

**PONTIFÍCIA UNIVERSIDADE CATÓLICA DE MINAS GERAIS**  
**Programa de Pós-Graduação em Engenharia Elétrica**

**Franciele Aparecida de Souza Alves**

**ANÁLISE DE MODELOS DE REDES NEURAIS ARTIFICIAIS NO  
RECONHECIMENTO DE PADRÕES EM SINAIS DE EEG PARA  
CLASSIFICAÇÃO DA IMAGÉTICA MOTORA**

Belo Horizonte  
2017

Franciele Aparecida de Souza Alves

**ANÁLISE DE MODELOS DE REDES NEURAIIS ARTIFICIAIS NO  
RECONHECIMENTO DE PADRÕES EM SINAIS DE EEG PARA  
CLASSIFICAÇÃO DA IMAGÉTICA MOTORA**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Pontifícia Universidade Católica de Minas Gerais, como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Maury Meirelles Gouvea Junior

Belo Horizonte

2017

FICHA CATALOGRÁFICA

Elaborada pela Biblioteca da Pontifícia Universidade Católica de Minas Gerais

A474a Alves, Franciele Aparecida de Souza  
Análise de modelos de redes neurais artificiais no reconhecimento de padrões em sinais de EEG para classificação da imagética motora / Franciele Aparecida de Souza Alves. Belo Horizonte, 2016.  
86 f. : il.

Orientador: Maury Meirelles Gouvea Junior  
Dissertação (Mestrado) – Pontifícia Universidade Católica de Minas Gerais.  
Programa de Pós-Graduação em Engenharia Elétrica

1. Sistemas de reconhecimento de padrões. 2. Eletroencefalografia. 3. Redes neurais (Computação). 4. Algoritmos genéticos. 5. Processamento de imagens. I. Gouvea Junior, Maury Meirelles. II. Pontifícia Universidade Católica de Minas Gerais. Programa de Pós-Graduação em Engenharia Elétrica. III. Título.

SIB PUC MINAS

CDU: 681.3.091



**“ANÁLISE DE MODELOS DE REDES NEURAIAS ARTIFICIAIS NO  
RECONHECIMENTO DE PADRÕES EM SINAIS DE EEG PARA  
CLASSIFICAÇÃO DA IMAGÉTICA MOTORA”**

**FRANCIELE APARECIDA DE SOUZA ALVES**

Dissertação de Mestrado submetida à banca examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Pontifícia Universidade Católica de Minas Gerais, como parte dos requisitos necessários à obtenção do grau de Mestre em Engenharia Elétrica.

Aprovada em 02 de março de 2017.

Por:

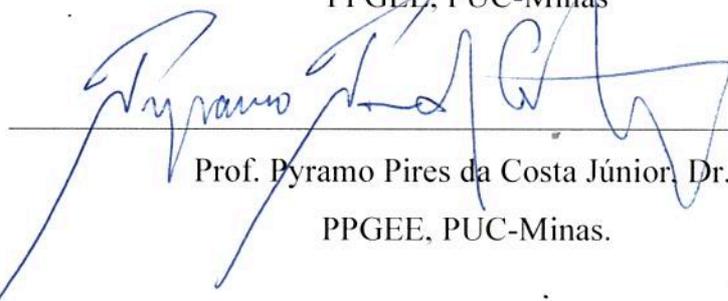


Prof. Daniel Furtado Leite, Dr., UFLA



Prof. Maury Meirelles Gouveia Júnior, Dr., - orientador

PPGEE, PUC-Minas



Prof. Pyramo Pires da Costa Júnior, Dr.,

PPGEE, PUC-Minas.

Prof.<sup>a</sup> Rose Mary de Souza Batalha, Dra.– Suplente

PUC Minas

*Dedico este mestrado aos meus pais, pelo exemplo de vida que são. A minha irmã pelo incentivo e amizade. Ao meu namorado por estar ao meu lado nos melhores e piores momentos de minha vida.*

## AGRADECIMENTOS

Inicio meus agradecimentos a Deus, por sempre me dar forças e conhecimento para atingir meus objetivos!

Ao Dr. Maury M. Gouvêa Jr. pela orientação e por sempre ter acreditado em mim e no potencial desta pesquisa.

Ao Dr. Pyramo P. da Costa Jr. pelo conhecimento passado e contribuição nesta dissertação.

Ao Programa de Pós-graduação em Engenharia Elétrica (PPGEE) por abrirem as portas para que eu pudesse realizar este sonho.

Aos demais professores, funcionários e aos colegas do PPGEE, pela gentileza e colaboração.

A meus pais, Elizabeth e Antonio, meu infinito agradecimento, pois sempre acreditaram em minha capacidade, isso só me fortaleceu a fazer o melhor de mim. Obrigada pelo amor incondicional!

A minha irmã e melhor amiga Geissiele, por todo apoio e paciência prestada, se dispondo a ajudar-me sempre que precisei. Obrigada pela força!

A meu querido namorado, Alexandre, por estar sempre a meu lado, me colocando para cima e me fazendo acreditar que posso mais que imagino. Devido a seu companheirismo, paciência e compreensão, este trabalho pôde ser concretizado.

Agradeço, também, à CAPES pela bolsa de estudos, sem ela este sonho não seria possível de ser realizado!

E a todos que contribuíram, direta ou indiretamente, nessa longa jornada. Ninguém vence sozinho... Obrigada a todos!

*“Para se ter sucesso, é necessário amar de verdade o que se faz. Caso contrário, levando em conta apenas o lado racional, você simplesmente desiste. É o que acontece com a maioria das pessoas”- Steve Jobs*

## RESUMO

O eletroencefalograma (EEG) tem sido utilizado em pesquisas sobre interface homem-máquina (IHM), que consiste de sistemas que transformam sinais cerebrais em sinais de controle de máquina. Assim, pode-se proporcionar a interação do ambiente com pacientes que sofrem de deficiências motoras. Este trabalho tem como objetivo analisar sistemas de reconhecimento de padrões em sinais de EEG, baseados em redes neurais artificiais (RNAs), para classificação de três atividades mentais: movimentos das mãos, pés e língua. O estudo pode ser aplicado em dispositivos de IHM. Três modelos de redes neurais são estudados, a saber: (i) Multilayer Perceptron (MLP); (ii) *Time-Delay* (TDNN); e (iii) sistema evolutivo. O estudo analisa cinco algoritmos de treinamento: Algoritmo Genético (AG); *Backpropagation* (BP); *Levenberg-Marquardt*; híbrido com BP e AG; e sistema evolutivo. Para a montagem da base de treinamento das RNAs, três abordagens são propostas: série temporal do sinal EEG; RMS da série temporal; e valor de pico e atraso do pico da série temporal. Nos experimentos realizados, foram treinadas e testadas várias topologias para todos os modelos de RNA, com diferentes números de neurônios na camada oculta. Os experimentos mostraram que a TDNN, que utilizou apenas a abordagem da série temporal, destacou-se dos demais modelos com 99.3% de acerto na classificação dos padrões. Em seguida, a MLP com treinamento híbrido destacou-se na abordagem pico-atraso, obtendo taxa de acerto de 98.4%. Estudos futuros podem utilizar o algoritmo híbrido com outros modelos de RNA e algoritmos de treinamento, podendo melhorar o desempenho e encontrar a topologia mais adequada para o problema de classificação.

**Palavras-chave:** Interface Cérebro Computador, Sinais Bioelétricos, Eletroencefalograma, Imagética Motora, Rede Neural Artificial, Reconhecimento de Padrões.

## ABSTRACT

Electroencephalogram (EEG) has been used in research studies on brain computer interface (BCI), which consists of systems that convert brain signals to machine control signals. Thus, these devices may improve the interaction between people with physical disabilities and their environment. This work aims to analyze pattern recognition systems in EEG signals, based on artificial neural networks (ANNs), in order to classify three mental activities: movements of the hands, feet, and tongue. The study can be applied to BCI devices. Three ANN models are studied, as follows: (i) Multilayer Perceptron (MLP); (ii) Time-Delay (TDNN); and (iii) evolving system. The study analyzes five training algorithms: Genetic Algorithm (GA); Backpropagation (BP); Levenberg-Marquardt; hybrid with BP and GA; and evolving system. Three approaches are proposed to construct the training data of ANNs: temporal series of EEG signals; RMS of the temporal series; and peak and peak delay of the temporal series. In the experiments performed, several topologies for all ANN models were trained and tested, with different number of neurons in the hidden layer. The results showed that TDNN, which used only temporal series approach, outperformed the other models with 99.3% accuracy rate for pattern classification. Next, MLP with hybrid training by using peak-delay approach with 98.4% accuracy rate. Future studies can use the hybrid algorithm with other ANN models and training algorithms, which may improve the performance and find out the most suitable topology for the classification problem.

**Keywords:** Brain Computer Interface, Bioelectrical Signals, Electroencephalogram, Motor Imagery, Artificial Neural Network, Pattern Recognition.

## LISTA DE ILUSTRAÇÕES

FIGURA 1 – Sistema Internacional 10-20 visto de: A) Esquerda B) Topo da Cabeça	27
FIGURA 2 – Onda Delta . . . . .	27
FIGURA 3 – Onda Theta . . . . .	28
FIGURA 4 – Onda Alpha . . . . .	28
FIGURA 5 – Onda Beta . . . . .	28
FIGURA 6 – Esquema BCI . . . . .	29
FIGURA 7 – Modelo Neurônio Artificial . . . . .	34
FIGURA 8 – Exemplos de Funções de Ativação . . . . .	35
FIGURA 9 – Rede Multilayer Perceptron . . . . .	36
FIGURA 10 – Modelo de Memória Associativa . . . . .	38
FIGURA 11 – Rede Neural <i>Time-Delay</i> . . . . .	39
FIGURA 12 – Arquitetura geral eMLP . . . . .	40
FIGURA 13 – Esquema do Algoritmo Genético . . . . .	43
FIGURA 14 – Fluxograma do sistema proposto . . . . .	47
FIGURA 15 – Esquema do paradigma cronometrado . . . . .	48
FIGURA 16 – Posicionamento dos Eletrodos . . . . .	49
FIGURA 17 – Esquema Pico/Atraso . . . . .	50
FIGURA 18 – Esquema do Algoritmo Híbrido utilizado neste estudo . . . . .	52
FIGURA 19 – Algoritmo Genético: EQM dos dados de treinamento das diferentes topologias para a abordagem RMS . . . . .	55
FIGURA 20 – Algoritmo Genético: Matriz de Confusão de teste do melhor caso para a abordagem RMS . . . . .	56
FIGURA 21 – Backpropagation: EQM dos dados de treinamento das diferentes topologias para a abordagem RMS . . . . .	57
FIGURA 22 – Backpropagation: Matriz de Confusão de teste do melhor caso para a abordagem RMS . . . . .	59
FIGURA 23 – <i>Levenberg-Marquardt</i> : EQM dos dados de treinamento das diferentes topologias para a abordagem RMS . . . . .	60
FIGURA 24 – <i>Levenberg-Marquardt</i> : Matriz de Confusão de teste do melhor caso para a abordagem RMS . . . . .	61
FIGURA 25 – Híbrido: EQM dos dados de treinamento das diferentes topologias para a abordagem RMS . . . . .	62
FIGURA 26 – Híbrido: Matriz de Confusão de teste do melhor caso para a abordagem RMS . . . . .	64
FIGURA 27 – Algoritmo Genético: EQM dos dados de treinamento das diferentes topologias para a abordagem Pico/Atraso . . . . .	65
FIGURA 28 – Algoritmo Genético: Matriz de Confusão de teste do melhor caso para a abordagem Pico/Atraso . . . . .	66

FIGURA 29 – Backpropagation: EQM dos dados de treinamento das diferentes topologias para a abordagem Pico/Atraso . . . . .	67
FIGURA 30 – Backpropagation: Matriz de Confusão de teste do melhor caso para a abordagem Pico/Atraso . . . . .	68
FIGURA 31 – <i>Levenberg-Marquardt</i> : EQM dos dados de treinamento das diferentes topologias para a abordagem Pico/Atraso . . . . .	69
FIGURA 32 – <i>Levenberg-Marquardt</i> : Matriz de Confusão de teste do melhor caso para a abordagem Pico/Atraso . . . . .	70
FIGURA 33 – Híbrido: EQM dos dados de treinamento das diferentes topologias para a abordagem Pico/Atraso . . . . .	71
FIGURA 34 – Híbrido: Matriz de Confusão de teste do melhor caso para a abordagem Pico/Atraso . . . . .	72
FIGURA 35 – Rede <i>Time-Delay</i> : EQM dos dados de treinamento das diferentes topologias . . . . .	74
FIGURA 36 – Rede <i>Time-Delay</i> : Matriz de Confusão de teste do melhor caso . . .	75
FIGURA 37 – Matriz de Confusão Abordagem RMS usando eMLP . . . . .	77
FIGURA 38 – Matriz de Confusão Abordagem Pico/Atraso usando eMLP . . . . .	79
FIGURA 39 – Relação da Quantidade de Neurônios X Iterações: A) Abordagem RMS B) Abordagem Pico/Atraso . . . . .	79

## LISTA DE TABELAS

TABELA 1	–	Características do principais Sinais Bioelétricos . . . . .	25
TABELA 2	–	Algoritmo Genético: Resultados do treinamento das topologias para a abordagem RMS . . . . .	55
TABELA 3	–	Algoritmo Genético: Resultados do teste das topologias para a abordagem RMS . . . . .	56
TABELA 4	–	Backpropagation: Resultados do treinamento das topologias para a abordagem RMS . . . . .	58
TABELA 5	–	Backpropagation: Resultados do teste das topologias para a abordagem RMS . . . . .	58
TABELA 6	–	<i>Levenberg-Marquardt</i> : Resultados do treinamento das topologias para a abordagem RMS . . . . .	59
TABELA 7	–	<i>Levenberg-Marquardt</i> : Resultados do teste das topologias para a abordagem RMS . . . . .	60
TABELA 8	–	Híbrido: Resultados do treinamento das topologias para a abordagem RMS . . . . .	63
TABELA 9	–	Híbrido: Resultados do teste das topologias para a abordagem RMS	63
TABELA 11	–	Algoritmo Genético: Resultados do teste das topologias para a abordagem Pico/Atraso . . . . .	65
TABELA 10	–	Algoritmo Genético: Resultados do treinamento das topologias para a abordagem Pico/Atraso . . . . .	66
TABELA 12	–	Backpropagation: Resultados do treinamento das topologias para a abordagem Pico/Atraso . . . . .	67
TABELA 13	–	Backpropagation: Resultados do teste das topologias para a abordagem Pico/Atraso . . . . .	68
TABELA 14	–	<i>Levenberg-Marquardt</i> : Resultados do treinamento das topologias para a abordagem Pico/Atraso . . . . .	69
TABELA 15	–	<i>Levenberg-Marquardt</i> : Resultados do teste das topologias para a abordagem Pico/Atraso . . . . .	70
TABELA 16	–	Híbrido: Resultados do treinamento das topologias para a abordagem Pico/Atraso . . . . .	72
TABELA 17	–	Híbrido: Resultados do teste das topologias para a abordagem Pico/Atraso . . . . .	72
TABELA 18	–	Rede <i>Time-Delay</i> : Resultados do treinamento das topologias . . . . .	73
TABELA 19	–	Rede <i>Time-Delay</i> : Resultados do teste das topologias . . . . .	74
TABELA 20	–	Classificação de Padrões dos dados de teste para a abordagem RMS	76
TABELA 21	–	Classificação de Padrões dos dados de teste para a abordagem Pico/Atraso . . . . .	77
TABELA 22	–	Resultados nos melhores casos por método . . . . .	80

## LISTA DE SIGLAS

AG	Algoritmo Genético
BCI	Brain Computer Interface
ECoS	Sistema Conexionista Evolutivo
EEG	Eletroencefalograma
eMLP	Multilayer Perceptron Evolutiva
EQM	Erro Quadrático Médio
GD	Gradiente Descendente
IM	Imagética Motora
LM	Levenberg-Marquardt
MLP	Multilayer Perceptron
RMS	Root Mean Square
RNA	Rede Neural Artificial
TDNN	Neural Network Time-Delay

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> . . . . .	<b>19</b>
<b>1.1</b>	<b>Objetivo do trabalho</b> . . . . .	<b>20</b>
1.1.1	<i>Objetivo geral</i> . . . . .	20
1.1.2	<i>Objetivo específico</i> . . . . .	20
1.1.3	<i>Justificativa</i> . . . . .	21
1.1.4	<i>Trabalhos Relacionados</i> . . . . .	21
1.1.5	<i>Estrutura da dissertação</i> . . . . .	24
<b>2</b>	<b>INTERFACE CÉREBRO MÁQUINA</b> . . . . .	<b>25</b>
<b>2.1</b>	<b>Sinais Bioelétricos</b> . . . . .	<b>25</b>
2.1.1	<i>Eletroencefalograma</i> . . . . .	26
2.1.1.1	<i>Aquisição de EEG</i> . . . . .	26
<b>2.2</b>	<b>Metodologia para Interface Cérebro Máquina</b> . . . . .	<b>28</b>
<b>2.3</b>	<b>Imagética Motora</b> . . . . .	<b>30</b>
<b>3</b>	<b>REDES NEURAIS ARTIFICIAIS</b> . . . . .	<b>33</b>
<b>3.1</b>	<b>Modelo Neurônio Artificial</b> . . . . .	<b>33</b>
3.1.1	<i>Função de Ativação</i> . . . . .	34
<b>3.2</b>	<b>Modelos de Redes Neurais</b> . . . . .	<b>36</b>
3.2.1	<i>Rede Multilayer Perceptron</i> . . . . .	36
3.2.2	<i>Memória Associativa</i> . . . . .	37
3.2.3	<i>Rede Neural Time-Delay</i> . . . . .	38
3.2.4	<i>Sistema Conexionista Evolutivo</i> . . . . .	39
3.2.4.1	<i>Multilayer Perceptron Evolutiva</i> . . . . .	40
<b>3.3</b>	<b>Algoritmos de Aprendizagem</b> . . . . .	<b>41</b>
3.3.1	<i>Backpropagation</i> . . . . .	41
3.3.1.1	<i>Levenberg-Marquardt</i> . . . . .	42
3.3.2	<i>Algoritmo Genético</i> . . . . .	43
3.3.2.1	<i>Seleção</i> . . . . .	43
3.3.2.2	<i>Recombinação</i> . . . . .	44
3.3.2.3	<i>Mutação</i> . . . . .	44
3.3.2.4	<i>Modelo de População</i> . . . . .	44
3.3.2.5	<i>Dinâmica</i> . . . . .	44
3.3.3	<i>Treinamento Evolutivo</i> . . . . .	45
<b>4</b>	<b>MODELOS DE REDES NEURAIS ARTIFICIAIS NO RE- CONHECIMENTO DE PADRÕES EM SINAIS DE EEG</b> . . . . .	<b>47</b>

4.1	Base de Dados . . . . .	47
4.1.1	<i>Abordagens para tratamento dos sinais EEG</i> . . . . .	49
4.1.2	<i>Normalização</i> . . . . .	50
4.2	Modelagem da Arquitetura . . . . .	50
4.3	Classificação dos Padrões . . . . .	51
4.4	Treinamento Híbrido . . . . .	52
5	ESTUDO EXPERIMENTAL . . . . .	53
5.1	Classificações via Rede Multilayer Perceptron . . . . .	53
5.1.1	<i>Abordagem RMS</i> . . . . .	54
5.1.1.1	<i>Treinamento com Algoritmo Genético</i> . . . . .	54
5.1.1.2	<i>Treinamento com Algoritmo Backpropagation</i> . . . . .	57
5.1.1.3	<i>Treinamento com Algoritmo Levenberg-Marquardt</i> . . . . .	59
5.1.1.4	<i>Treinamento com Algoritmo Híbrido</i> . . . . .	61
5.1.2	<i>Abordagem Pico/Atraso</i> . . . . .	64
5.1.2.1	<i>Treinamento com Algoritmo Genético</i> . . . . .	64
5.1.2.2	<i>Treinamento com Algoritmo Backpropagation</i> . . . . .	66
5.1.2.3	<i>Treinamento com Algoritmo Levenberg-Marquardt</i> . . . . .	68
5.1.2.4	<i>Treinamento com Algoritmo Híbrido</i> . . . . .	70
5.2	Classificação via Rede <i>Time-Delay</i> . . . . .	73
5.3	Classificações via Rede Multilayer Perceptron Evolutiva . . . . .	74
5.4	Análise Geral dos Resultados . . . . .	78
6	CONCLUSÃO . . . . .	81
6.1	Trabalhos futuros . . . . .	81
	REFERÊNCIAS . . . . .	83

## 1 INTRODUÇÃO

O sistema nervoso tem sido, nos dias atuais, o limiar para a interação homem-máquina. Pesquisas na área buscam transformar sinais biológicos em sinais de controle de máquina para fins específicos, como controle de braço robótico através de sinais eletromiográficos (EMG), Ferreira e Gouvêa (2016), e simulação de movimentos através de sinais EEG para pessoas portadoras de deficientes motoras. Em 1924, Hans Berger, professor alemão de psiquiatria em Viena, introduziu o conceito de EEG, conectando dois eletrodos ao couro cabeludo de um paciente e detectou uma pequena corrente elétrica. Berger afirmou que o cérebro gera uma atividade elétrica capaz de ser registrada, identificando assim as ondas alfa na faixa 8-12 Hz (BERGER, 1929). Durante os anos 1929-1938, Berger publicou 14 relatórios a cerca dos seus estudos com sinais EEG, e muito do conhecimento atual sobre este assunto, deve-se à sua pesquisa (BERGER, 1969).

