, and V. I. Maher (1986). Scalp potentials of normal and hearing-impaired subjects in response to sinusoidally amplitude modulated tones. *Hear. Res.*, 21(2):179-192, 1986. 15
- [07] A. R. Moller (1974). No abstract responses of units in the cochlear nucleus to sinusoidally amplitude modulated tones, *Exp Neurol.*, v. 45, n. 1, pp. 105-117. 15
- [08] M. F. Bear, B. W. Connors, M. A. Paradiso (2008). Os Sistemas Auditivo e Vestibular, In: *Neurociências: desvendando o sistema nervoso*. cap. 11. 15
- [09] L. T. Cohen, F. W. Rickards and G. M. Clark (1991). A comparison of steady-state evoked potentials to modulated tones in awake and sleeping humans. *J. Acoust. Soc. Am.*, 90(5):2467-2479, 1991. 15
- [10] E. C. Levi, R. C. Folsom and R. A. Dobie (1993). Amplitude modulation following response (amfr) - effects of modulation rate, carrier frequency, age and state. *Hear. Res.*, 68(1):42-52, 1993. 15
- [11] R. Galambos, S. Makeig and P. J. Talmachoff (1981). A 40 hz auditory potential recorded from the human scalp. *P. Natl. Acad. Sci-Biol.*, 78(4):2643-2647, 1981. 15
- [12] R. D. Linden, K. B. Campbell, G. Hamel (1985). Human auditory steady-state potentials during sleep. *Ear Hearing*, v. 6, n. 1, pp. 167-174. 15, 25
- [13] D. R. Stapells, R. Galambos, J. A. Costello and S. Makeig (1988). Inconsistency of auditory middle latency and steady-state responses in infants. *Electroenceph. Clin. Neurophysiol.*, 71(4):289-295, JUL-AUG 1988. 15
- [14] G. Plourde and T. W. Picton (1990). Human auditory steady-state response during general anesthesia. *Anesth. Analg.*, 71(5):460-468, Nov. 1990. 15
- [15] M. S. John, O. G. Lins, B. L. Boucher and T. W. Picton (1998). Multiple auditory steady-state responses (master): Stimulus and recording parameters. *Audiology*, 37(1):59-82, 1998. 15, 25
- [16] M. Aoyagi, T. Kiren, Y. Kim, Y. Suzuki, T. Fuse, and Y. Koike (1993). Optimal modulation frequency for amplitude modulation following response in young children during sleep. *Hear. Res.*, 65(1-2):253-261, Feb 1993. 15
- [17] F. W. Rickards, L. E. Tan, L. T. Cohen, O. J. Wilson, J. H. Drew e G. M. Clark (1994). Auditory steady-state evoked potential in newborns. *Brit. J. Audiol.*, 28(6):327-337, Dec. 1994. 15
- [18] O. G. Lins, T. W. Picton (1995). Auditory Steady-State Responses to Multiple Simultaneous Stimuli, *Electroenceph. Clin. Neurophysiol.*, v. 96, pp. 420-432. 15
- [19] A. Boothroyd (1986). *Speech acoustics and perception*. Austin: Pro-ed; 1986. p. 65-73. 16
- [20] L. D. Pereira (1993). *Processamento Auditivo*. *Temas Desenv.* 1993; 2(11): 7-14. 16
- [21] L. D. Pereira, M. Cavadas (1998). *Processamento auditivo central*. In: Frota S. *Fundamentos em fonoaudiologia: audiologia*. Rio de Janeiro: Guanabara Koogan; 1998 p. 63-68. 16
- [22] M. Giard, A. Fort, Y. Mouchetant-Rostaing (2000). Neurophysiological mechanisms of auditory selective attention in humans, *Frontiers in Bioscience*, v. 5, pp. 84-94. 16
- [23] A. C. Guyton, J. E. Hall (2006). *Tratado de Fisiologia Médica*. 11ª. s.l. : Elsevier, 2006. pp. 651-655. 16, 17, 18
- [24] Página da internet acessada no dia 30 de janeiro de 2014: <http://www.afh.bio.br/sentidos/Sentidos4.asp>. 17
- [25] J. R. Wolpaw (2007). Brain computer interfaces as new brain output pathways, *The Journal of Physiology*, v. 579, n. 3, pp. 613-619. 18
- [26] J. R. Wolpaw, N. Birbaumer, D. J. Mcfarland (2002). Brain-Computer Interfaces for communication and control, *Clin Neurophysiol*, v. 113, pp. 767-791. 18