Diante do aumento da compreensão do funcionamento cerebral e melhoria da tecnologia de aquisição não invasiva de sinais neurológicos, os sinais EEG tem sido o instrumento mais utilizado para estudar a organização do cérebro em processos cognitivos, como percepção e memória, além de propiciar o desenvolvimento de pesquisas de interface cérebro-computador (BCI, do inglês, *Brain Computer Interface*) (BOTTI et al., 2011). A BCI consiste em sistemas que utilizam medições da atividade cerebral, realiza a interpretação dos sinais elétricos cerebrais e promove a interação com o ambiente externo através de máquinas (WOLPAW; WOLPAW, 2012). A BCI pode proporcionar uma interação do ambiente com pacientes que sofrem de deficiências motoras, como a Esclerose Lateral Amiotrófica (ELA), mas não apresentam danos cognitivos. Assim, o usuário pode ser capaz de realizar tarefas em um computador ou outro dispositivo por meio dos sinais provenientes diretamente do cérebro. A simulação de movimentos, sem ser manifestada como movimento físico, i.e., sem que o corpo expresse tal ato, é chamada de Imagética Motora (IM) (HANAKAWA; DIMYAN; HALLETT1, 2008) e tem sido associado a pacientes com sequelas motoras quando ele simula internamente uma tarefa motora sem que ocorra o movimento de quaisquer segmentos corporais associados a esta tarefa (GENTILI; PAPAXANTHIS; POZZO, 2006).

O processamento dos sinais bioelétricos tem sido alvo de diversos estudos que buscam a melhor forma de realizá-lo. Os métodos computacionais vêm sendo aliados aos tratamentos destes sinais, dando destaque aos métodos baseados em inteligência artificial, que podem ser empregados para reconhecimento de padrões. A discussão sobre tarefas de reconhecimentos de padrões, leva ao conceito de memória. As atividades neurais formam um padrão espacial dentro da memória que contém informações sobre os estímulos (HAYKIN; NETWORK, 2004). Portanto, a memória realiza um mapeamento distribuído que transforma um padrão de atividade no espaço de entrada em outro padrão de atividade no espaço de saída. O reconhecimento de padrões pode ser tratado como uma tarefa da memória associativa, pois permite o endereçamento e a recordação de padrões armazenados em resposta a

um estímulo de entrada (HAYKIN; NETWORK, 2004; SPECKMANN; ELGER; GORJI, 1999). Além disso, a memória associativa pode ser capaz de recuperar corretamente uma saída mesmo após a apresentação de uma entrada incompleta ou ruidosa.

Neste trabalho, desenvolveu-se um sistema para reconhecimento de padrões em sinais de EEG, baseado em redes neurais artificiais para classificação da imagética motora que correspondam a três atividades mentais distintas: movimentos imaginário das mãos, pés e língua, para aplicação em dispositivos e controles externos de interfaces cérebro-máquina. Três modelos são estudados: (i) Rede Neural Multilayer Perceptron (FAUSETT, 1994), (ii) Rede Neural *Time-Delay* (LANG; WAIBEL; HINTON, 1990) e (iii) Rede Multilayer Perceptron Evolutiva (KASABOV, 1998). Cinco métodos de treinamento são utilizados para ajustes dos pesos sinápticos: (i) Algoritmo Genético, (ii) *Backpropagation*, (iii) *Levenberg-Marquardt*, (iv) Híbrido e (v) Treinamento para Sistemas Evolutivos.

## 1.1 Objetivo do trabalho

### 1.1.1 Objetivo geral

Este trabalho tem como objetivo elaborar um sistema de reconhecimento de padrões de EEG para classificação de sinais cerebrais obtidos através do conjunto de dados de Graz (NAEEM, 2006) e avaliar o desempenho do modelo proposto em relação aos três modelos de redes neurais artificiais e cinco algoritmos de treinamento.

### 1.1.2 Objetivo específico

Como objetivos específicos têm-se:

1. realizar o levantamento bibliográfico sobre eletroencefalograma e classificação de padrões em imagética motora;
2. estudar modelos de redes neurais artificiais e métodos de treinamento para classificação dos sinais EEG;
3. implementar diferentes abordagens de representação do sinal EMG;
4. utilizar do conceito de memória associativa para estudo dos métodos utilizados;
5. avaliar o desempenho das redes neurais artificiais utilizadas e dos algoritmos de treinamento pelo melhor resultado na classificação dos padrões em sinais de EEG para a tarefa proposta;
6. publicar os resultados do estudo proposto em congressos e periódicos da área.

### 1.1.3 *Justificativa*

A captura de sinais de EEG pode melhorar a inclusão social e aumentar a interação entre pessoas portadoras de deficiências motoras com o ambiente que as cerca. Assim, os sinais cerebrais são utilizados como possível solução para gerar sinais de controle de dispositivos externos, como braços robóticos.

Os sinais bioelétricos, assim como o EEG, após passarem pelo processo de extração de características, são processados através de um sistema de classificação com redes neurais artificiais (HAYKIN; NETWORK, 2004). As redes neurais artificiais têm sido utilizadas em diversos sistemas graças à sua flexibilidade, podendo aprender a partir de exemplos, se adaptar ao diversos tipos de entrada, e ainda ter a capacidade de generalização. Suas aplicações encontram-se em diversas áreas, como reconhecimento de caracteres ou previsão de séries temporais e análise de imagens médicas com sistemas de diagnóstico (FAUSETT, 1994). A topologia escolhida ao modelar a rede neural artificial e o algoritmo de aprendizagem é crítico, pois determina o desempenho da solução: por isso, deve ser realizado um estudo experimental dos modelos a serem utilizados a fim de obter a maior taxa de acerto no reconhecimento de padrões.

A vantagem de usar e comparar modelos de rede neural artificial e métodos de treinamento para realizar a classificação de padrões é poder construir fronteiras de decisões não lineares entre as diferentes classes e oferecer um método prático para resolver problemas altamente complexos de classificação de padrões (HAYKIN; NETWORK, 2004).

### 1.1.4 *Trabalhos Relacionados*

Os principais trabalhos relacionados foram obtidos da literatura embasados no reconhecimento de padrões em sinais de eletroencefalograma para classificação da imagética motora.

Xu (2008) apresenta um novo método de extração de características para reconhecimento de padrões da imagética motora da mão esquerda e da mão direita, dados obtidos pelo conjunto de dados Graz para a Competição BCI de 2003. A extração é feita utilizando a combinação da transformada wavelet discreta (DWT) e modelo auto-regressivo (AR), onde o valor do processo é expresso com um agregado linear dos valores anteriores, apropriados para descrever séries temporais estacionárias, isto é, séries que se desenvolvem no tempo ao redor de uma média constante. A grande contribuição deste trabalho e trabalhar com o sinal como uma série temporal completa, onde após os testes os resultados são satisfatórios obtendo uma taxa de erro abaixo de 10,0% e taxa de reconhecimento de 92,1%. As técnicas de classificação de padrões, conforme descrito neste trabalho tornam possíveis o desenvolvimento de um sistema de análise de sinais da imagética motora EEG totalmente automatizado, online e que é preciso para usar em um BCI.

Medeiros (2009) propõe um método para controlar uma interface não-invasiva,

baseada em EEG, de três classes da imagética motora: imaginação de movimento da mão esquerda, imaginação de movimento da mão direita e operação matemática de soma. O método proposto consiste em utilizar Rede Neural Artificial para distinguir entre os três padrões de EEG relacionados com as tarefas. Para aquisição do sinal eletroencefalográfico foi utilizado um aparelho de EEG (BrainNet BNT- 36) de 22 canais, com uma frequência de amostragem de 400 Hz e um filtro notch em 60 Hz. Os eletrodos foram posicionados no escalpo de dois voluntários saudáveis, de acordo com o padrão 10/20. Os sujeitos realizaram 3 sessões, onde em cada sessão, tarefas mentais eram apresentadas aleatoriamente. Após extrair as características do sinal, o próximo passo foi utilizá-las para treinar um classificador baseado em redes neurais artificiais do tipo MultiLayer Perceptron (MLP). Foram escolhidas, arbitrariamente, dois tipos de arquitetura para a rede: com uma camada oculta (80 neurônios) e duas camadas ocultas (50 na primeira e 30 na segunda). Essas redes foram utilizadas para gerar dois tipos de classificadores: ternários (todas as tarefas) e binário (par de tarefas). Todas as redes foram treinadas com uma taxa de aprendizado de 0.01. Em geral, os classificadores ternários obtiveram dificuldade em distinguir as tarefas, especialmente para as tarefas de imagética motora relacionadas com movimentos das mãos. Em ambos os casos, as taxas de acerto médio foram superiores a 60%. Entretanto, ao analisar as matrizes de confusão, é possível observar uma maior taxa de acerto para a tarefa de soma algébrica, enquanto que as tarefas de imagética motora apresentam uma alta taxa de colisão entre si. Apesar de funcionar no modo off-line, o trabalho é inédito, por utilizar RNAs para classificar padrões derivados da imagética motora. Como trabalhos futuros, é proposto ampliar a quantidade de sujeitos para obter uma maior generalização dos resultados obtidos.

Hsu (2012) propõe um sistema de análise de eletroencefalograma (EEG) para a classificação de dados imagética motora da mão direita e esquerda do conjunto de dados de Graz utilizando-se Rede Neural Fuzzy Hopfield (FHNN). A FHNN é a combinação da Rede Hopfield, modelos de redes neurais auto-associativas desenvolvidas por J. Hopfield em 1982, e Fuzzy C-means, método de agrupamento frequentemente usado no reconhecimento de padrões, que permite que um pedaço de dados pertença a dois ou mais conjuntos, desenvolvido por Dunn em 1973 e melhorado por Bezdek em 1981 ). Para comprovar a efetividade do sistema, o autor utiliza outros classificadores como métricas de comparação, a saber: (i) Multilayer Perceptron (MLP) e (ii) Máquina de Vetor Suporte (SVM), método que toma como entrada um conjunto de dados e prediz, para cada entrada dada, qual de duas possíveis classes a entrada faz parte. A grande contribuição deste trabalho é combinar dois métodos, resultando em um classificador não supervisionados promissor. O FHNN obteve a segunda maior taxa de reconhecimento (82,9%), apenas um pouco a menos (0,7%) do que a do SVM, que por sua vez obteve a maior taxa de reconhecimento (83,6%). A MLP, em comparação com os demais métodos rendeu a pior taxa de reconhecimento da média (79,6%), sendo a diferença de 4,0% pra SVM.

Kottaimalai (2013) realiza a classificação de cinco tarefas cognitivas retirados da

base de dados da Universidade de Colorado. Para o processo de classificação, foram utilizados dois métodos diferentes a fim de avaliar o melhor desempenho, a saber: (i) MLP e (ii) Análise de Componente Principal (PCA) combinada com MLP, que 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. Ambos métodos foram treinados com os mesmos parâmetros por 1000 épocas. Com os resultados conclui-se que a porcentagem de dados corretamente classificados é melhor em Análise de Componentes Principais com MLP comparados a Multilayer Perceptron. A pesquisa permite verificar a eficiência da combinação de métodos de reconhecimento de padrões para a classificação de tarefas cognitivas.

Marilú (2014) propõe o desenvolvimento uma Rede Neural Dinâmica para identificação dos padrões de imaginação do movimento das mãos, por meio da análise de EEG para futura aplicação em um BCI. A aquisição do sinal de EEG foi realizada por meio do equipamento VERTEX SC823 da Meditron, composto pelo hardware EEG COMPACT 723 e software SOMNIUM. A captura dos sinais foi realizada em 10 indivíduos saudáveis do sexo masculino e destros, na faixa etária de 18 a 40 anos, que não possuíam qualquer problema neurológico aparente e que não faziam uso de medicação que pudesse provocar alterações no sinal de EEG. A primeira etapa de pré-processamento realizada nos sinais de EEG adquiridos neste trabalho foi determinada pela extração de características utilizando a Transformada Wavelet Discreta (DWT), decompondo o sinal em suas aproximações e detalhes, e eliminando as componentes indesejadas. Foram desenvolvidas duas RNAs, uma RNA estática (RNAE) e uma RNA dinâmica (RNAD), para o auxílio na identificação da imagética motora por meio da análise do registro de EEG. Em ambas redes o reconhecimento foi realizado de forma dinâmica, simulando um processamento online e utilizando o algoritmo de treinamento supervisionado Backpropagation. Utilizando a RNAE obteve-se uma eficiência de 49% na classificação dos eventos e com a utilização da RNAD obteve-se 72%. As ferramentas utilizadas são promissoras, podendo ser facilmente aplicadas na detecção de padrões da imagética motora, tornando viável sua utilização em uma BCI em tempo real.

Li (2015) aplica Rede Neural Backpropagation Integrada (IBPNN) à pesquisa de reconhecimento de padrões de imagética motora EEG (imaginando o movimento da mão esquerda, imaginando o movimento da mão direita e imaginando nenhum movimento) a fim de resolver problemas existentes da baixa taxa de reconhecimento e pobre desempenho em tempo real. A IBPNN é composta de múltiplas Redes Backpropagation individuais, e essas sub-redes não estão conectadas entre si. Os experimentos foram comparados a Rede Backpropagation, onde a característica de computação paralela da IBPNN não só melhorou a capacidade de generalização de rede, mas também encurtou o tempo de operação. Os resultados experimentais mostraram que a IBPNN foi mais competente em reconhecer sinais de EEG. A taxa de reconhecimento da IBPNN foi de 97%, enquanto a outra rede

obteve 93%. Portanto, IBPNN é mais competente em reconhecer sinais de EEG de motores imaginários e sua generalização pode melhorar a capacidade da rede, de modo a melhorar a aumentar a precisão do reconhecimento de padrões

Através do estudo dos trabalhos relacionados observa-se que existem diversas técnicas para reconhecimento de padrões em sinais de eletroencefalograma, durante a imagética motora, presentes na literatura. A principal limitação encontrada na literatura é o estudo de diferentes abordagens para trabalhar com o sinal EEG. Este trabalho visa desenvolver um sistema para reconhecimento de padrões em sinais de eletroencefalograma, baseando-se no estudo de redes neurais artificiais, para classificação da imagética motora que correspondam a três atividades mentais distintas utilizando três abordagens diferentes durante os estudos: série temporal, RMS e Pico/Atraso.

#### *1.1.5 Estrutura da dissertação*

Esta dissertação está estruturada em 6 capítulos. Este primeiro capítulo, além de apresentar o contexto da pesquisa, os objetivos da proposta, apresenta também o cenário que justifica este estudo e os trabalhos relacionados. No Capítulo 2 é apresentado uma breve descrição sobre sinais bioelétricos, dando destaque ao eletroencefalograma. No capítulo 3 são apresentados os principais conceitos de rede neural artificial e algoritmos de aprendizagem, assim como os mesmos podem ser utilizados para resolver problemas de classificação de padrões. No capítulo 4 é apresentada a metodologia para o desenvolvimento do sistema de reconhecimento de sinais EEG para classificação da imagética motora. No capítulo 5 são apresentados os estudos experimentais de cada etapa da pesquisa, assim como a análise dos resultados. No capítulo 6 são apresentadas as conclusões gerais e as propostas de trabalhos futuros.

## 2 INTERFACE CÉREBRO MÁQUINA

Neste capítulo é feita uma revisão sobre os conceitos para compreensão de uma Interface Cérebro Máquina. Inicialmente são descritos os sinais bioelétricos, dando ênfase ao eletroencefalograma. A seguir é apresentada a metodologia de uma Interface Cérebro Máquina. Por fim, é apresentado o conceito de imagética motora utilizada na tarefa de reconhecimento de padrões deste trabalho.

### 2.1 Sinais Bioelétricos

Sinais bioelétricos, também conhecidos como biosinais, são sinais que podem ser monitorados a partir de seres biológicos gerados por suas células nervosas e musculares. A aquisição de destes sinais normalmente são leituras nas variações de correntes elétricas produzidas por um tecido especializado, órgão ou sistema (TEPLAN, 2002; IVES, 1989). Os sinais bioelétricos podem ser classificados de acordo com suas características de aquisição e transmissão, entre as formas mais comuns e que utilizam eletrodos de superfície destacam-se as da Tabela 1:

**Tabela 1 – Características do principais Sinais Bioelétricos**

Classificação	Faixa de Frequência (Hz)	Faixa de Amplitude (mV)
Eletrooculograma	0 - 100	10 - 5
Eletroencefalograma	0,5 - 100	2 - 100
Eletromiograma	2 - 500	50- 5
Eletrocardiograma	0,05 - 100	1 - 10

**Fonte: teplan**

1. Eletrooculograma: é a medição do potencial existente entre a córnea e a retina através do uso de dois eletrodos em volta do olho e mais um para o sinal de referência (terra), está associada ao movimento do olho.
2. Eletroencefalograma: alvo do estudo deste presente trabalho, esta técnica usa eletrodos em contato com o couro cabeludo a fim de perceber a atividade elétrica de regiões do cérebro. Ele vem sendo utilizado para estudar a organização do cérebro em processos cognitivos, como: percepção, memória, atenção, linguagens, etc
3. Eletromiograma: é a representação da corrente elétrica gerada na membrana das fibras musculares, associada a contração do músculo, que se propaga pelos tecidos até chegar aos eletrodos de superfície ou em agulhas que penetram o músculo

4. Eletrocardiograma: é o registro gráfico das atividades elétricas do coração por meio dos eletrodos posicionados no corpo do sujeito

### 2.1.1 Eletroencefalograma

O eletroencefalograma é o estudo do registro gráfico da atividade cerebral coletiva dos neurônios. Desde que foi proposta por Hans Berger (1929), o sinal obtido desta técnica tem sido amplamente adotado na investigação e diagnóstico de fenômenos neurológicos. O EEG ocupa uma banda em frequência de 0 a 100 Hz, com uma concentração de energia do sinal entre 0,5 e 60 Hz. O processamento destes sinais é dado em três etapas: (i) o pré-processamento com a filtragem, retificação e ampliação do sinal, (ii) a extração das características do sinal e (iii) o processamento do sinal (MCFARLAND, 1995; ZHANG; ZHANG; GE, 2004). Apesar do objetivo principal ser a classificação, as duas primeiras etapas são essenciais e muitas vezes decisórias no processamento do sinal. Um método de extração ou seleção de características escolhe as características do padrão que serão utilizadas pelo classificador. O pré-processamento prepara os dados para melhorar o processo de extração ou seleção das características que melhor representam os dados (WANG; DENG; HE, 2004).

#### 2.1.1.1 Aquisição de EEG

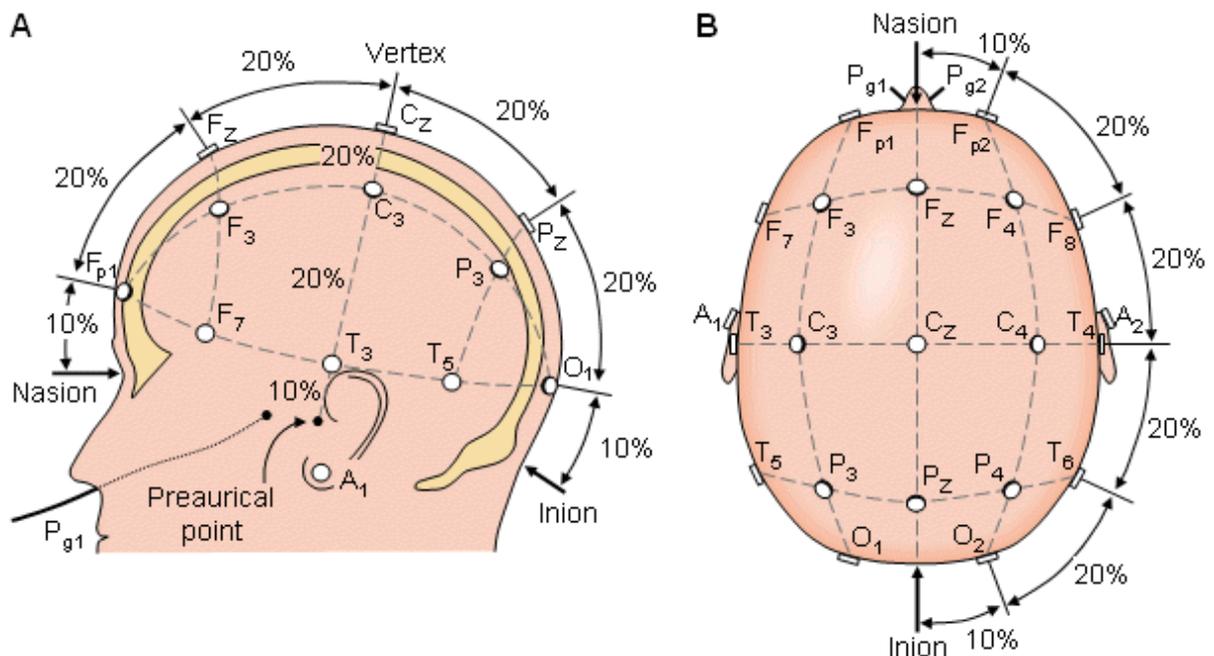
A atividade elétrica cerebral pode ser obtido através de três formas: com a introdução de eletrodos no interior do tecido cerebral (Registro de Profundidade); através do posicionamento dos eletrodos diretamente na superfície exposta do córtex cerebral (Eletrocorticograma - ECOG), ou de maneira não invasiva na superfície do couro cabeludo (o Eletroencefalograma - EEG), método mais utilizado por não ser invasivo e apresentar baixo custo em relação aos demais (PENNY et al., 2000; COIMBRA, 1994).

Jasper e Carmichael (1935) foram os responsáveis por publicar a primeira verificação de eletroencefalograma desenvolvida do Berger, utilizando eletrodos de prata em um paciente com quadro convulsivo. Comprovou, assim, que patologias cerebrais alteram o EEG. Posteriormente, Jasper propôs em 1958 o sistema de colocação de eletrodos utilizado internacionalmente, o Sistema 10-20. Neste sistema, 21 eletrodos são determinados por pontos de referências, chamados marcos anatômicos, que são: (i) nasion, que corresponde a pequena depressão anatômica no topo do nariz, alinhada com os olhos e (ii)inion, que corresponde a pequena proeminência ossea que existe na base do crânio, na linha mediana da nuca. Determinado estes pontos, os perímetros cranianos são medidos nos planos transversal e medial, onde as posições dos eletrodos estão a intervalo de 10% e 20% deste perímetros (ZANGEROLAME, 2009). Os demais eletrodos são colocados em cada lateral igualmente distante dos pontos vizinhos conforme observado na Figura 1.B.

A Figura 1 ilustra o posicionamento dos eletrodos e as letras indicam as posições:

parietal (P), frontal (F), temporal (T), central ( C ), occipital (O). Os eletrodos com numero par referem-se ao lado direito e os com numero impar, lado esquerdo. Na região central do escalpo, os eletrodos recebem a letra z.

**Figura 1 – Sistema Internacional 10-20 visto de: A) Esquerda B) Topo da Cabeça**



Fonte: fernanda

A voltagem registrada no EEG determina a amplitude da onda e uma escala é necessária para traçar sua interpretação. A frequência de ondas cerebrais (ciclos/seg = Hz) (M.VENTOURAS et al., 2005) é classificada em:

1. Delta - Ondas lentas, geralmente de grande amplitude conforme Figura 2 . É um ritmo comum em crianças pequenas, recém-nascidos, e encontrado durante o sono.

**Figura 2 – Onda Delta**



Fonte: Ventouras

2. Theta - Ondas na frequência de 4,0 a 7,7Hz como observado na Figura 3 , comum em crianças, adultos em estado de sonolência e sono, ou aparecendo ocasionalmente, em

surtos de curta duração como. Na região frontal, o ritmo teta pode aparecer durante atividade mental (ex: cálculos matemáticos). Quando assimétrica ou constante, a atividade Teta pode sugerir disfunção em determinada área cerebral.

**Figura 3 – Onda Theta**



Fonte: Ventouras

3. Alpha - Ondas de 8-13 Hz, amplitude média de 50mV, predominantes na região posterior do cérebro, durante o repouso, com olhos fechados. Alpha é o ritmo típico do repouso, com olhos fechados, durante a vigília. Nos estados de sonolência, este ritmo tende a desaparecer, e apenas curtos surtos de ritmo alfa são observados a intervalos cada vez maiores. A característica dessa onda pode ser observada na Figura 4.

**Figura 4 – Onda Alpha**



Fonte: Ventouras

4. Beta - Ondas com frequência maior que 13 ciclo/seg, conforme Figura 5 . Adultos em vigília apresentam atividade beta principalmente nas regiões anteriores do cérebro.

**Figura 5 – Onda Beta**



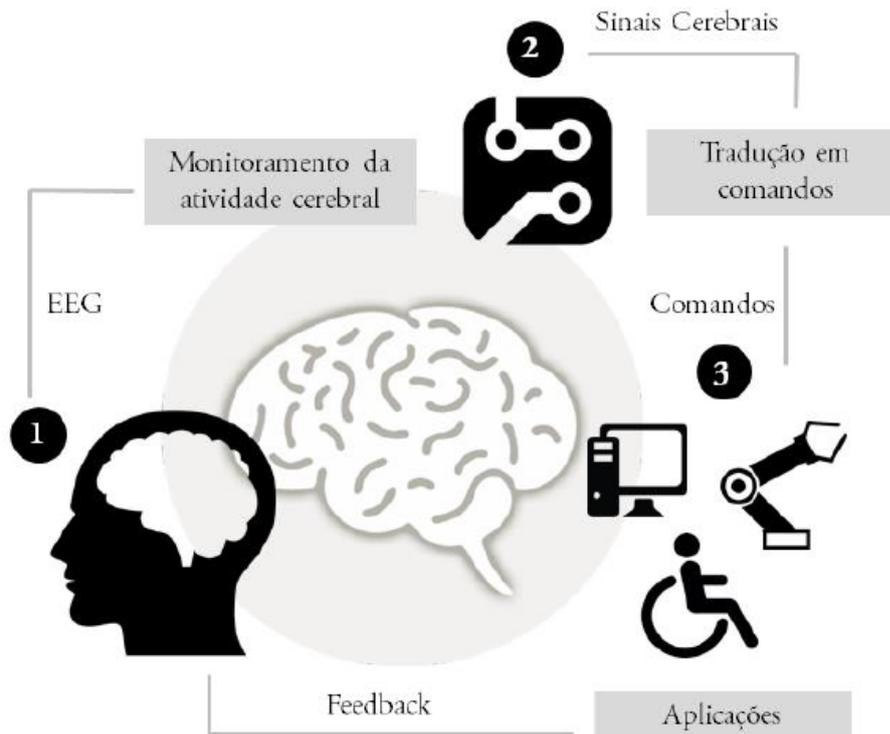
Fonte: Ventouras

## 2.2 Metodologia para Interface Cérebro Máquina

A Interface Cérebro-Máquina (BCI, do inglês *Brain Computer Interface*, é um sistema que utiliza medições da atividade neural gerada pelo cérebro e as converte em saídas artificiais que substitui, restaura, aprimora, complementa e melhora as saídas naturais do

Sistema Nervoso Central (SNC), alterando assim as interações entre o SNC e seu ambiente interno ou externo (WOLPAW; WOLPAW, 2012). O objetivo da BCI é reconhecer padrões da atividade cerebral classificando e traduzindo-os em comandos que serão executados pelas aplicações conforme mostra a Figura 6.

**Figura 6 – Esquema BCI**



**Fonte: Elaborada pela autora**

O primeiro BCI foi descrito por Dr. Grey Walter, em 1964, onde ele conectou eletrodos diretamente às áreas motoras do cérebro de um paciente e o orientou a pressionar um botão para avançar um projetor de slides enquanto sua atividade cerebral relativa à tarefa era gravada. Em seguida, esse sistema de eletrodos foi ligado ao projetor para que este avançasse os slides sempre que a atividade cerebral do paciente indicasse que ele queria pressionar o botão (GRAIMANN; ALLISON, 2010).

Para que um sistema seja considerado como um BCI existem algumas regras, a saber:

1. a atividade deve ser gravada diretamente do cérebro;
2. deve ser fornecido um retorno para o usuário, sendo este feito *online*;
3. é imprescindível que haja um controle intencional, i.e., o usuário deve escolher mentalmente. Desse modo, diante de tais regras, é possível afirmar que os dispositivos que apenas passivamente detectam mudanças na atividade cerebral que ocorrem sem

qualquer intenção, como a atividade EEG associada à carga de trabalho, excitação ou sono, não são BCI.

Um sistema BCI pode ser denotado como (i) síncrono, onde estados mentais são produzidos por estímulos externos, ou (ii) assíncrono, ritmado por estímulos internos que o usuário é livre para controlar os estados mentais e pensamentos, como, por exemplo, a imagética motora (PFURTSCHHELLER et al., 1997).

### 2.3 Imagética Motora

A imagética motora (IM) é definida como um processo mental dinâmico no qual um indivíduo simula uma tarefa motora sem que ocorra o movimento de quaisquer segmentos corporais associados a esta tarefa (DECETY; INGVAR, 1990; MUNZERTA; LOREYA; ZENTGRAFA, 2009). A IM possui relatos de estudos desde 1883, tendo como autor pioneiro Galton. Em seu trabalho, demonstrou estudos sobre o fenômeno conhecido por Imagética Mental, conceituada como representação mental de um estímulo, relativa à percepção, relacionada à esquematização de uma tarefa, seja ela motora, auditiva, visual, etc, sem que para isto o estímulo esteja presente. Galton utilizou questionários que mensuravam a clareza dos quadros mentais gerados (GALTON, 1883).

O processo de imagética motora consiste em processar a informação sobre um ato motor da memória de longo termo para a memória de trabalho ou de curto prazo. Embora as imagens possam se referir a qualquer um dos sentidos, as imagens dinâmicas dos atos motores consistem tipicamente de informação cenestésica<sup>1</sup> ou visual.

Durante experimentos com imagética motora pode ser solicitado ao sujeito para imaginar o movimento do pé, das mãos ou da língua, por exemplo, ou pode-se tentar obter a imagética de forma implícita como, por exemplo, perguntando qual seria a melhor forma de segurar um objeto, onde se espera que o indivíduo se imagine executando o movimento no processo (MUNZERTA; LOREYA; ZENTGRAFA, 2009). Hesslow (2002) afirma que, para o cérebro, a imagética motora consiste de três premissas fundamentais:

1. imaginação de ações: ativa as estruturas motoras do cérebro de tal forma que elas remetam à atividade que ocorre durante uma ação normal de movimento, entretanto, sem nenhum movimento evidente;
2. imaginação de percepção: a imaginação de estar percebendo uma atividade é o mesmo que realmente está percebendo algo. Em sua essência a atividade de percepção é gerada pelo próprio cérebro em depreciação de estímulos externos;
3. antecipação: uma ação simulada pode provocar a atividade perceptiva que remete àquela que deveria ter acontecido, se a ação fosse executada de fato.

---

<sup>1</sup>adjetivo relacionado a designação genérica para as impressões sensoriais internas do organismo, que formam a base das sensações

Diversos trabalhos utilizam apenas a imagética motora para gerar padrões distintos de EEG (LI et al., 2015). Nesses casos, o mais comum é usar a imaginação do movimento das mãos (MARILU, 2014), o que se justifica pelo fato de que a posição da região do córtex motor que controla o movimento das mãos é localizada mais lateralmente no hemisfério cerebral (HSU, 2012). Essa posição mais lateral permite uma maior resolução espacial para diferenciar a atividade das mãos direita e esquerda(XU; SONG, 2008). Existem trabalhos que usam, além das mãos, a imagética motora dos pés e até da língua . Por fim, ainda há aqueles trabalhos que utilizam outras tarefas mentais não motoras para gerar padrões de onda diferenciáveis pelo EEG, como por exemplo, tarefas matemáticas (MEDEIROS et al., 2009), de linguagem, até mesmo musicais( LOTTE et al., 2007; KOTTAIMALAI, 2013).



### 3 REDES NEURAIS ARTIFICIAIS

Redes Neurais Artificiais (RNAs) são sistemas de processamento de informação que apresenta certas características das redes neurais biológicas. Composta de métodos matemáticos e algoritmos computacionais, as RNAs simulam o processamento de informação e criam modelos artificiais no cérebro humano, baseando-se nos seguintes princípios (ALVES; NEUMANN; GOUEVA, 2014; HAYKIN; NETWORK, 2004):

1. o processamento de informações ocorre em vários elementos simples chamados de neurônios;
2. os sinais são transferidos entre os neurônios por conexões entre eles;
3. cada conexão tem um peso associado, o qual, em uma rede neural típica, é multiplicado pelo sinal transmitido;
4. cada neurônio aplica uma função de transferência (normalmente não-linear) à soma das entradas ponderadas para determinar uma saída.

Uma rede neural artificial é caracterizada pelo padrão de suas conexões (arquitetura da rede), método que determina os pesos da conexão (treinamento/aprendizagem) e a função de ativação dos neurônios, que são tratados a seguir.

A classificação de padrões é uma das tarefas mais comuns para aplicar uma RNA, onde cada vetor de entrada (padrão a ser classificado) pertence, ou não, a uma classe dada pelo problema. Por exemplo, em um problema de classificação de dois padrões, se pertencente à classe, a saída da rede neural fornecerá um valor igual a 1; se não pertencer, o valor de saída será igual a 0 (ou  $-1$ , no caso de uma função bipolar de ativação dos neurônios) (FAUSETT, 1994).

#### 3.1 Modelo Neurônio Artificial

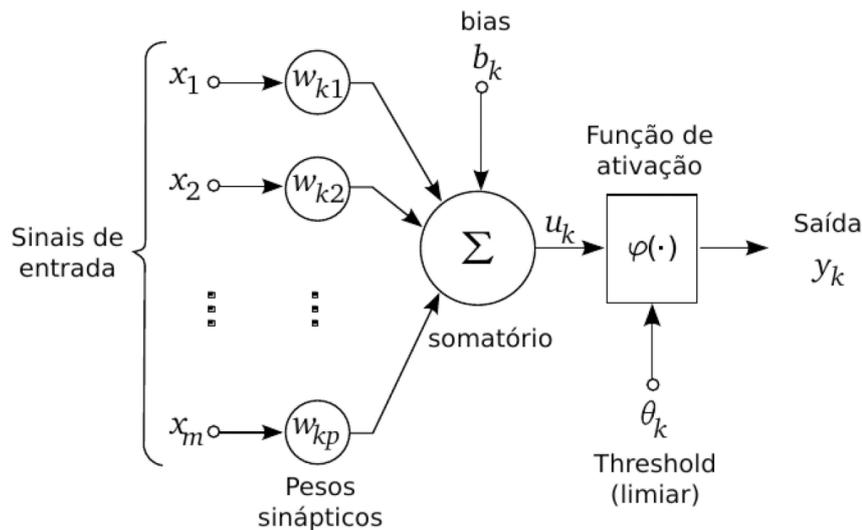
O Neurônio Artificial surgiu em 1943, quando Warren McCulloch e Walter Pitts (MCCULLOCH; PITTS, 1943) propuseram um primeiro modelo matemático para um neurônio biológico.

Um neurônio é uma unidade de processamento de informações que é fundamental para a operação de uma rede neural. O modelo do neurônio artificial possui os seguintes componentes principais um conjunto de sinapses ou conexões de entrada, sendo cada entrada ponderada por um peso sináptico; uma junção de soma, responsável pela combinação aditiva das entradas ponderadas pelos pesos sinápticos; uma função de ativação, geralmente não-linear, responsável pela ativação da saída ou resposta do elemento processador (FAUSETT, 1994; HAYKIN; NETWORK, 2004).

A Figura 7 apresenta o modelo do  $k$ -ésimo neurônio de uma RNA que recebe diversas entradas  $x_i, i = 1, \dots, p$  e cada uma das entradas é ponderada por um peso  $w_{kp}$ .

O sinal de cada entrada é multiplicado pelo peso sináptico correspondente, assim após o cálculo de todas as conexões, todos os sinais são somados e este valor é passado para função de ativação. Através da função de ativação, o neurônio decidirá o que fazer com o resultado da soma ponderada das entrada (ativar ou não) . O  $b_k$  refere-se a um bias, termo constante para correções, fazendo com que o neurônio da rede se adapte melhor ao conjunto de entradas e saídas.

**Figura 7 – Modelo Neurônio Artificial**



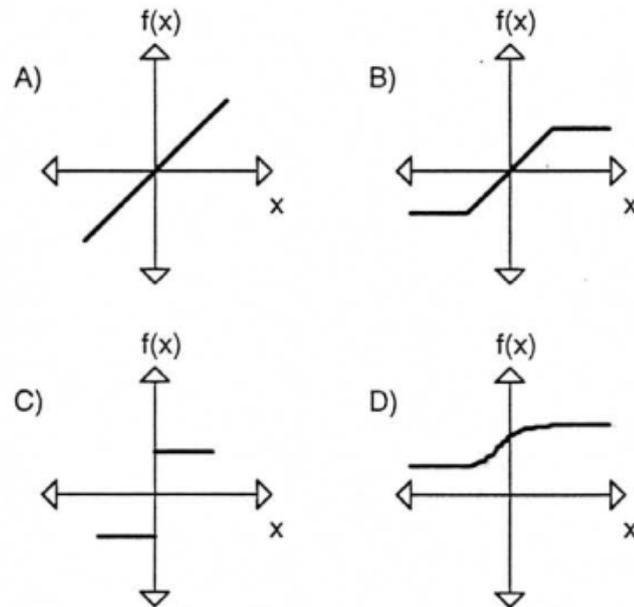
Fonte: haykin

### 3.1.1 Função de Ativação

A função básica do neurônio artificial, ou elemento processador, é realizar o somatório, ponderado por fatores denominados pesos sinápticos, dos elementos do vetor de entrada e aplicar este resultado como entrada de uma função não linear denominada função de ativação (HASSOUN, 1995).

Para o cálculo da função de ativação é necessário uma regra que calcule o valor de ativação no instante  $t$ . Quatro modelos de função de ativação são comumente utilizados na literatura, conforme observado na Figura 8 :

Figura 8 – Exemplos de Funções de Ativação



Fonte: Hassoun

1. Função linear: possui como equação:  $f(x) = \alpha x$ , onde  $\alpha$  é uma constante real que regula a intensidade da atividade  $x$ .
2. Função limiar rampa: é uma função limiar limitada pelo intervalo  $[-y, +y]$ , onde  $y$  indica os valores de saída máximo e mínimo, definido pelas seguintes equações

$$f(x) = \begin{cases} +y & \text{se } x \geq y \\ x & \text{se } |x| \leq y \\ -y & \text{se } x \leq -y \end{cases}$$

3. Função sinal: responde ao sinal de entrada emitindo valor  $+1$  se o somatório for positivo e  $0$  ou  $-1$  nos demais casos.
4. Função sigmóide: função de ativação mais utilizada em redes neurais artificiais. Definida como uma função monotônica crescente e sua resposta é gradual e não-linear. Um exemplo de função sigmoide é a função logística definida pela Equação 1:

$$f(x) = \frac{1}{1 + e^{-\alpha x}} \quad (1)$$

onde  $\alpha$  é o parâmetro de inclinação da função, definido neste trabalho pela constante  $0,5$ .

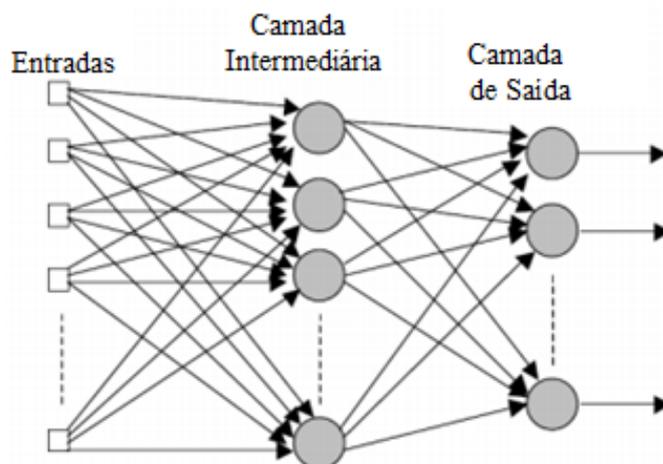
### 3.2 Modelos de Redes Neurais

A arquitetura de uma rede neural artificial define como os neurônios estão estruturados e conectados uns aos outros. Existem diversos modelos de redes neurais, sendo assim a escolha da topologia mais adequada depende do problema a ser resolvido. Dentre estes modelos, foram selecionados três que serão utilizados em estudos experimentais neste trabalho, a saber: (i) Rede Neural Multilayer Perceptron (FAUSETT, 1994), (ii) Rede Neural *Time-Delay* (LANG; WAIBEL; HINTON, 1990) e (iii) Rede Multilayer Perceptron Evolutiva (KASABOV, 1998). A seguir serão apresentados com mais detalhes os modelos acima citados e adotados neste estudo.

#### 3.2.1 Rede Multilayer Perceptron

Uma Rede Multilayer Perceptron (MLP) é composta por neurônios conectados por ligações ponderadas e estão dispostos em camadas de entrada, que fornece os respectivos elementos do padrão de ativação (vetor de entrada); camada intermediária e de saída, conforme Figura 9. A rede neural possui pesos sinápticos, uma junção de somatórios e uma função de ativação (NARENDRA, 1996).

**Figura 9 – Rede Multilayer Perceptron**



Fonte: Adaptado de haykin

A função dos neurônios na camada intermediária é intervir entre a entrada externa e a saída da rede de uma maneira útil. Adicionando-se uma ou mais camadas intermediárias a rede torna-se capaz de extrair características de ordem elevada, ou seja, adquire uma perspectiva global apesar de sua conectividade local. A habilidade de os neurônios da camada intermediária extraírem estatísticas de ordem elevada é particularmente valiosa quando o tamanho da camada de entrada é grande (HAYKIN; NETWORK, 2004).

Um sinal de entrada  $x_i$  de um neurônio  $I$  é multiplicado pelo peso sináptico  $w_{ij}$  após o cálculo, o valor é enviado à entrada do neurônio  $J$ . Cada neurônio  $J$  realiza o somatório de todos os sinais aplicados à sua entrada, conforme Equação 2, e aplica este resultado em uma função de ativação.

$$u = \sum x_i w_{ij} \quad (2)$$

O modelo de cada neurônio ou elemento processador da rede possui uma função de ativação não-linear. A função sigmoideal atende esta exigência e é muito utilizada em redes MLP, conforme Equação 3. A função de ativação é responsável por definir o limiar de ativação do neurônio.

$$f(u) = \frac{1}{1 - e^{-ku}} \quad (3)$$

sendo a constante  $k=0,5$ . A saída  $y_i$  é igual ao valor da função de ativação em um determinado instante, dado pela Equação 4:

$$y_i = f(u) \quad (4)$$

O conjunto de sinais de saída dos neurônios da camada de saída da rede constitui a resposta global da rede para o padrão de ativação fornecido pelos nós de fonte da camada de entrada.

### 3.2.2 Memória Associativa

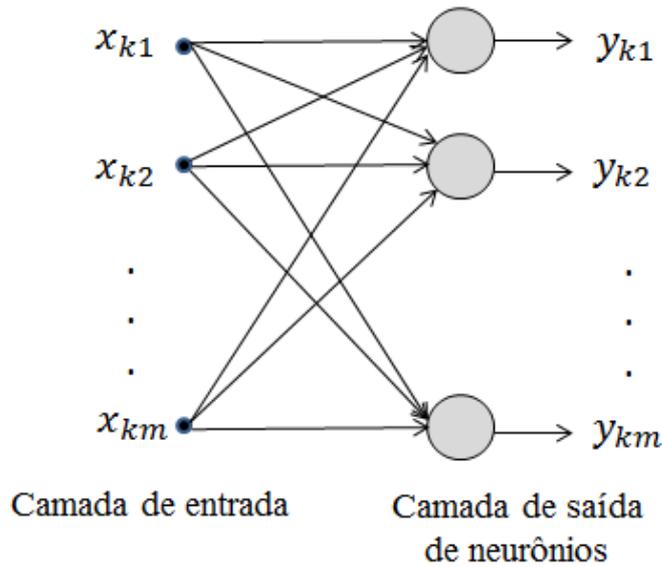
Memória associativa é o conceito utilizado para uma classe de modelos neurais inspirados na capacidade de cognição humana a fim de construir matematicamente uma possível ligação entre o modelo conexionista e o desenvolvimento de inteligência artificial (PRASAD; PESNK; SAGAR, 2010). A 10 apresenta a memória associativa correspondente para uma rede neural artificial, onde se tem a camada de entrada e uma camada de saída de neurônios.