- [27] J. R. Millán, R. Rupp, G. R. Muller-Putz (2010). Combining Brain-Computer Interfaces and Assistive Technologies: State-of-the-Art and Challenges, *Frontiers in Neuroscience*, v. 4, pp. 1-15. 18
- [28] N. Birbaumer, A. Kubler, N. Ghanayim, T. Hinterberger, J. Perelmouter, J. Kaiser, I. Iversen, B. Kotchoubey, N. Neumann, and H. Flor (2000). The thought translation device (ttt) for completely paralyzed patients. *IEEE Transactions on Rehabilitation Engineering*, 8:190-193, 2000. 18
- [29] L. A. Riggs, F. Tatloff, J. C. Cornsweet, and T. N. Cornsweet (1953). The Disappearance of Steadily Fixated Visual Test Objects. *Journal of the Optical Society of America*, 43(6), 495-501. 19
- [30] S. A. Hillyard, R. F. Hink, V. L. Schwent, and T. W. Picton (1973). Electrical signs of selective attention in the human brain. *Science*, 182:174-179, 1973. 19
- [31] B. Obermaier, C. Neuper, C. Guger (2001). Information Transfer Rate in a Five-Class Brain-Computer Interface, *IEEE Trans. on Neural Systems and Rehabilitation Engineering*, v. 9, n. 3, pp. 283-288. 19
- [32] C. E. Shannon (1948). The mathematical theory of communication, *The Bell System Technical Journal*, v. 27, pp. 379-423. 19
- [33] I. N. Silva, D. H. Spatti e R. A. Flauzinho (2010). *Redes Neurais Artificiais para engenharia e ciências aplicadas*, Artliber 2010. 20, 21, 22, 23
- [34] Página na internet acessada no dia 20 de junho de 2012: <http://it.wikipedia.org/wiki/Portale:Neuroscienze>. 24
- [35] L. B. Felix, J. E. Moraes, A. M. F. L. Miranda de Sá (2005). Avoiding spectral leakage in objective detection of auditory steady-state evoked responses in the inferior colliculus of rat using coherence, *Journal of Neuroscience Methods*, v. 144, n. 2 (JUN), pp. 249-255. 24
- [36] B. Ross, R. Draganova and T. W. Picton (2003). Frequency specificity of 40-Hz auditory steady-state responses, *Hearing Research*, v. 186, n. 1, pp. 57-68. 25
- [37] F. S. Ranaudo (2012). *Dissertação (Mestrado) – COPPE, Universidade Federal do Rio de Janeiro*, 2012. 26, 28, 36
- [38] Página na internet acessada no dia 20 de junho de 2012: <http://it.wikipedia.org/wiki/Portale:Neuroscienze>. 27
- [39] Página na internet acessada no dia 30 de janeiro de 2014: <http://www.neuropediatria.org.br>. 27
- [40] LYNX Tecnologia eletrônica LTDA, *Instruções de uso BrainNet BNT - 36 Amplificador de Sinais Biológicos*, pp.12-13. 28
- [41] A. F. C. Infantosi, D. B. Melges, C. J. Tierra-Criollo (2006). Use of magnitude-squared coherence to identify the maximum driving response band of the somatosensory. *Braz. J. Med. Biol. Res.*, v. 39, n. 12, p. 1593 – 1603, 2006. 28
- [42] S. Haykin (2002). *Redes Neurais – Princípios e prática*. [S.1]: Bookman, 2002. 29
- [43] L. A. Aguirre (2004). *Introdução à identificação de sistemas – Técnicas lineares e não-lineares aplicadas a sistemas reais*. [S.1]: UFMG, 2004. 31
- [44] C. Viadaurre (2006). Fully online adaptive bci. *IEEE Trans. Biomed. Eng.*, v. 53, n. 6, p. 1214-1219, 2006. 33

Apêndice A – Carta de Aprovação



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DE VIÇOSA
COMITÊ DE ÉTICA EM PESQUISA COM SERES HUMANOS

Campus Universitário - Viçosa, MG - 36570-000 - Telefone: (31) 3899-1269

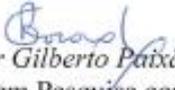
Of. Ref. Nº 051/2010/Comitê de Ética

Viçosa, 04 de junho de 2010.

Prezado Professor:

Cientificamos V.S^a. de que o Comitê de Ética em Pesquisa com Seres Humanos, em sua 4^a Reunião de 2010, realizada em 31-5-2010, analisou e aprovou, sob o aspecto ético, o projeto de pesquisa intitulado *Investigação da atenção seletiva auditiva para interface cérebro-computador*.

Atenciosamente,


Professor Gilberto Paixão Rosado
Comitê de Ética em Pesquisa com Seres Humanos
Presidente

Professor
Leonardo Bonato Félix
DEL

Apêndice B – Fluxograma do Sistema