Ainda no modelo apresentado acima,  $x_k$  representa o vetor de padrões de atividades na camada de entrada da rede e  $y_k$  o vetor de padrões de atividades na camada de saída. A associação destes vetores pode ser descrita na forma matricial pela Equação 5:

$$y_k = W(k)x_k \quad (5)$$

sendo  $k = 1, 2, \dots, q$  e  $W(k)$  e uma matriz de pesos determinada apenas pelo par de entrada-saída  $x_k, y_k$ .

Figura 10 – Modelo de Memória Associativa



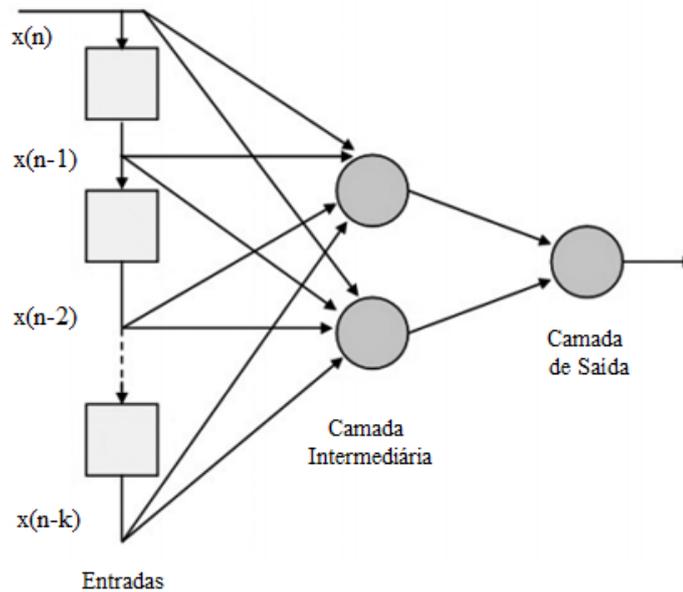
Fonte: Adaptado de haykin

### 3.2.3 Rede Neural Time-Delay

A Rede Neural *Time Delay* (do inglês TDNN, *Time Delay Neural Network*) proposta por (LANG; WAIBEL; HINTON, 1990) possui uma rede neural com arquitetura *feedforward*, com resposta no tempo  $k$  baseada nas entradas  $(k - 1)$ ,  $(k - 2)$ , ...,  $(k - n)$ . Com isso, considera-se um histórico da sequência temporal dos dados. A topologia de uma TDNN está embutida em uma rede MLP, onde cada conexão é representada por um filtro de impulso de resposta com duração finita, conhecida como FIR (*Finite Duration Impulse Response*) (ARAUJO, 2004).

Nas redes neurais convencionais, como a MLP, cada neurônio geralmente conecta-se somente uma vez com outro da camada seguinte; no modelo TDNN, são realizadas diversas conexões com pesos independentes. Antes do cálculo do peso de cada conexão, os dados sofrem um atraso que os elimina do cálculo da soma de pesos. Uma vez que cada conexão é associada a um atraso correspondente, as conexões atuam como o mecanismo de memória de curto prazo, possibilitando relatar e comparar o vetor de entrada atual aos dados observados anteriormente. As saídas de cada camada são computadas e utilizadas como valores de entrada para as camadas seguintes, até chegar à camada de saída. Os valores de saída são comparados aos valores desejados, calculando o erro que é propagado pela RNA, atualizando os pesos e, conseqüentemente, decrementando o erro global. O procedimento é repetido até a saída da RNA convergir para a saída desejada. Dessa maneira, uma predição eficiente somente é possível após o treinamento repetitivo da RNA (DODONOV; MELLO, 2008). A Figura 11 apresenta a arquitetura de uma TDNN contendo apenas uma camada oculta.

Figura 11 – Rede Neural *Time-Delay*



Fonte: Adaptado de Kevin

O treinamento da TDNN é realizado por um algoritmo muito similar ao backpropagation modificado de modo a considerar os valores passados dos sinais. Uma vez treinada a rede, todos os pesos são fixados. A rede pode, então, ser utilizada para operar um sinal de entrada de tempo real, propagando o sinal através da rede, camada por camada (BRAGA; CARVALHO; LUDERMIR, 2000).

### 3.2.4 Sistema Conexionista Evolutivo

Um sistema conexionista evolutivo (ECoS) é uma rede neural ou uma coleção de redes que opera continuamente no tempo e adapta sua estrutura e funcionalidades através de interações contínuas com o ambiente (KASABOV, 1998). Estes sistemas são inspirados no comportamento de redes neurais biológicas e na evolução dos indivíduos durante seu ciclo de vida: aprendendo a partir da experiência, herança e mudança gradual. Em termos gerais, um sistema conexionista pode ser definido como  $E, P, W, F, R, FO$ , onde:  $E$  representa sua estrutura,  $P$  seu conjunto de parâmetros,  $W$  os pesos de suas conexões,  $F$  sua função,  $R$  um método de aprendizado e  $FO$  função objetivo (LEITE; COSTA; GOMIDE, 2009).

ECoS constituem um pequeno subconjunto de todos os modelos conexionistas no contexto da inteligência computacional, e são uma maneira inovadora e alternativa de adaptar, aprender e representar conhecimento sobre ambientes em constante mudança (ANGELOV; ZHOU, 2006). Eles evoluem tanto no espaço de dados do problema, como no próprio espaço do sistema. Eles aprendem em qualquer modo de aprendizado: super-

visionado, não supervisionado, por reforço ou por uma combinação destes (KASABOV, 2003).

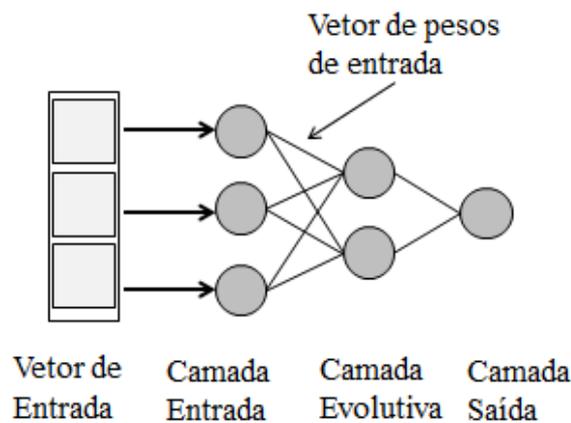
Em geral, suas principais características incluem:

1. Evoluem em domínios abertos;
2. Aprendem continuamente durante toda a sua existência;
3. Usam aprendizado construtivo e possuem estruturas evolutivas;
4. Dividem o espaço do problema permitindo uma rápida adaptação.

### 3.2.4.1 *Multilayer Perceptron Evolutiva*

O modelo Perceptron Multi-Camadas Evolutivo (eMLP) foi originalmente proposto em (KASABOV, 2003). eMLP é uma rede neural evolutiva que consiste de três camadas de neurônios  $i, j$  e  $k$  denominadas nesta ordem: camada de entrada, com funções lineares ou não-lineares; camada evolutiva; e camada de saída, com funções de ativação lineares saturadas, conforme Figura 12.

**Figura 12 – Arquitetura geral eMLP**



**Fonte:** Adaptado de kasabov<sub>2003</sub>

A camada evolutiva é a camada que se adapta aos dados e é também a camada a qual o aprendizado está mais relacionado. O nível de ativação de um neurônio  $\phi^v$  coleção finita de nerônios existentes na camada evolutiva  $\phi = \phi^1, \dots, \phi^v, \dots, \phi^c$  considerando função de ativação linear é obtido a partir da Equação 6:

$$A^v = 1 - D^v \tag{6}$$

onde  $D^v$  é a distância normalizada entre o vetor de entrada atual e o vetor de pesos das conexões da entrada do neurônio  $\phi^v$ . A medida  $D^v$  pode ser calculada, por exemplo, a partir da distância Euclidiana entre  $X$  e  $W_{ij}^v$

### 3.3 Algoritmos de Aprendizagem

A habilidade aprender a partir de seu ambiente e de melhorar o seu desempenho através da aprendizagem são propriedades fundamentais de uma rede neural. Define-se algoritmo de aprendizado como um conjunto de regras, que tem por objetivo encontrar a melhor solução para um determinado problema, através do reajuste dos pesos (HAYKIN; NETWORK, 2004). Sendo assim, a rede se torna mais instruída sobre o seu ambiente após cada interação do processo de aprendizagem, que corresponde a seguinte sequência de eventos:

1. A rede neural é estimulada por um ambiente;
2. A rede neural sofre modificações nos seus parâmetros livres como resultado desta estimulação
3. A rede neural responde de maneira nova ao ambiente, devido às modificações ocorridas na sua estrutura.

Encontra-se, na literatura, uma grande variedade de algoritmos, que se diferem principalmente pelo modo como os pesos são modificados. Neste trabalho foram utilizados algoritmos de aprendizagem distribuídos de acordo com as arquiteturas de redes neurais utilizadas. A seguir são apresentados os conceitos e equações de cada modelo de treinamento utilizados neste estudo.

#### 3.3.1 *Backpropagation*

O Backpropagation é um método de treinamento supervisionado, baseado em um tipo de regressão denominado gradiente descendente, onde utiliza-se o gradiente de uma função para caminhar para um de seus mínimos locais (GOUVEA, 2012). Utilizado como algoritmo de aprendizagem para ajuste dos pesos de uma rede neural de múltiplas camadas, o algoritmo busca encontrar um vetor  $w$  que minimize o erro  $E$ , que mede o desempenho da rede neural. Definida a função erro na Equação 7, obtida pela média dos erros quadráticos:

$$E = \frac{1}{2} \sum_{i=1}^m (d_i - y_i)^2 \quad (7)$$

Onde  $y_i$  é a  $i$ -ésima saída da RNA, e  $d_i$  é a saída desejada para o  $i$ -ésimo padrão de entrada, e  $j$  é o número de neurônios de saída da rede. O ajuste do  $j$ -ésimo peso do  $i$ -ésimo neurônio é definido pela Equação 8:

$$\Delta w_{ij} = -\eta \delta_i x_j \quad (8)$$

Onde o sinal negativo corresponde ao gradiente descendente no espaço de peso, e

$$\delta_i = \varphi'(v_i)(d_i - y_i) \quad (9)$$

para o  $i$ -ésimo neurônio da camada de saída e

$$\delta_i = \varphi'(v_i) \sum_j \delta_j w_{ij} \quad (10)$$

para o  $i$ -ésimo neurônio da camada oculta, onde o índice  $j$  refere aos neurônios da próxima camada que o  $i$ -ésimo neurônio está conectado. O coeficiente  $\eta$ , denominado taxa de aprendizagem, determina o comprimento do passo da função do erro quadrático.

### 3.3.1.1 Levenberg-Marquardt

O algoritmo Levenberg-Marquardt é um método de otimização e aceleração da convergência do algoritmo backpropagation, sendo mais poderoso do que a técnica convencional do gradiente descendente (BISHOP, 1995). É considerado um método de segunda ordem, assim como os métodos do gradiente conjugado e do método Gauss-Newton, pois utiliza informações sobre a derivada segunda da função de erro. Além disso, assim como o método quase-Newton, o algoritmo de Levenberg-Marquardt pode tornar-se computacionalmente impraticável em RNAs muito grandes. Porém, é mais eficiente do que método do gradiente conjugado em RNAs com algumas centenas de pesos e possui menor custo computacional do que o método quase-Newton (HAGAN; MENHAJ, 1994).

A aproximação do LM é obtida a partir da modificação do método de Gauss-Newton introduzindo-se o parâmetro  $\mu$ , conforme a equação

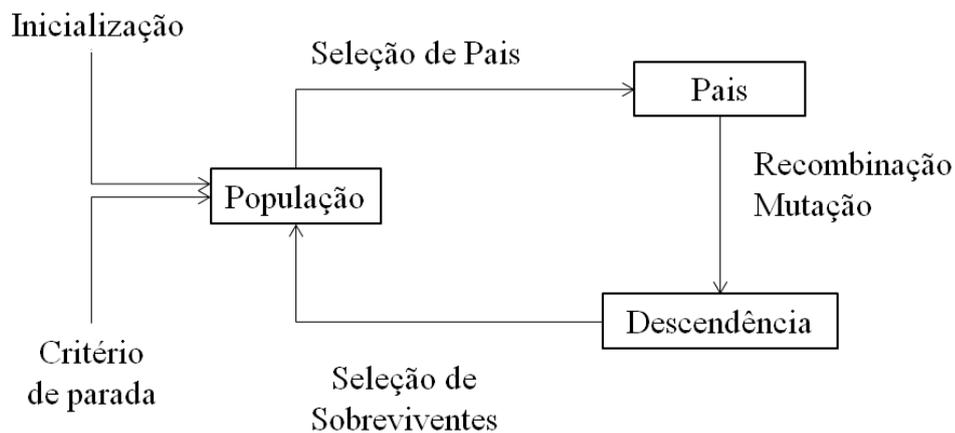
$$\Delta x = [J^t(x)J(x) + \mu I]^{-1} J^t(x)e(x) \quad (11)$$

onde  $I$  é a matriz identidade,  $e(x)$  é o erro e  $J$  é a matriz Jacobiana. O parâmetro  $\mu$  é multiplicado por um fator ( $\beta$ ) toda vez que um passo resultar num aumento na função erro, que se deseja minimizar. Quando um passo resultar na diminuição da função genérica  $V(x)$ ,  $\mu$  é dividido pelo fator  $\beta$ . Isto significa dizer que, se houver uma convergência para o mínimo da função,  $\mu$  é pequeno e o algoritmo se aproxima do método de Newton; no caso de não haver convergência, o método se aproxima da descida de gradiente. O parâmetro  $\mu$  funciona como um fator de estabilização do treinamento, ajustando a aproximação de forma a utilizar a rápida convergência do método de Newton e evitando passos muito grandes que possam levar a um erro de convergência.

### 3.3.2 Algoritmo Genético

O Algoritmo Genético (AG) é um método de busca e otimização global, probabilístico, baseado no princípio da evolução de Darwin e na genética (GOLDBERG, 1989; CALVETE; GALE; IRANZO, 2013). Em um AG, existem inúmeras soluções para um mesmo problema, chamadas de população de indivíduos. A qualidade da solução gerada por um indivíduo é denominada aptidão ou fitness. A partir de uma população inicial, aplica-se, ciclicamente, nos indivíduos operadores de variação, denominados cruzamento e mutação. Com o passar das iterações, ou gerações, o fitness médio da população tende a melhorar – chegando a uma solução ótima ou sub-ótima para o problema. A Figura 13 apresenta o esquema de um algoritmo genético padrão.

**Figura 13 – Esquema do Algoritmo Genético**



Fonte: Elaborada pela autora

As próximas subseções apresentam os operadores genéticos e a dinâmica global do AG.

#### 3.3.2.1 Seleção

Dada uma população em que a cada indivíduo foi atribuído um valor de aptidão, existe vários métodos para selecionar os indivíduos sobre os quais serão aplicados os operadores genéticos. Há diversas formas de seleção, entre eles há o método de seleção por Roleta e o método de seleção por Torneio. No método de seleção por Roleta, cada indivíduo da população é representado na roleta proporcionalmente ao seu índice de aptidão. Assim, para indivíduos com alta aptidão é dada uma porção maior da roleta, enquanto aos indivíduos de aptidão mais baixa, é dada uma porção relativamente menor.

Um outro método é a seleção por Torneio, onde um número  $n$  de indivíduos da população é escolhido aleatoriamente para formar uma sub-população temporária. Deste grupo, o indivíduo selecionado dependerá de uma probabilidade  $k$  definida previamente.

### **3.3.2.2 Recombinação**

Através do cruzamento são criados novos indivíduos misturando características de dois indivíduos "pais". Esta mistura é feita tentando imitar (em um alto nível de abstração) a reprodução de genes em células. Trechos das características de um indivíduo são trocados pelo trecho equivalente do outro. O resultado desta operação é um indivíduo que potencialmente combine as melhores características dos indivíduos usados como base.

### **3.3.2.3 Mutação**

Esta operação simplesmente modifica aleatoriamente alguma característica do indivíduo sobre o qual é aplicada. Esta troca é importante, pois acaba por criar novos valores de características que não existiam ou apareciam em pequena quantidade na população em análise. O operador de mutação é necessário para a introdução e manutenção da diversidade genética da população. Desta forma, a mutação assegura que a probabilidade de se chegar a qualquer ponto do espaço de busca possivelmente não será zero.

### **3.3.2.4 Modelo de População**

A população de um algoritmo genético é o conjunto de indivíduos que estão sendo cogitados como solução e que serão usados para criar o novo conjunto de indivíduos para análise. O tamanho da população pode afetar o desempenho global e a eficiência dos algoritmos genéticos. Populações muito pequenas têm grandes chances de perder a diversidade necessária para convergir a uma boa solução, pois fornecem uma pequena cobertura do espaço de busca do problema. Entretanto, se a população tiver muitos indivíduos, o algoritmo poderá perder grande parte de sua eficiência pela demora em avaliar a função de aptidão de todo o conjunto a cada iteração, além de ser necessário trabalhar com maiores recursos computacionais. Uma população pode ser gerada através do Modelo de Geração, isto é, a partir de uma população com  $n$  indivíduos, são selecionados  $n$  indivíduos para cruzamento. A partir dos indivíduos selecionados para cruzamento, são gerados  $n$  novos indivíduos que formam a nova geração; e Modelo de Regime Permanente, onde a partir de uma população com  $n$  indivíduos, somente  $\lambda$  indivíduos são substituídos a cada nova geração.

### **3.3.2.5 Dinâmica**

A implementação de um AG inicia-se com uma população inicial gerada aleatoriamente, cuja aptidão de cada indivíduo é avaliada. A aptidão dá uma mostra do quão próxima está a solução do indivíduo da solução desejada. Neste trabalho, a aptidão de um

indivíduo é medida em função do erro quadrático médio, conforme Equação 12.

$$E = \frac{1}{p} \sum_p \sum_{i=1}^n d_i y_i \quad (12)$$

Sendo  $p$  é o número de padrões,  $d_i$  apresenta a saída desejada e  $y_i$  representa a saída da rede neural. Após o cálculo da aptidão, é gerada uma nova população de indivíduos (filhos), através do processo de seleção e cruzamento. No processo de seleção, são selecionados dois indivíduos (pais) probabilisticamente gerando dois filhos, garantindo que as características dos pais sejam passadas para os filhos. Em seguida, é aplicado o operador de mutação, quando cada gene, ou variável de decisão, é alterado aleatoriamente – garantindo novas características ao indivíduo. Finalmente, a nova população de filhos passa novamente por todo o processo evolucionário que continua até que um critério de parada se atendido (AFFENZELLER et al., 2009).

Como algoritmo de otimização, um AG pode ser utilizado como algoritmo de treinamento de uma RNA para encontrar os pesos sinápticos que minimizem o desvio entre as saídas desejadas e as geradas pela RNA.

### 3.3.3 *Treinamento Evolutivo*

Uma eMLP aprende se o sistema otimizar ao menos parte de sua estrutura  $E$  e função  $F$  após a observação dos eventos  $\Psi_1, \Psi_2, \dots$ , de um problema no espaço  $\Psi$ . Através do processo de aprendizado, o sistema melhora sua reação aos eventos observados e captura informações que podem posteriormente representar conhecimento (LEITE; COSTA; GOMIDE, 2009).

O termo Evolutivos no contexto de ECoS não está relacionado à Algoritmo Genético como visto na Seção 5.4.2. Evolutivo para ECoS se refere ao fato de que esses sistemas mudam ao longo do tempo, a estrutura da rede do ECoS é dinâmica.

Basicamente, o aprendizado em ECoS consiste nas seguintes etapas:

1. Aquisição de Dados;
2. Pré processamento e avaliação de características;
3. Modelagem conexionista;
4. Aquisição de conhecimento.

Na primeira passagem do exemplo pelo treinamento, um ECoS já deve aprender o dado, com isto ele é um aprendizado online, ou seja, enquanto os dados são apresentados para a rede, os dados que foram apresentados nos treinamentos passados não precisam ser re-treinados e não são esquecidos. Assim é possível que a rede acomode novos dados sem perder a capacidade adquirida com os dados apresentados em treinamentos anteriores

O aprendizado eMLP é baseado na acomodação de novos exemplos de treinamento nos parâmetros do modelo através do ajuste dos pesos sinápticos, ou então adição de novos neurônios na camada de neurônios, estendendo assim a coleção atual de neurônios  $\phi$ , que antes do treinamento é igual a zero.

Quando um neurônio  $\phi$  é criado, seu respectivo vetor de pesos  $W_{ij}^\phi$  é ajustado exatamente para o vetor de entrada  $x$ , ao passo que seu vetor de pesos de saída  $W_{jk}^\phi$  é ajustado para o vetor de saída desejado  $y$ . Um neurônio é dito vencedor quando ele apresenta a maior ativação  $A^v$ , conforme Equação 13 para a entrada atual. Os pesos  $W_{ij}^v$  do neurônio vencedor são ajustados de acordo com:

$$W_{ij}^v = W_{ij}^v + \eta_1(x - W_{ij}^v) \quad (13)$$

Onde  $\eta_1$  é a taxa de aprendizado 1. O vetor de pesos de saída do neurônio vencedor é ajustado de acordo com a Equação 14:

$$W_{jk}^v = W_{jk}^v + \eta_2(A^v E^v) \quad (14)$$

Onde  $\eta_2$  é a taxa de aprendizado 2 e  $E^v$  é um vetor de erro obtido a partir da Equação 15:

$$E^v = y - \bar{y} \quad (15)$$

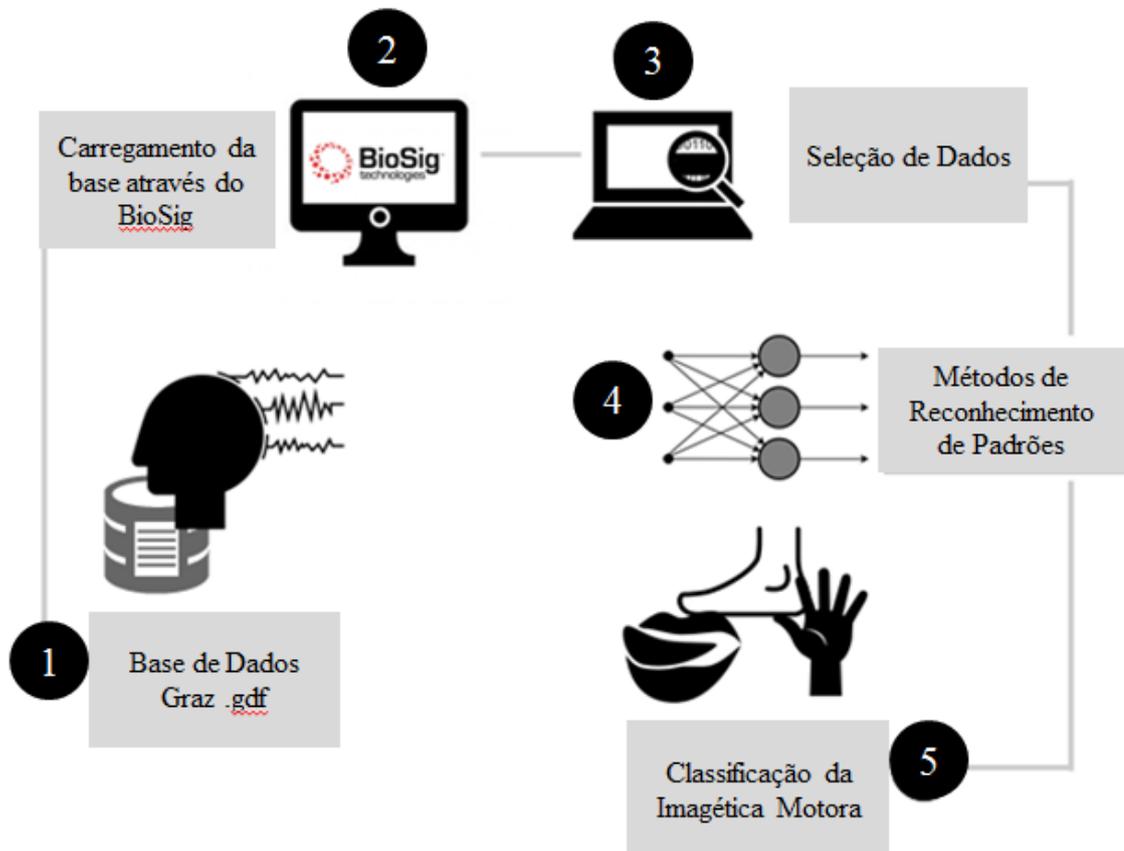
Onde  $y$  é a saída desejada e  $\bar{y}$  é a saída obtida pela rede.

A agregação de neurônios na camada evolutiva de redes eMLP é um mecanismo sugerido para manter controle sob a quantidade de neurônios se desenvolvendo durante o processo de aprendizado. Basicamente, este operador agrega dois neurônios se desenvolvendo de forma similar em um único neurônio. O operador de agregação pode ser aplicado em todas as iterações do algoritmo de aprendizado ou após um certo número de iterações. Em geral, este operador melhora a capacidade de generalização razoável de informação ativa na memória.

#### 4 MODELOS DE REDES NEURAIS ARTIFICIAIS NO RECONHECIMENTO DE PADRÕES EM SINAIS DE EEG

Neste trabalho desenvolveu-se um estudo experimental utilizando RNAs para reconhecimento de padrões em sinais de eletroencefalograma, na classificação da imagética motora. A Figura 14 descreve, de forma geral, o funcionamento do sistema proposto neste trabalho. Todo o conjunto de dados é armazenado no Formato Geral para Sinais Biomédicos (GDF). Os arquivos GDF são carregados usando a caixa de ferramentas *open-source* BioSig, disponível gratuitamente para o MATLAB. Posteriormente, os dados são submetidos aos métodos de reconhecimento de padrões e classificados em três movimentos imaginários (movimento das mãos, ambos os pés e língua). Diante de tal tarefa, o modelo proposto é avaliado em relação aos três modelos utilizados.

Figura 14 – Fluxograma do sistema proposto



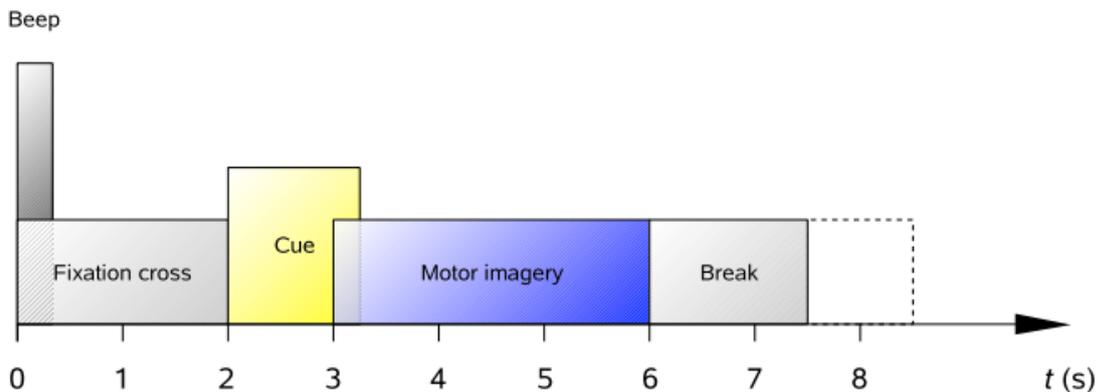
Fonte: Elaborada pela autora

##### 4.1 Base de Dados

Os dados de EEG utilizados neste estudo são obtidos através do conjunto 2a obtido na IV Competição Internacional de BCI (NAEEM, 2006). Esse conjunto de dados consiste

de sinais de EEG a partir de 9 indivíduos. O paradigma de análise consiste de três tarefas da imagética motora, a saber: (i) imaginação do movimento das mãos (classe 1), (ii) ambos os pés (classe 2) e (iii) língua (classe 3). Duas sessões em dias diferentes foram gravadas para cada . Uma execução consiste de 48 ensaios (16 para cada uma das três classes possíveis). No início de cada sessão, uma gravação de cerca de 5 minutos foi realizada para avaliar a influência Eeetrooculagrama, porém tais dados não foram levados em consideração neste trabalho. No início de um ensaio ( $t = 0$  s), uma cruz de fixação aparece na tela. Além disso, um sinal de aviso acústico curto é apresentado. Depois de dois segundos ( $t = 2$  s), aparece na tela uma sinalização na forma de uma seta apontando para a esquerda, direita, para baixo ou para cima (o que corresponde a uma das três classes mãos, pés ou língua). Isto levou os indivíduos a executar a tarefa imagética motora desejada. Foi solicitado que os indivíduos realizassem a tarefa imagética motora até a cruz de fixação desaparecesse da tela em  $t = 6$  s. O paradigma é ilustrado na Figura 15.

**Figura 15 – Esquema do paradigma cronometrado**



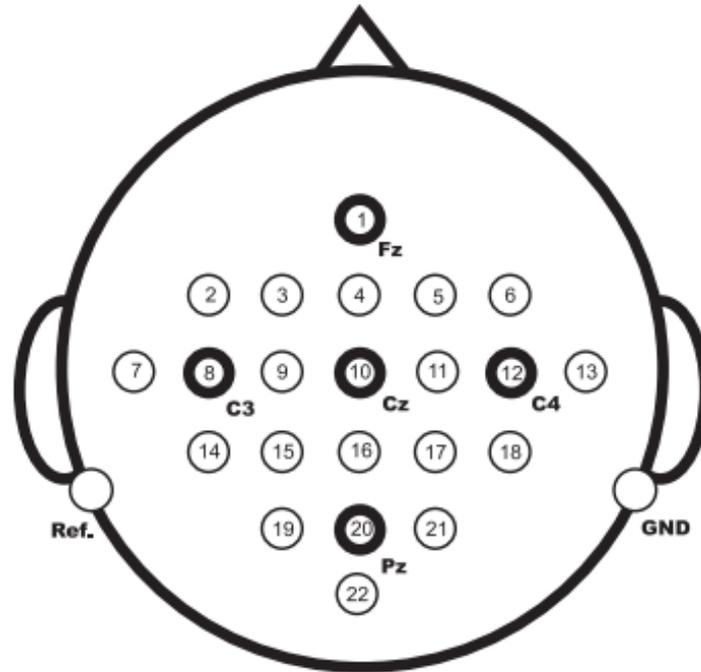
Fonte: naeem

Vinte e dois eletrodos Ag/AgCl (com distâncias intereletrodo de 3,5 cm) são usados para gravar os sinais de EEG; como mostra a Figura 16. Os sinais foram amostrados com 250 Hz e filtro passa-faixa entre 0,5 Hz e 100 Hz. A sensibilidade do amplificador foi ajustado para 100  $\mu$ V.

Para este trabalho, o tamanho da base de dados foi ajustado conforme o problema em estudo. Utilizou-se 540 exemplo de sinais, sendo 180 exemplos para cada uma das 3 classes da base de dados distribuídos igualmente entre os 9 indivíduos. Cada exemplos de sinal é composto por uma série temporal com cerca de  $N$  amostras, sendo  $N=1000$ .

Os exemplos foram selecionados na base de dados levando em consideração o tempo de melhor resposta do sinal. No início da coleta, os sinais ainda são imprecisos, já ao final da coleta, o paciente encontra-se levemente saturado e os sinais sofrem alteração, assim os sinais utilizados para remontar a base deste estudo correspondem ao tempo intermediário

Figura 16 – Posicionamento dos Eletrodos



Fonte: naeem

da sessão.

#### 4.1.1 Abordagens para tratamento dos sinais EEG

O sinal de EEG é dado por uma série temporal variável, que depende diretamente do estado em que o paciente se encontra (LEHNERTZ, 1999). Série temporal é um conjunto de observações feitas sequencialmente ao longo do tempo, onde sua característica mais importante é que as observações vizinhas são dependentes. Uma série temporal pode ser classificada como (i) contínua, quando as observações são feitas continuamente no tempo, ou como (ii) discreta, quando as observações são feitas em tempos específicos (BOX; JENKINS; REINSEL, 1994; BROCKWELL; J.; DAVIS, 2013).

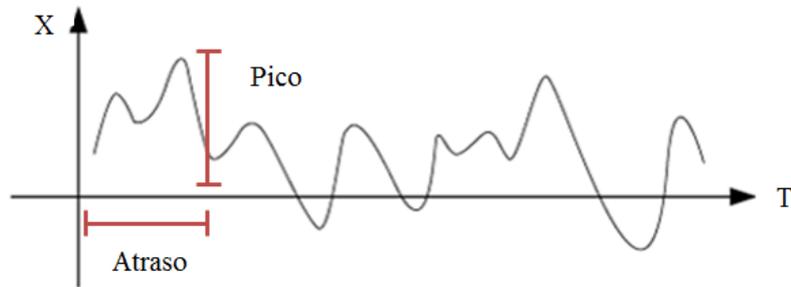
Neste estudo, a série temporal é utilizada apenas na *Time-Delay Neural Network*, já nos demais métodos, com o objetivo de não perder informações com o uso da série temporal duas abordagens distintas foram adotadas:

1. Raiz do valor quadrático médio ou Root-mean-square (RMS) da Série Temporal, que é uma medida estatística da magnitude de uma quantidade variável, conforme Equação 16:

$$X_{RMS} = \sqrt{\frac{1}{N} \sum_{n=1}^1 |X_n|^2} \quad (16)$$

2. Pico e Atraso da Série Temporal, sendo o pico a amplitude do sinal e o atraso refere-se ao tempo que demorou para atingir este pico, conforme a Figura 17:

**Figura 17 – Esquema Pico/Atraso**



**Fonte: Elaborada pela autora**

#### 4.1.2 Normalização

Seguindo as abordagens acima, os dados foram normalizados em uma nova escala, não perdendo o significado da informação neles contidas. Caso a normalização não seja realizada, os dados de entrada terão um efeito adicional sobre o neurônio da rede neural em estudo, levando a decisões erradas (HAYKIN; NETWORK, 2004).

Neste estudo, os dados foram normalizados para o intervalo  $[0,1]$ , segundo a amplitude, que é utilizada quando as unidades são diferentes ou as dispersões são muito heterogêneas, como segue na Equação 17:

$$y = \frac{x - \min}{\max - \min} \quad (17)$$

sendo  $y$  é o dado normalizado,  $x$  é o dado a ser normalizado,  $\min$  o menor valor da base de dados  $\max$  o maior valor da base de dados. Na MLP e TDNN, a normalização foi aplicada a toda base de dados, antes mesmo de dividi-la em conjuntos de: treinamento, teste e validação. Já na eMLP, cada linha da matriz (atributo) foi normalizada, ao invés da base como um todo (vetores de entrada), para assim em seguida dividi-la em treinamento e teste.

## 4.2 Modelagem da Arquitetura

Projetar a arquitetura de uma rede neural artificial para um problema envolve algumas etapas, como:

1. Determinar quantidade de camadas
2. Quantos neurônios artificiais ocultos a RNA deve possuir

3. Especificar de acordo com a base de dados, a tamanho das camadas de entrada e saída da rede

A etapa de determinar quantos neurônios artificiais ocultos e quantas camadas a rede deverá possuir para solucionar com precisão o problema, é uma tarefa que não possui resposta exata. Porém, existem heurísticas que procuram estimar essas variáveis e que devem se comprometer a (i) convergência da rede, que é a capacidade da rede de aprender todos os padrões de entrada usados no seu treinamento; e a (ii) generalização, que é a capacidade da rede neural responder adequadamente a padrões inéditos, i.e., não apresentados no treinamento. Uma RNA muito grande – com número de neurônios muito superior aos necessários para o problema – não responderá corretamente a padrões nunca vistos – perderá a capacidade de generalizar. Isto ocorrerá pois os pesos sinápticos da rede aprenderão os vetores de entrada e também o ruído presente nos dados de treinamento (FAUSETT, 1994).

A arquitetura a ser utilizada neste trabalho é apresentada de acordo com o modelo neural ao qual se refere, a saber:

1. Rede MLP: apresenta o número de neurônios na camada de entrada variável de acordo com a abordagem utilizada, isto é, na abordagem (i) RMS, são 22 neurônios de entrada, e na (ii) Pico/Atraso, são 44 neurônios de entrada. Utilizou-se uma única camada intermediária, variando-se o número de neurônios da mesma a fim de verificar qual quantidade apresenta melhores resultados. A camada de saída é composta de 3 neurônios binários, cada qual representando uma classe da base;
2. Rede TDNN: A camada de entrada possui o dobro do número de canais da base de dados, pelo fato da utilização do atraso no tempo (delay de  $t-1$ ), para cada uma das curvas de entrada. Este atraso é formado pelo valor atual da amplitude do sinal e por um valor temporalmente anterior a este, de cada um dos 22 canais, totalizando 44 entradas. A camada de saída é composta de 3 neurônios binários, cada qual representando uma classe da base;
3. Rede eMLP: apresenta o número de neurônios na camada de entrada variável de acordo com a abordagem utilizada. Na camada evolutiva o número de neurônios é adaptado de acordo com os dados apresentados. A camada de saída é composta de 3 neurônios, cada qual representando uma classe da base.

### 4.3 Classificação dos Padrões

A eficiência de uma rede neural é dada pela taxa de acerto obtida para um determinado conjunto de teste, i.e., não usado no treinamento. Deve-se diferenciar desempenho de treinamento, de teste e de validação.

A classificação das abordagens propostas ocorre com o estudo de três modelos de RNA e os algoritmos de treinamentos específicos, apresentados no Capítulo 3, a saber:

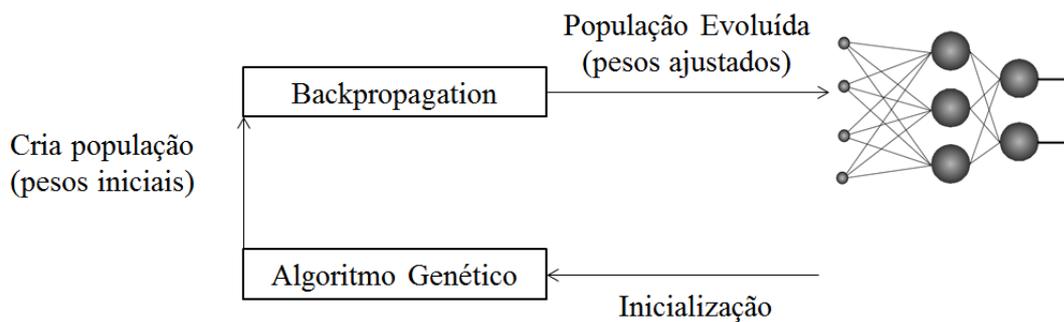
1. Rede MLP treinada via Backpropagation, Algoritmo Genético e Algoritmo Híbrido;
2. Rede TDNN treinada via Backpropagation adaptado;
3. Rede eMLP treinada de forma evolutiva.

#### 4.4 Treinamento Híbrido

Este trabalho propõe um algoritmo híbrido para o reconhecimento de padrões da base utilizada. A aprendizagem híbrida é um método que combina duas ou mais técnicas de aprendizagem, para ajuste dos pesos sinápticos de uma rede neural, com o objetivo de unir as vantagens e superar limitações individuais de cada técnica. Este método permite construir sistemas mais robustos, resolver problemas mais complexos, dentre outras vantagens.

Nesta pesquisa, o treinamento híbrido da RNA combinará as vantagens de busca global do Algoritmo Genético com as vantagens de busca local do Backpropagation, um método de otimização que parte de um ponto inicial aleatório e realiza a busca direcionada do ótimo local através do cálculo do gradiente da função-objetivo (BURGES et al., 2005). O AG é utilizado para encontrar boas regiões no espaço de peso, enquanto o backpropagation realiza uma busca local nessa região, conforme Figura 18.

**Figura 18 – Esquema do Algoritmo Híbrido utilizado neste estudo**



Fonte: Elaborada pela autora

## 5 ESTUDO EXPERIMENTAL

Este capítulo apresenta o estudo experimental para os modelos de RNA: Rede Multilayer Perceptron, Rede *Time-Delay* e Rede Multilayer Perceptron Evolutiva executados para o reconhecimento de padrões da Imagética Motora em sinais de EEG. O objetivo desses experimentos é validar o desempenho dos algoritmos de treinamento na tarefa de prever o movimento imaginário das mãos, pés e língua.

### 5.1 Classificações via Rede Multilayer Perceptron

Para os experimentos utilizando a rede MLP na classificação dos sinais EEG foram utilizadas 320 amostras para treinamento, 110 amostras para validação e 110 amostras para teste.

Uma das questões mais discutidas na literatura é quanto ao número de neurônios na camada oculta na topologia de RNA. Utilizar poucos neurônios na camada oculta implica em uma RNA incapaz de modelar dados mais complexos, resultando em uma baixa capacidade de generalização. Se muitos neurônios foram utilizados, o treinamento da RNA torna-se excessivamente longo e a rede pode sofrer problemas de reajuste (HAYKIN; NETWORK, 2004). O número de neurônios na camada oculta, neste estudo, é definido empiricamente; porém toma-se como base a heurística do valor  $2n - 1$  como partida, sendo  $n$  é o número de entradas da RNA. Assim, para a abordagem RMS, que possui 22 neurônios de entrada, realizou-se experimentos com 25, 30, 43 e 45 neurônios na camada oculta. Para abordagem Pico/Atraso, que possui 44 neurônios de entrada, realizou-se experimentos com 50, 60, 87 e 90 neurônios na camada oculta.

Outro ponto importante no treinamento de uma RNA é o intervalo de pesos sinápticos, de forma a alcançar o intervalo que apresenta o melhor desempenho para cada abordagem. Neste estudo, utiliza-se a fórmula proposta por Wessels e Barnard (1992), onde é proposto que a inicialização dos pesos devem estar uniformemente distribuídas no intervalo  $[-a, a]$ , sendo  $a \in \mathbb{R}$ . Após a realização de testes experimentais ficou definido para a abordagem RMS o intervalo de pesos  $[-10, 10]$  e para a abordagem Pico/Atraso o intervalo de pesos  $[-25, 25]$ .

As seções subsequentes apresentam os experimentos realizados com diferentes algoritmos de treinamento para ambas abordagens, buscando qual a topologia e método apresente o menor EQM de teste, melhor capacidade de generalização.

### 5.1.1 Abordagem RMS

#### 5.1.1.1 *Treinamento com Algoritmo Genético*

Para os experimentos, o algoritmo genético foi executado por 100 épocas de treinamento e configurado com os seguintes parâmetros específicos, baseados nos estudos iniciais:

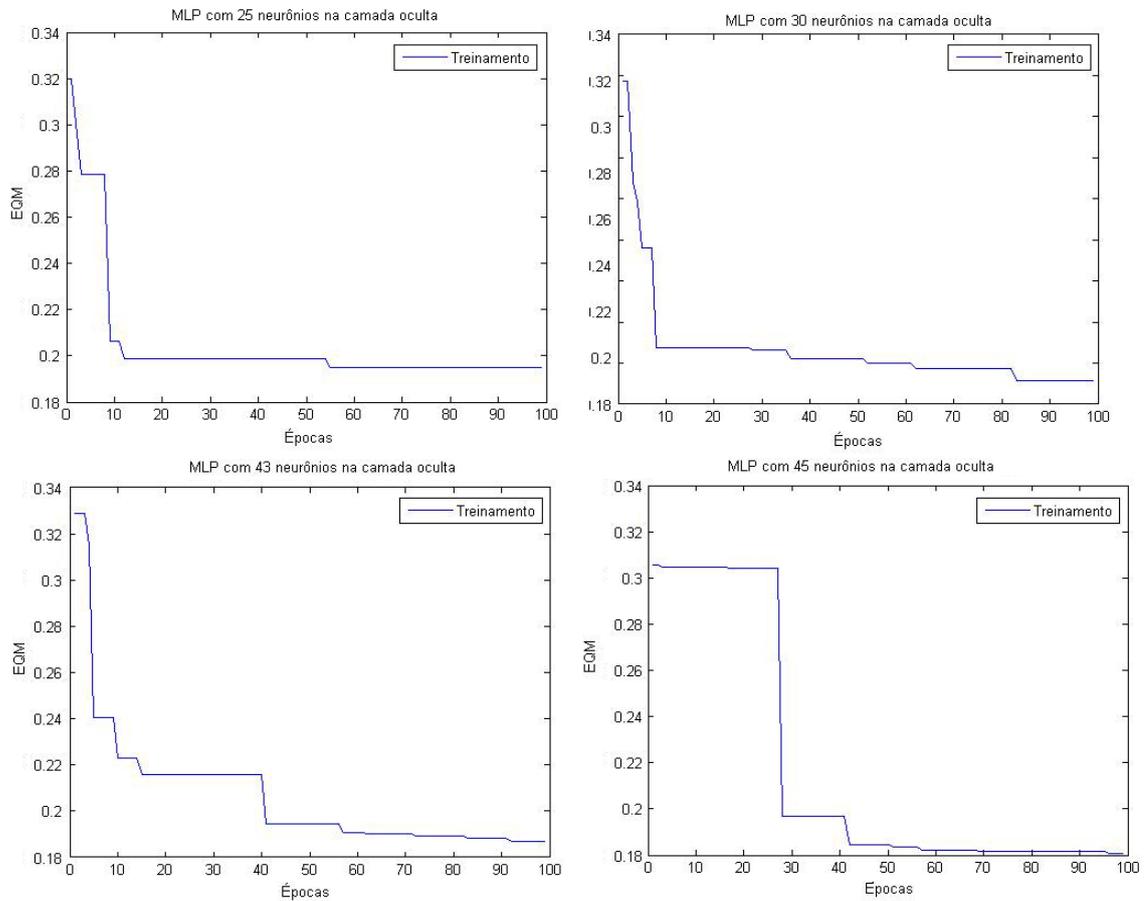
- Tamanho da população de pesos sinápticos: 50
- Taxa de seleção: 10%
- Tipo de seleção: Seleção por torneio
- Taxa de cruzamento: 60%
- Taxa de mutação: 10%
- Modelo de População por Regime Permanente

O AG determina os valores dos pesos sinápticos ajustados, que em seguida são utilizados na execução da MLP, obtendo assim os valores de saída da rede que em seguida são comparados com a saída desejada. A seguir, os resultados são individualmente apresentados para cada abordagem.

A Figura 19 mostra o EQM durante o treinamento da MLP com o algoritmo genético para diferentes topologias na abordagem RMS. Pode-se verificar que nas diferentes topologias os resultados finais foram menores que 0,2. Observa-se que nas topologias de 25, 30 e 43 neurônios na camada oculta com apenas cerca de 10 épocas de treinamento o EQM já sofre uma redução considerável, enquanto na abordagem de 45 neurônios na camada oculta o EQM tende a diminuir consideravelmente com 30 épocas de treinamento. Nas quatro abordagens, os EQMs da base de treinamento tendem a convergir para um certo valor.

A Tabela 2 mostra o EQM final para cada topologia e seu respectivo tempo de treinamento. Os dados apresentados comprovam a análise dos gráficos da Figura 19, onde a topologia com 45 neurônios na camada oculta apresenta o EQM mais baixo dentre as demais topologias. A medida que aumenta-se o número de neurônios na camada oculta, maior é o tempo de treinamento da MLP com o algoritmo genético, que mantém uma média de aproximadamente 4 a 5,5 minutos.

**Figura 19 – Algoritmo Genético: EQM dos dados de treinamento das diferentes topologias para a abordagem RMS**



Fonte: Resultados da pesquisa

**Tabela 2 – Algoritmo Genético: Resultados do treinamento das topologias para a abordagem RMS**

Topologia (neurônios camada oculta)	EQM		Tempo de Treinamento (ms)
	Treinamento	Validação	
25	0.1922	0.2145	256029
30	0.1846	0.1741	293844
43	0.1835	0.1736	315621
45	0.1801	0.1663	319687

Fonte: Resultados da pesquisa

A Tabela 3 apresenta as taxas de acerto, os EQMs e os respectivos tempos, para a fase de teste das diferentes topologias da MLP com o algoritmo genético. Todas as topologias tiveram uma taxa de acerto superior à 71%. A MLP com 45 neurônios na camada oculta teve menor EQM e maior taxa de acerto, 79%.

Para melhor avaliar a qualidade dos resultados gerados, a Figura 20 apresenta a

**Tabela 3 – Algoritmo Genético: Resultados do teste das topologias para a abordagem RMS**

Topologia (neurônios camada oculta)	Teste	
	Taxa de acerto (%)	EQM
25	<b>71.4</b>	0.2157
30	75.6	0.1892
43	78.6	0.1863
45	<b>79.0</b>	0.1851

Fonte: Resultados da pesquisa

Matriz de Confusão para a melhor topologia da abordagem RMS. A Matriz de Confusão resume os resultados de teste. As três primeiras células diagonais mostram o número e a porcentagem de classificações corretas treinadas pela rede para as classes 1 (movimento das mãos), 2 (movimento dos pés) e 3 (movimento da língua). Comprovando os resultados da Tabela 3, observa-se que a abordagem de 45 neurônios na camada oculta, apresenta apenas 21% de padrões treinados incorretamente, ou seja, a menor taxa de erro e a maior taxa de acerto entre as topologias estudadas. Nota-se que a classe 1 é linearmente separável, onde nunca é confundida com as demais classes.

**Figura 20 – Algoritmo Genético: Matriz de Confusão de teste do melhor caso para a abordagem RMS**

Output Class	1	<b>12</b> 11.3%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>100%</b> 0.0%
	2	<b>14</b> 12.9%	<b>36</b> 32.3%	<b>4</b> 3.2%	<b>66.7%</b> 33.3%
	3	<b>0</b> 0.0%	<b>5</b> 4.8%	<b>39</b> 35.5%	<b>88.0%</b> 12.0%
		<b>46.7%</b> 53.3%	<b>87.0%</b> 13.0%	<b>91.7%</b> 8.3%	<b>79.0%</b> <b>21.0%</b>
		1	2	3	Target Class

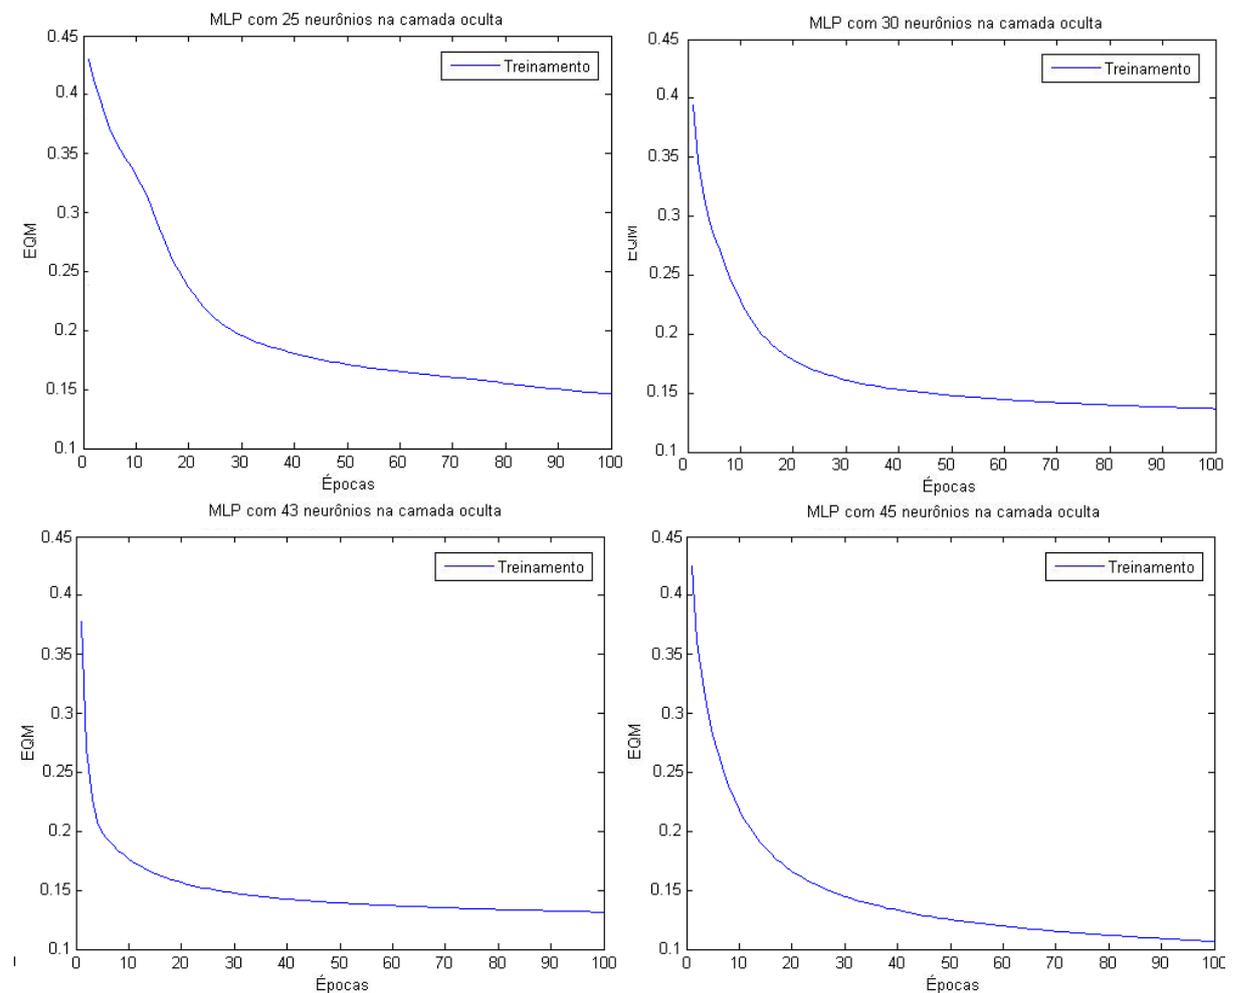
Fonte: Resultados da pesquisa

### 5.1.1.2 Treinamento com Algoritmo Backpropagation

O *Backpropagation* foi executado por 100 épocas de treinamento. Utilizou-se como função de ativação a função sigmoide e estabeleceu empiricamente o valor da constante  $k=0.5$ .

O *Backpropagation* determina os valores dos pesos sinápticos da rede. A Figura 21 mostra os EQMs durante o treinamento da MLP com o backpropagation para diferentes topologias na abordagem RMS. Pode-se verificar que os resultados finais de erro foram menores que 0,15. Observa-se que o valor do EQM tende a convergir após cerca de 70 épocas treinamento.

**Figura 21 – Backpropagation: EQM dos dados de treinamento das diferentes topologias para a abordagem RMS**



Fonte: Resultados da pesquisa

A Tabela 4 mostra o EQM para cada topologia e seu respectivo tempo de treinamento. Os dados apresentados comprovam a análise dos gráficos da Figura 21, onde a topologia com 45 neurônios na camada oculta apresenta o EQM mais baixo dentre as topologias. A medida que aumenta-se o número de neurônios na camada oculta, maior é o tempo de

treinamento da MLP com o *Backpropagation*, que mantém uma média de aproximadamente 6 segundos.

**Tabela 4 – Backpropagation: Resultados do treinamento das topologias para a abordagem RMS**

Topologia (neurônios camada oculta)	EQM		Tempo de Treinamento (ms)
	Treinamento	Validação	
25	0.1501	0.1691	5386
30	0.1426	0.1402	5677
43	0.1368	0.1349	6288
45	0.1199	0.1362	6295

Fonte: Resultados da pesquisa

A Tabela 5 apresenta as taxas de acerto, os EQMs e os respectivos tempos, para a fase de teste das diferentes topologias da MLP com o *backpropagation*. Todas as topologias tiveram uma taxa de acerto superior à 88%. A MLP com 45 neurônios na camada oculta teve menor EQM e maior taxa de acerto, se destacando das demais topologias.

**Tabela 5 – Backpropagation: Resultados do teste das topologias para a abordagem RMS**

Topologia (neurônios camada oculta)	Teste	
	Taxa de acerto (%)	EQM
25	<b>88.7</b>	0.1415
30	88.9	0.1410
43	89.4	0.1322
45	<b>90.4</b>	0.1205

Fonte: Resultados da pesquisa

As três primeiras células diagonais da Matriz de Confusão, na Figura 22, mostram o número e a porcentagem de classificações corretas treinadas pela rede para as classes 1 (movimento das mãos), 2 (movimento dos pés) e 3 (movimento da língua). Comprovando os resultados da Tabela 5, observa-se que a topologia de 45 neurônios na camada oculta, apresenta apenas 9,6% de padrões treinados incorretamente, ou seja, a menor taxa de erro e a maior taxa de acerto entre as topologias estudadas. Note também que a classe 1 foi sempre identificado corretamente, e que a dificuldade ou os erros se referem à eventuais trocas entre movimento dos pés e língua.

Figura 22 – Backpropagation: Matriz de Confusão de teste do melhor caso para a abordagem RMS

Output Class	1	36 32.7%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	34 30.8%	2 1.9%	94.1% 5.9%
	3	0 0.0%	8 7.7%	30 26.9%	77.8% 22.2%
		100% 0.0%	80.0% 20.0%	93.3% 6.7%	90.4% 9.6%
		1	2	3	
		Target Class			

Fonte: Resultados da pesquisa

### 5.1.1.3 Treinamento com Algoritmo Levenberg-Marquardt

O algoritmo *Levenberg-Marquardt* foi executado por 100 épocas de treinamento e determina os valores dos pesos sinápticos da rede MLP. A Figura 23 mostra o EQM durante o treinamento da MLP com o *Levenberg-Marquardt* para diferentes topologias na abordagem RMS. Pode-se verificar que nas diferentes topologias os resultados finais foram menores que 0,10. Nas quatro abordagens os EQMs da base de treinamento convergem.

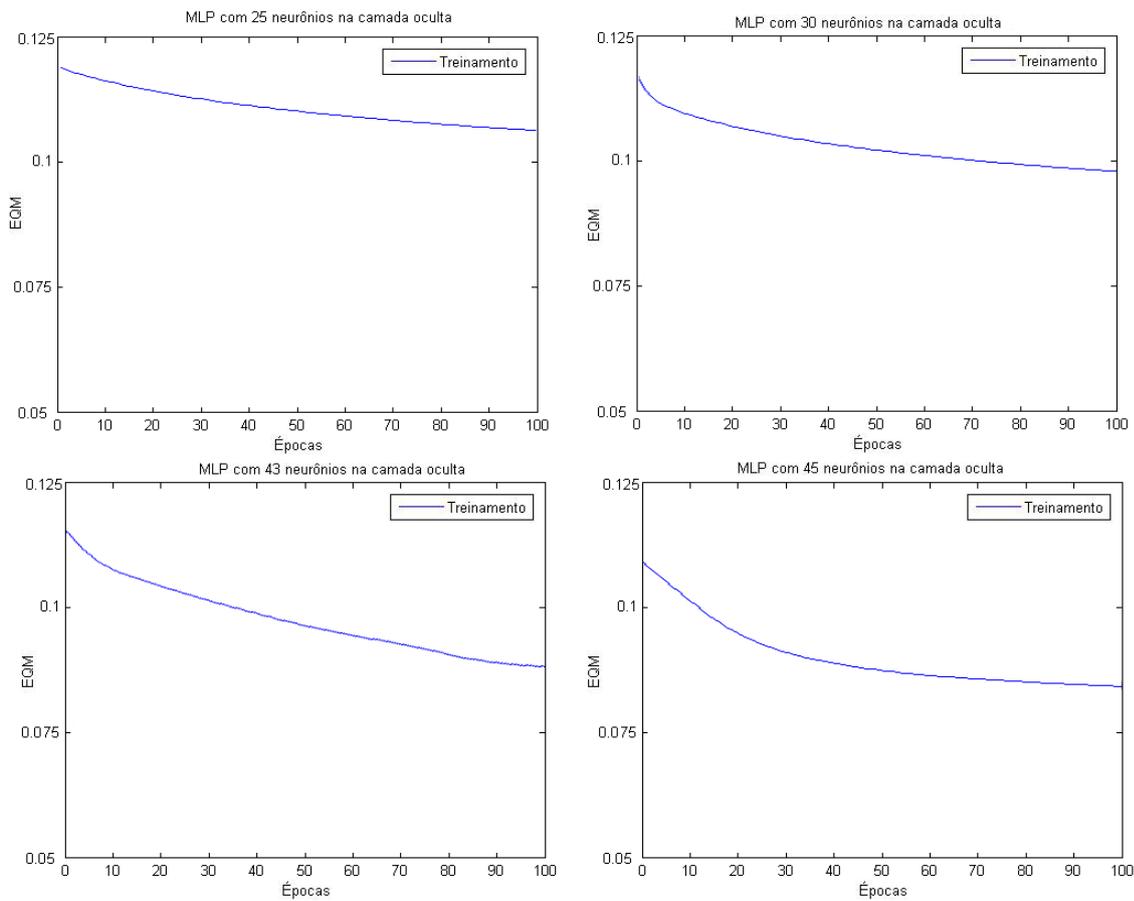
A Tabela 6 mostra o EQM para cada topologia e seu respectivo tempo de treinamento. Os dados apresentados comprovam a análise dos gráficos da Figura 23, onde a topologia com 45 neurônios na camada oculta apresenta o EQM mais baixo dentre as topologias. A medida que aumenta-se o número de neurônios na camada oculta, maior é o tempo de treinamento da MLP com o *Levenberg-Marquardt*, que mantém uma média de 6 segundos.

Tabela 6 – *Levenberg-Marquardt*: Resultados do treinamento das topologias para a abordagem RMS

Topologia (neurônios camada oculta)	EQM		Tempo de Treinamento (ms)
	Treinamento	Validação	
25	0.1081	0.1242	5458
30	0.0973	0.1139	6610
43	0.0891	0.1051	6646
45	0.0829	0.1012	6781

Fonte: Resultados da pesquisa

**Figura 23 – Levenberg-Marquardt: EQM dos dados de treinamento das diferentes topologias para a abordagem RMS**



**Fonte: Resultados da pesquisa**

A Tabela 7 apresenta as taxas de acertos, para a fase de teste das diferentes topologias. Todas as topologias tiveram uma taxa de acerto superior à 93%. A MLP com 45 neurônios na camada oculta teve menor EQM e maior taxa de acerto.

**Tabela 7 – Levenberg-Marquardt: Resultados do teste das topologias para a abordagem RMS**

Topologia (neurônios camada oculta)	Teste	
	Taxa de acerto (%)	EQM
25	<b>93.2</b>	0.0982
30	94.7	0.0946
43	95.1	0.0819
45	<b>95.6</b>	0.0803

**Fonte: Resultados da pesquisa**

A Figura 24 apresenta a Matriz de Confusão para a melhor topologia da abordagem

RMS. A classe 1, 2 e 3 referem-se ao movimento das mãos, pés e língua. Observa-se que a topologia de 45 neurônios na camada oculta, apresenta apenas 4,4% de padrões treinados incorretamente. Nota-se que ocorre confusão entre as classes 2 e 3, ou seja, o mesmo problema dos algoritmos de busca local somente.

**Figura 24 – Levenberg-Marquardt: Matriz de Confusão de teste do melhor caso para a abordagem RMS**

Output Class	1	30 26.7%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	35 32.2%	1 1.1%	96.7% 3.3%
	3	0 0.0%	4 3.3%	40 36.7%	91.7% 8.3%
		100% 0.0%	90.6% 9.4%	97.1% 2.9%	95.6% 4.4%
		1	2	3	
		Target Class			

Fonte: Resultados da pesquisa

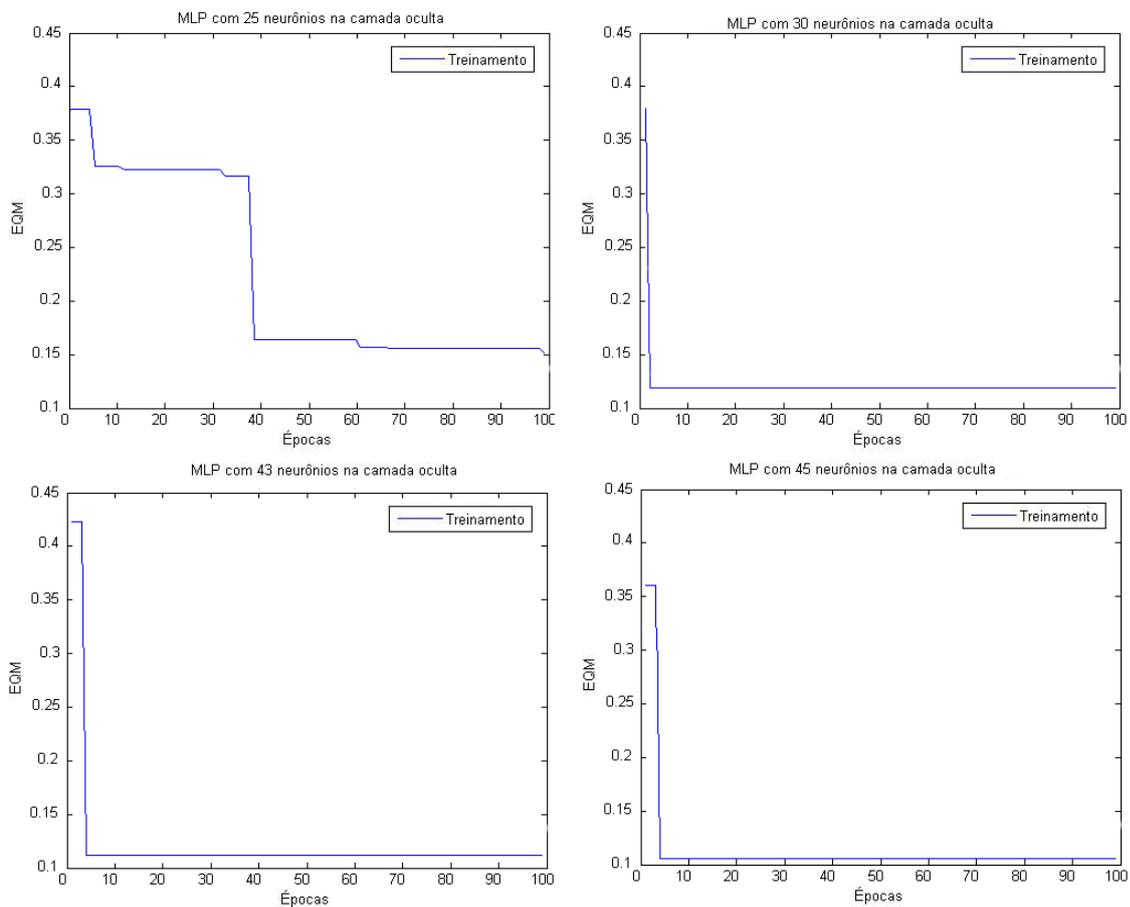
#### 5.1.1.4 Treinamento com Algoritmo Híbrido

O algoritmo híbrido foi executado por 100 épocas de treinamento e configurado com os seguintes parâmetros:

- Número de épocas por indivíduo: 10
- Número de épocas do Backpropagation: 100
- Número de gerações do Algoritmo Genético: 100
- Tamanho da população de pesos sinápticos: 50
- Taxa de seleção: 10%
- Tipo de seleção: torneio
- Taxa de cruzamento: 60%
- Taxa de mutação: 10%

O algoritmo híbrido determina os valores dos pesos da rede MLP. A Figura 25 mostra os EQMs durante o treinamento da MLP com o algoritmo híbrido para diferentes topologias na abordagem RMS. Pode-se verificar que nas diferentes topologias os resultados finais foram menores que 0,15. Observa-se que nas topologias de 30,43 e 45 neurônios na camada oculta com apenas cerca de 5 épocas de treinamento o EQM já sofre uma queda considerável, enquanto na abordagem de 25 neurônios na camada oculta o EQM tende a diminuir consideravelmente com 40 épocas de treinamento. Nas quatro abordagens os EQMs da base de treinamento convergem.

**Figura 25 – Híbrido: EQM dos dados de treinamento das diferentes topologias para a abordagem RMS**



**Fonte: Resultados da pesquisa**

A Tabela 8 mostra o EQM para cada topologia e seu respectivo tempo de treinamento. Os dados apresentados comprovam a análise dos gráficos da Figura 25, onde a topologia com 45 neurônios na camada oculta apresenta o EQM mais baixo dentre as topologias. A medida que aumenta-se o número de neurônios na camada oculta, maior é o tempo de treinamento da MLP com o algoritmo híbrido.

**Tabela 8 – Híbrido: Resultados do treinamento das topologias para a abordagem RMS**

Topologia (neurônios camada oculta)	EQM		Tempo de Treinamento (ms)
	Treinamento	Validação	
25	0.1509	0.1846	35267
30	0.1272	0.1191	35307
43	0.1195	0.1232	37415
45	0.1071	0.1134	37948

Fonte: Resultados da pesquisa

A Tabela 9 apresenta as taxas de acerto, os EQMs e os respectivo tempos, para a fase de teste das diferentes topologias da MLP com o algoritmo híbrido. Todas as topologias tiveram uma taxa de acerto superior à 93%. A MLP com 45 neurônios na camada oculta teve menor EQM e maior taxa de acerto, se destacando das demais topologias.

**Tabela 9 – Híbrido: Resultados do teste das topologias para a abordagem RMS**

Topologia (neurônios camada oculta)	Teste	
	Taxa de acerto (%)	EQM
25	<b>93.3</b>	0.1335
30	94.7	0.1183
43	95.2	0.1148
45	<b>95.7</b>	0.1079

Fonte: Resultados da pesquisa

A Matriz de Confusão para a melhor topologia da abordagem RMS é apresentada na Figura 26. As três primeiras células diagonais mostram o número e a porcentagem de classificações corretas treinadas pela rede para as classes 1 (movimento das mãos), 2 (movimento dos pés) e 3 (movimento da língua). Comprovando os resultados da Tabela 9, observa-se que a topologia de 45 neurônios na camada oculta, apresenta apenas 4.3% de padrões treinados incorretamente. Nota-se que quando usou o AG houve confusão entre as classes 1 e 2. Com o pós-processamento via BP, a solução tende para o local mínimo. Não há mais confusão com relação a classe 1.

Figura 26 – Híbrido: Matriz de Confusão de teste do melhor caso para a abordagem RMS

Output Class	1	38 34.8%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	48 43.5%	5 4.3%	90.9% 9.1%
	3	0 0.0%	0 0.0%	19 17.4%	100% 0.0%
		100% 0.0%	100% 0.0%	80.0% 20.0%	95.7% 4.3%
		1	2	3	
		Target Class			

Fonte: Resultados da pesquisa

### 5.1.2 Abordagem Pico/Atraso

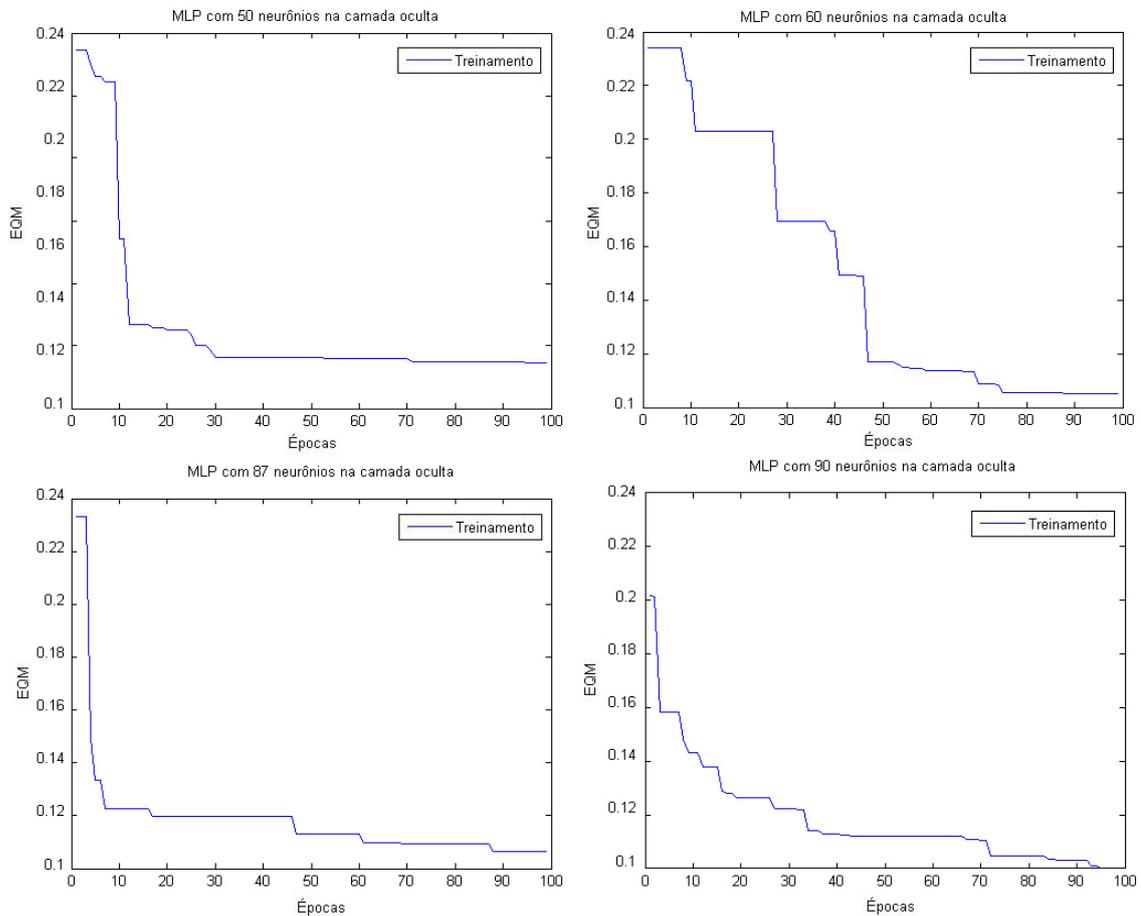
#### 5.1.2.1 Treinamento com Algoritmo Genético

A Figura 27 mostra os EQMs durante o treinamento da MLP com o algoritmo genético para diferentes topologias na abordagem Pico/Atraso. Pode-se verificar que nas diferentes topologias os resultados finais foram menores que 0,12. Observa-se que nas topologias de 50, 87 e 90 neurônios na camada oculta com apenas cerca de 10 épocas de treinamento o EQM reduz consideravelmente, enquanto, na abordagem de 60 neurônios na camada oculta o EQM tende a diminuir consideravelmente com 40 épocas de treinamento. Os EQMs da base de treinamento convergem para um certo valor.

A Tabela 10 mostra os EQMs para cada topologia e seu respectivo tempo de treinamento. Os dados apresentados comprovam a análise dos gráficos da Figura 27, onde a topologia com 90 neurônios na camada oculta apresenta o EQM mais baixo dentre as topologias. A medida que aumenta-se o número de neurônios na camada oculta, maior é o tempo de treinamento da MLP com o algoritmo genético, que mantém uma média de 6 minutos.

A Tabela 11 apresenta as taxas de acerto, os EQMs e os respectivos tempos, para a fase de teste das diferentes topologias da MLP com o algoritmo genético. Todas as topologias tiveram uma taxa de acerto superior à 83%. A MLP com 90 neurônios na camada oculta teve menor EQM e maior taxa de acerto, se destacando das demais topologias.

Figura 27 – Algoritmo Genético: EQM dos dados de treinamento das diferentes topologias para a abordagem Pico/Atraso



Fonte: Resultados da pesquisa

Tabela 11 – Algoritmo Genético: Resultados do teste das topologias para a abordagem Pico/Atraso

Topologia (neurônios camada oculta)	Teste	
	Taxa de acerto (%)	EQM
50	<b>83.3</b>	0.1254
60	84.4	0.1165
87	85.7	0.1104
90	<b>87.1</b>	0.1081

Fonte: Resultados da pesquisa

A Figura 28 apresenta a Matriz de Confusão para a melhor topologia da abordagem Pico/Atraso. Comprovando os resultados da Tabela 11, observa-se que a topologia de 90 neurônios na camada oculta, apresenta apenas 12,9% de padrões classificados incorretamente.

Tabela 10 – Algoritmo Genético: Resultados do treinamento das topologias para a abordagem Pico/Atraso

Topologia (neurônios camada oculta)	EQM		Tempo de Treinamento (ms)
	Treinamento	Validação	
50	0.1195	0.1945	324833
60	0.1128	0.1847	365401
87	0.1139	0.1743	391667
90	0.1002	0.1773	405277

Fonte: Resultados da pesquisa

Figura 28 – Algoritmo Genético: Matriz de Confusão de teste do melhor caso para a abordagem Pico/Atraso

Output Class	1	26 24.2%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	28 25.8%	4 3.2%	88.9% 11.1%
	3	0 0.0%	11 9.7%	41 37.1%	79.3% 20.7%
		100% 0.0%	72.7% 27.3%	92.0% 8.0%	87.1% 12.9%
		1	2	3	
		Target Class			

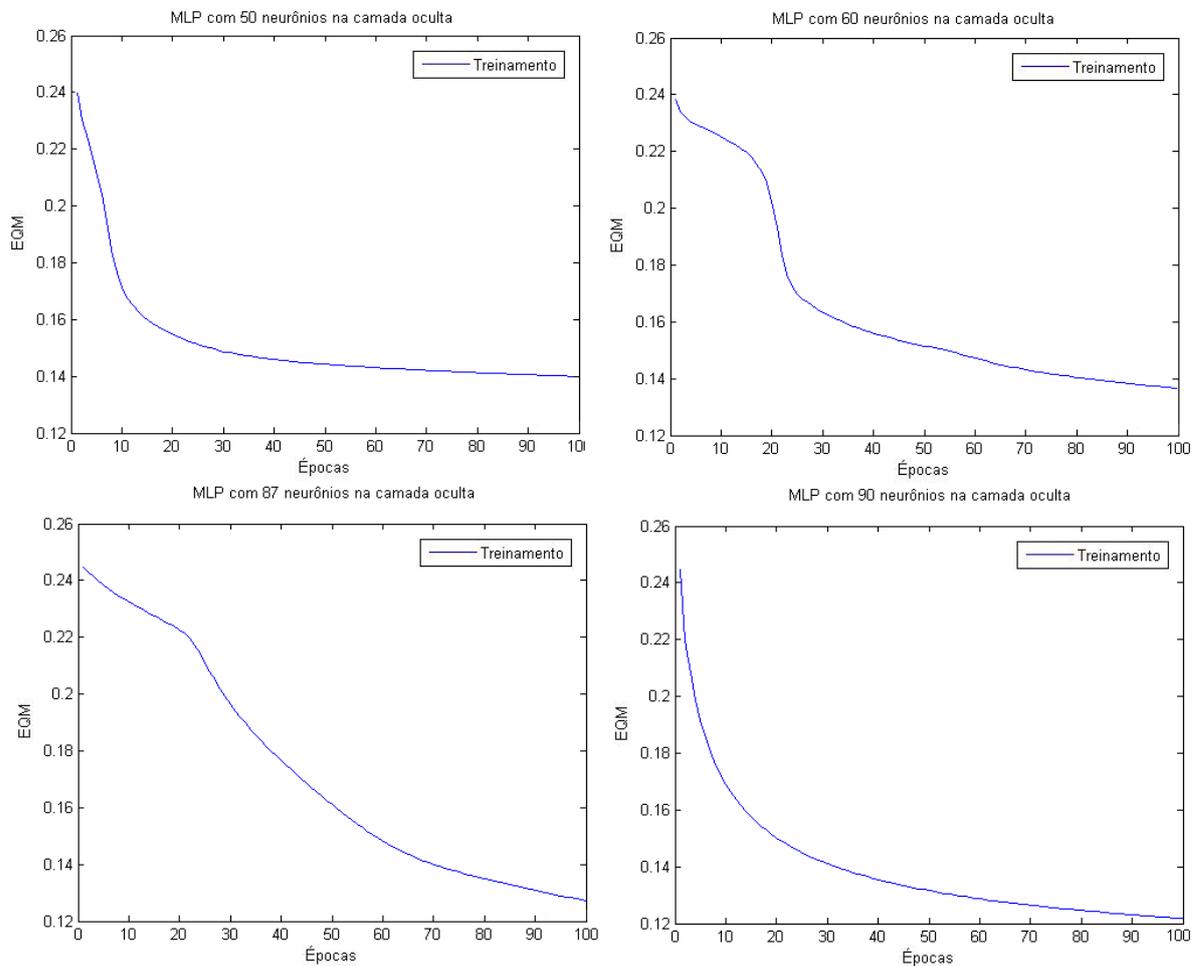
Fonte: Resultados da pesquisa

### 5.1.2.2 Treinamento com Algoritmo Backpropagation

A Figura 29 mostra o EQM durante o treinamento da MLP com o *Backpropagation* para diferentes topologias na abordagem Pico/Atraso. Pode-se verificar que nas diferentes topologias os resultados finais foram menores que 0,14.

A Tabela 12 mostra os EQMs para cada topologia e seu respectivo tempo de treinamento. Os dados apresentados comprovam a análise dos gráficos da Figura 29, onde a topologia com 90 neurônios na camada oculta apresenta o EQM mais baixo dentre as topologias.

**Figura 29 – Backpropagation: EQM dos dados de treinamento das diferentes topologias para a abordagem Pico/Atraso**



Fonte: Resultados da pesquisa

**Tabela 12 – Backpropagation: Resultados do treinamento das topologias para a abordagem Pico/Atraso**

Topologia (neurônios na camada oculta)	EQM		Tempo de Treinamento (ms)
	Treinamento	Validação	
50	0.1402	0.1635	5643
60	0.1473	0.1341	5461
87	0.1297	0.1194	6754
90	0.1218	0.1463	6912

Fonte: Resultados da pesquisa

A Tabela 13 apresenta as taxas de acerto na fase de teste. Todas as topologias tiveram uma taxa de acerto superior à 92%. A MLP com 90 neurônios na camada oculta teve menor EQM e maior taxa de acerto, se destacando das demais topologias.

Tabela 13 – Backpropagation: Resultados do teste das topologias para a abordagem Pico/Atraso

Topologia (neurônios camada oculta)	Teste	
	Taxa de acerto (%)	EQM
50	<b>92.2</b>	0.1524
60	92.9	0.1365
87	93.5	0.1214
90	<b>94.4</b>	0.1202

Fonte: Resultados da pesquisa

A Figura 30 apresenta a Matriz de Confusão para a melhor topologia da abordagem Pico/Atraso. Comprovando os resultados da Tabela 13, observa-se que a topologia de 90 neurônios na camada oculta, apresenta apenas 5,6% de padrões treinados incorretamente.

Figura 30 – Backpropagation: Matriz de Confusão de teste do melhor caso para a abordagem Pico/Atraso

Output Class	1	29 26.7%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	35 31.1%	1 1.1%	96.6% 3.4%
	3	0 0.0%	5 4.4%	40 36.7%	89.2% 10.8%
		100% 0.0%	87.5% 12.5%	97.1% 2.9%	<b>94.4%</b> <b>5.6%</b>
		1	2	3	
		Target Class			

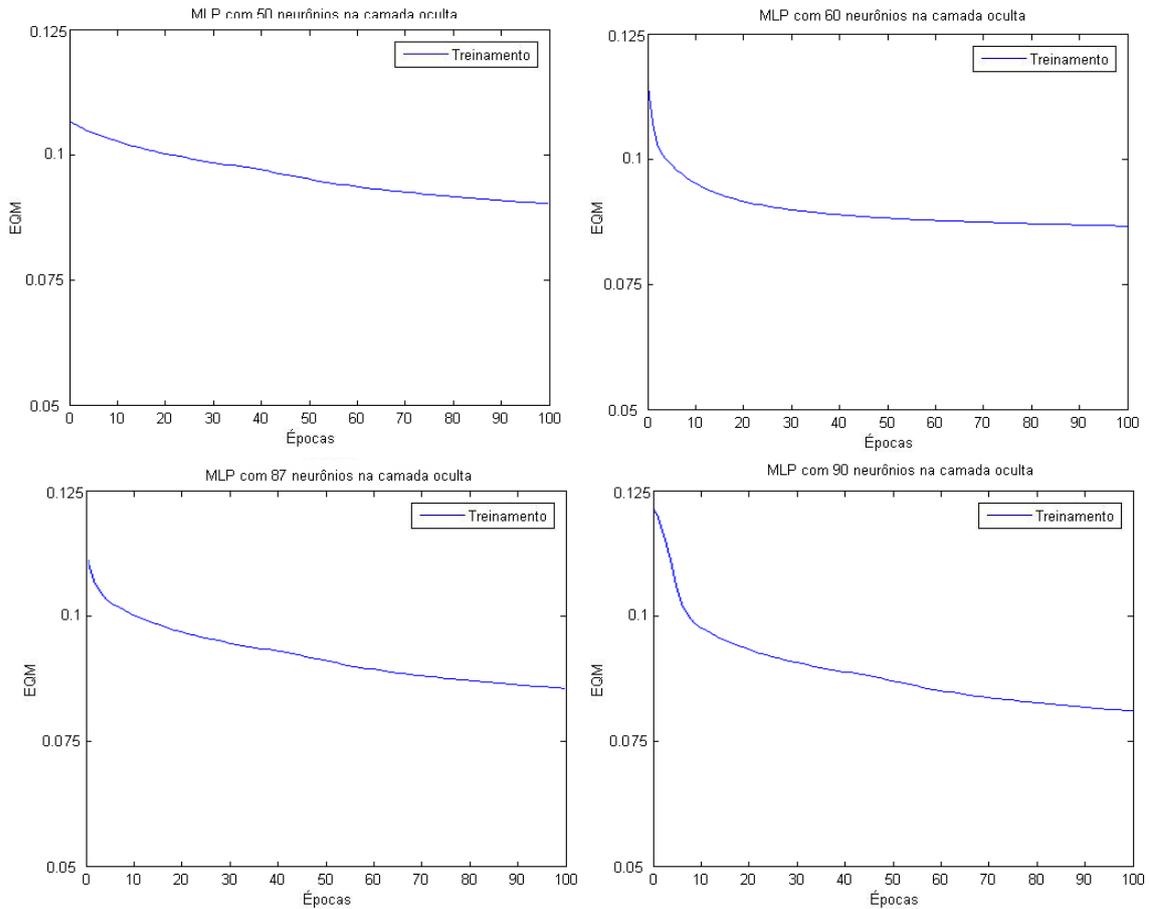
Fonte: Resultados da pesquisa

### 5.1.2.3 Treinamento com Algoritmo Levenberg-Marquardt

A Figura 31 mostra os EQMs durante o treinamento da MLP com o *Levenberg-Marquardt* para diferentes topologias na abordagem Pico/Atraso. Pode-se verificar que nas diferentes topologias os resultados finais foram menores que 0,08.

A Tabela 14 mostra os EQMs para cada topologia e seu respectivo tempo de treinamento. Os dados apresentados comprovam a análise dos gráficos da Figura 31, onde a

Figura 31 – *Levenberg-Marquardt*: EQM dos dados de treinamento das diferentes topologias para a abordagem Pico/Atraso



Fonte: Resultados da pesquisa

topologia com 90 neurônios na camada oculta apresenta o EQM menor dentre as topologias.

Tabela 14 – *Levenberg-Marquardt*: Resultados do treinamento das topologias para a abordagem Pico/Atraso

Topologia (neurônios camada oculta)	EQM		Tempo de Treinamento (ms)
	Treinamento	Validação	
50	0.0886	0.1184	6574
60	0.0837	0.1068	6817
87	0.0835	0.1059	7125
90	0.0792	0.1035	7248

Fonte: Resultados da pesquisa

A Tabela 15 apresenta as taxas de erro para a fase de teste das diferentes topologias da MLP. Todas as topologias tiveram uma taxa de acerto superior à 95%. A MLP com 90

neurônios na camada oculta obteve menor EQM.

**Tabela 15 – *Levenberg-Marquardt*: Resultados do teste das topologias para a abordagem Pico/Atraso**

Topologia (neurônios camada oculta)	Teste	
	Taxa de acerto (%)	EQM
50	<b>95.3</b>	0.0864
60	95.5	0.0828
87	95.9	0.0711
90	<b>96.0</b>	0.0693

Fonte: Resultados da pesquisa

A Figura 32 apresenta a Matriz de Confusão, que resume os resultados de teste, para a melhor topologia. Comprovando os resultados da Tabela 15, observa-se que a topologia de 90 neurônios na camada oculta, apresenta apenas 4% de padrões treinados incorretamente.

**Figura 32 – *Levenberg-Marquardt*: Matriz de Confusão de teste do melhor caso para a abordagem Pico/Atraso**

Output Class	1	<b>37</b> 33.3%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>100%</b> 0.0%
	2	<b>0</b> 0.0%	<b>34</b> 30.7%	<b>1</b> 1.3%	<b>95.8%</b> 4.2%
	3	<b>0</b> 0.0%	<b>3</b> 2.7%	<b>35</b> 32.0%	<b>92.3%</b> 7.7%
		<b>100%</b> 0.0%	<b>92.0%</b> 8.0%	<b>96.0%</b> 4.0%	<b>96.0%</b> 4.0%
		1	2	3	
		<b>Target Class</b>			

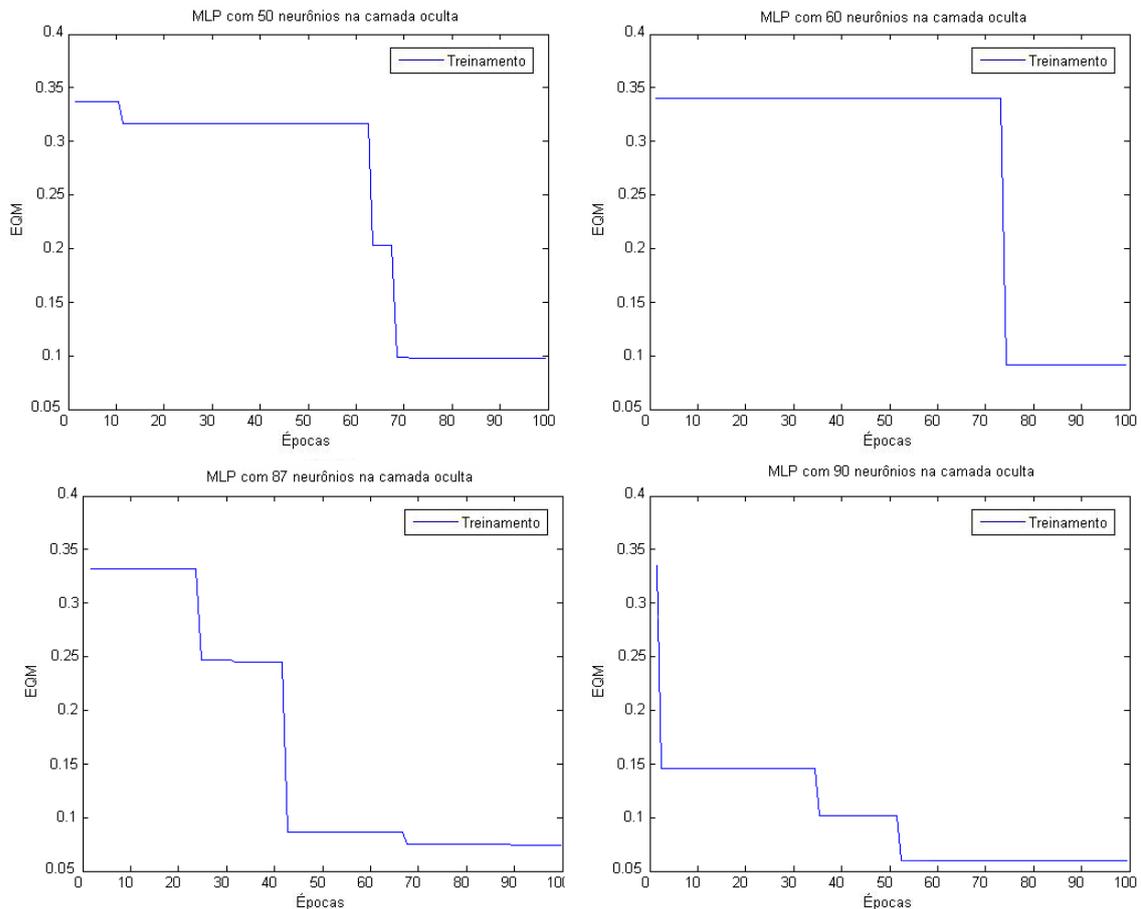
Fonte: Resultados da pesquisa

#### 5.1.2.4 *Treinamento com Algoritmo Híbrido*

A Figura 33 mostra o EQM durante o treinamento da MLP com o algoritmo híbrido para diferentes topologias na abordagem Pico/Atraso. Pode-se verificar que nas diferentes

topologias os resultados finais foram menores que 0,1. Nas quatro abordagens os EQMs da base de treinamento converge.

**Figura 33 – Híbrido: EQM dos dados de treinamento das diferentes topologias para a abordagem Pico/Atraso**



**Fonte: Resultados da pesquisa**

A Tabela 16 mostra os EQMs para cada topologia e seu respectivo tempo de treinamento. Os dados apresentados comprovam a análise dos gráficos da Figura 33, onde a topologia com 90 neurônios na camada oculta apresenta o EQM menor.

A Tabela 17 apresenta as taxas de acerto para a fase de teste das diferentes topologias da MLP com o algoritmo híbrido. Todas as topologias tiveram uma taxa de acerto superior à 96%. A MLP com 90 neurônios na camada oculta teve menor EQM e maior taxa de acerto.

A Figura 34 apresenta a Matriz de Confusão para a melhor topologia da abordagem Pico/Atraso. Comprovando os resultados da Tabela 17, observa-se que a topologia de 90 neurônios na camada oculta, apresenta apenas 1.6% de padrões treinados incorretamente.

Tabela 16 – Híbrido: Resultados do treinamento das topologias para a abordagem Pico/Atraso

Topologia (neurônios camada oculta)	EQM		Tempo de Treinamento (ms)
	Treinamento	Validação	
50	0.0983	0.1120	360038
60	0.0876	0.1051	374145
87	0.0701	0.1024	391453
90	0.0597	0.0972	396431

Fonte: Resultados da pesquisa

Tabela 17 – Híbrido: Resultados do teste das topologias para a abordagem Pico/Atraso

Topologia (neurônios camada oculta)	Teste	
	Taxa de acerto (%)	EQM
50	<b>96.0</b>	0.0892
60	96.8	0.0870
87	97.8	0.0694
90	<b>98.4</b>	0.0521

Fonte: Resultados da pesquisa

Figura 34 – Híbrido: Matriz de Confusão de teste do melhor caso para a abordagem Pico/Atraso

Output Class	1	<b>38</b> 34.8%	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>100%</b> 0.0%
	2	<b>0</b> 0.0%	<b>48</b> 43.5%	<b>5</b> 4.3%	<b>90.9%</b> 9.1%
	3	<b>0</b> 0.0%	<b>0</b> 0.0%	<b>19</b> 17.4%	<b>100%</b> 0.0%
		<b>100%</b> 0.0%	<b>100%</b> 0.0%	<b>80.0%</b> 20.0%	<b>95.7%</b> <b>4.3%</b>
	1	2	3	Target Class	

Fonte: Resultados da pesquisa

## 5.2 Classificação via Rede *Time-Delay*

Para os experimentos utilizando Rede Neural *Time-Delay* na classificação dos padrões de Imagética Motora do sinal EEG, foram utilizados um total de 320 amostras para treinamento, 110 amostras para validação e 110 amostras para teste.

A camada de entrada possui o dobro do número de canais da base de dados, pelo fato da utilização do atraso no tempo (*delay* de  $t-1$ ), para cada uma das curvas de entrada. Este atraso é formado pelo valor atual da amplitude do sinal e por um valor temporalmente anterior a este, de cada um dos 22 canais, totalizando 44 entradas. Foi utilizada a mesma codificação, topologia, função de ativação e algoritmo de aprendizado adotados na rede MLP em estudo. Da mesma forma, foram realizadas trinta 100 épocas de treinamento. Sendo um total de 44 entradas, as topologias de neurônios na camada oculta foram as mesmas utilizadas na abordagem Pico/Atraso.

A Figura 35 mostra os EQMs durante o treinamento da TDNN para diferentes topologias. Pode-se verificar que nas diferentes topologias os resultados finais foram menores que 0.03. Nas quatro abordagens os EQMs da base de treinamento tendem a estabilizar.

A Tabela 18 mostra os EQMs para cada topologia e seu respectivo tempo de treinamento. Os dados apresentados comprovam a análise dos gráficos da Figura 35, onde a topologia com 90 neurônios na camada oculta apresenta o EQM menor dentre as topologias. A medida que aumenta-se o número de neurônios na camada oculta, maior é o tempo de treinamento da TDNN, que mantém uma média de 21 segundos.

**Tabela 18 – Rede *Time-Delay*: Resultados do treinamento das topologias**

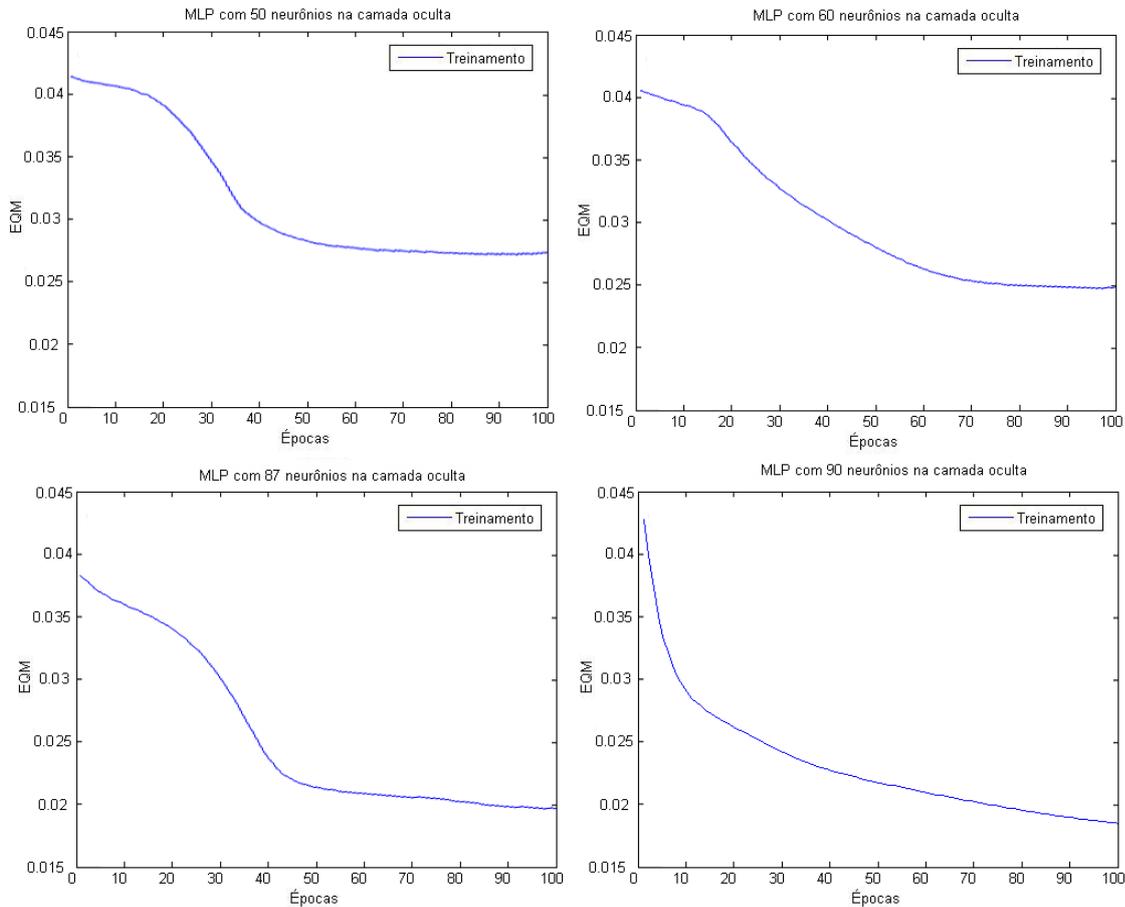
Topologia (neurônios camada oculta)	EQM		Tempo de Treinamento (ms)
	Treinamento	Validação	
50	0.0250	0.0458	20875
60	0.0225	0.0411	21632
87	0.0199	0.0403	22033
90	0.0182	0.0395	22001

Fonte: Resultados da pesquisa

A Tabela 19 apresenta as taxas de acerto, os EQMs e os respectivos tempos, para a fase de teste das diferentes topologias da TDNN. Todas as topologias tiveram uma taxa de acerto superior à 97%. A TDNN com 90 neurônios na camada oculta teve menor EQM e maior taxa de acerto.

A Figura 36 apresenta a Matriz de Confusão para a melhor topologia, resumindo os resultados de teste. Comprovando os resultados da Tabela 19, observa-se que a topologia de 90 neurônios na camada oculta, apresenta apenas 0.7% de padrões treinados incorretamente.

Figura 35 – Rede *Time-Delay*: EQM dos dados de treinamento das diferentes topologias



Fonte: Resultados da pesquisa

Tabela 19 – Rede *Time-Delay*: Resultados do teste das topologias

Topologia (neurônios camada oculta)	Teste	
	Taxa de acerto (%)	EQM
50	<b>97.2</b>	0.0282
60	98.6	0.0241
87	99.0	0.0204
90	<b>99.3</b>	0.0197

Fonte: Resultados da pesquisa

### 5.3 Classificações via Rede Multilayer Perceptron Evolutiva

Para os experimentos utilizando Sistema Conexionista Evolutivo na classificação dos padrões de Imagética Motora do sinal EEG, foram utilizados um total de 378 amostras para o treinamento (70% da base) e 162 amostras para teste (30% da base). A eMLP foi

Figura 36 – Rede *Time-Delay*: Matriz de Confusão de teste do melhor caso

Output Class	1	36 33.3%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	37 32.7%	0 0.0%	100% 0.0%
	3	0 0.0%	1 0.7%	36 33.3%	98.0% 2.0%
		100% 0.0%	98.0% 2.0%	100% 0.0%	99.3% 0.7%
		1	2	3	
		Target Class			

Fonte: Resultados da pesquisa

configurada com os seguintes parâmetros:

- $A_{thr}$  (Threshold de Agregação): 0,3
- $E_{thr}$  (Threshold de Erro): 0,2
- $S_{thr}$  (Threshold de Ativação): 0,8
- $eta_1$  (Taxa de Treinamento 1): 0,8
- $eta_2$  (Taxa de Treinamento 2): 0,8

Os parâmetros foram obtidos por tentativa e erro a partir de uma série de simulações, ao final obtendo-se melhores resultados com os valores apresentados. Inicialmente verifica-se que ambas abordagens adotadas neste estudo são funcionais e apresentam resultados satisfatórios quando treinadas em um ECoS, porém a abordagem RMS possui média de padrões classificados corretamente igual a 93,88% e tempo de execução de 2476 ms, superiores a média 89,92% da abordagem Pico/Atraso e tempo de execução de 4783 ms.

O algoritmo foi executado por 10 vezes, fornecendo os vetores de pesos de entrada e de saída do treinamento anterior. Para análise da eficiência, observa-se a média de acerto obtida para cada abordagem. Observa-se nas Tabelas 20 e 21, que os valores não são crescentes, logo uma única época de treinamento é suficiente para comparar o eMLP com os demais modelos.

Na Figura 37 observa-se que para os 162 exemplos utilizados na base de teste da abordagem RMS, para o melhor caso, temos no geral 96,7% das classificações corretas e 3,3% classificações incorretas; no pior caso, 88% das classificações estão corretas e 12%

**Tabela 20 – Classificação de Padrões dos dados de teste para a abordagem RMS**

<b>Número de Execuções</b>	<b>Padrões Classificados Corretamente (%)</b>
1	95,6
2	<b>96,7</b>
3	92,7
4	95,6
5	93,1
6	94,2
7	<b>88,0</b>
8	93,1
9	<b>96,7</b>
10	93,1
<b>Média</b>	<b>93,88</b>

**Fonte: Resultados da pesquisa**

incorretas. Nota-se que ocorre uma confusão entre as classes 2 e 3, ou seja, possivelmente a fronteira de separação da classe 1 para as demais é linear. As demais classificações são observadas para cada classe como segue:

1. Primeira Classe (movimento das mãos): 49 exemplos são corretamente classificados como primeira classe o que corresponde a 30% de todos os exemplos da base de teste no melhor caso. Já no pior caso, 71 exemplos são corretamente classificados o que corresponde a 44% de todos os exemplos.
2. Segunda Classe (movimento dos pés): 49 exemplos estão corretamente classificados como segunda classe, correspondendo a 30% de todos os exemplos da base de teste no melhor caso. Já no pior caso, 26 exemplos são corretamente classificados o que corresponde a 16% de todos os exemplos e 20 exemplos, ou seja 12% da base, são classificados incorretamente.
3. Terceira Classe (movimento da língua): 59 exemplos estão corretamente classificados como terceira classe, correspondendo a 36,7% da base de teste no melhor caso; porém 5 exemplos, ou seja 3,3% foram classificados incorretamente. Já no pior caso, 45 exemplos são corretamente classificados o que corresponde a 28% de todos os exemplos.

Tabela 21 – Classificação de Padrões dos dados de teste para a abordagem Pico/Atraso

Número de Execuções	Padrões Classificados Corretamente (%)
1	93,5
2	87,5
3	91,0
4	93,2
5	<b>80,0</b>
6	88,7
7	88,8
8	<b>95,6</b>
9	91,0
10	89,9
<b>Média</b>	<b>89,92</b>

Fonte: Resultados da pesquisa

Figura 37 – Matriz de Confusão Abordagem RMS usando eMLP



Fonte: Resultados da pesquisa

Na Figura 38 observa-se que para os 162 exemplos utilizados na base de teste da abordagem Pico/Atraso, para o melhor caso, temos no geral 95,6% das classificações corretas e 4,4% classificações incorretas; no pior caso, 80% das classificações estão corretas e 20% incorretas. As demais classificações são observadas para cada classe como segue:

1. Primeira Classe (movimento das mãos): 43 exemplos são corretamente classificados como primeira classe o que corresponde a 26,7% de todos os exemplos da base de teste no melhor caso. Já no pior caso, 46 exemplos são corretamente classificados o que corresponde a 28% de todos os exemplos.
2. Segunda Classe (movimento dos pés): 52 exemplos estão corretamente classificados como segunda classe, correspondendo a 32,2% de todos os exemplos da base de teste no melhor caso; porém 5 exemplos, ou seja 3,3% foram classificados incorretamente. Já no pior caso, 26 exemplos são corretamente classificados o que corresponde a 16% de todos os exemplos e 32 exemplos, ou seja 20% da base, são classificados incorretamente.
3. Terceira Classe (movimento da língua): 60 exemplos estão corretamente classificados como terceira classe, correspondendo a 36,7% da base de teste no melhor caso, porém 2 exemplos, ou seja 1,1% foram classificados incorretamente. Já no pior caso, 58 exemplos são corretamente classificados o que corresponde a 36% de todos os exemplos.

Como a eMLP tende a ajustar sua topologia conforme os dados de entrada, verifica-se que a abordagem RMS é mais apropriada comparada a Pico/Atraso, pois a rede atingiu o número de 6 neurônios na camada evolutiva, o que se justifica pela abordagem facilitada pela quantidade de entradas fornecidas.

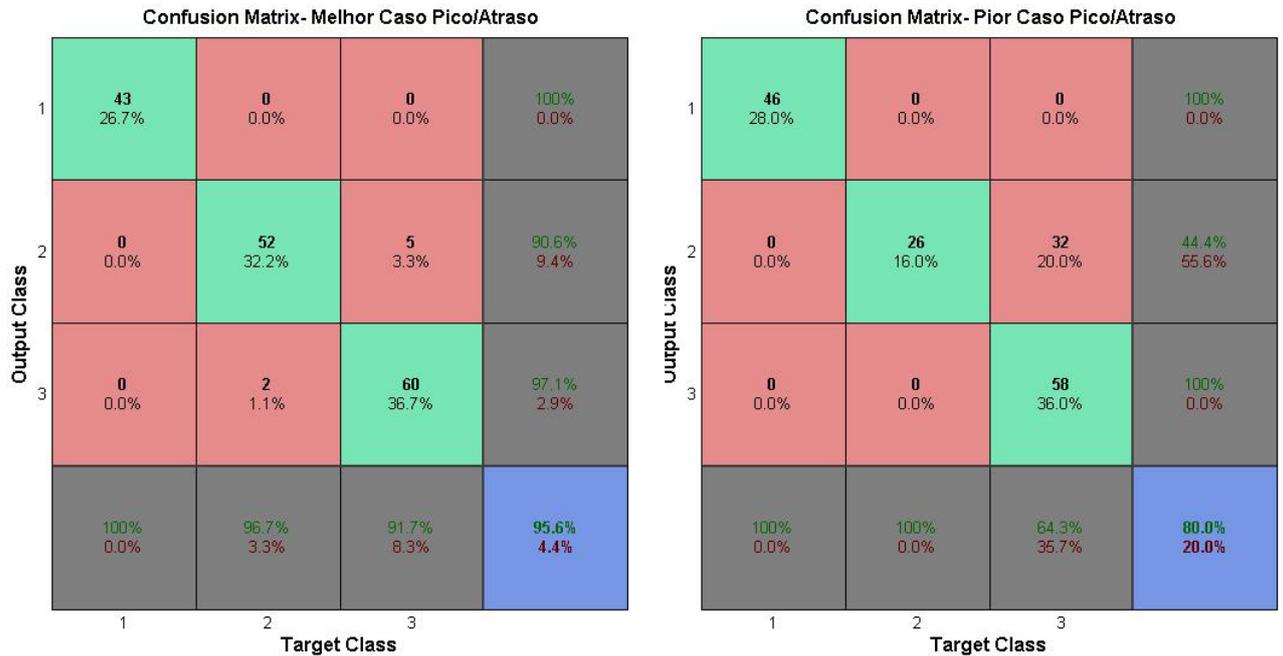
A agregação de neurônios colabora para que a RNA não cresça demasiadamente e sobreajuste aos dados. A agregação foi ajustada para ser executada na 350<sup>a</sup> iteração de cada etapa de treinamento, onde ela começa a agregar neurônios semelhantes.

A Figura 39 apresenta a quantidade de neurônios na camada oculta por iteração correspondente ao melhor caso de classificação no treinamento conforme analisado nas Tabelas 20 e 21, observa-se a tentativa do sistema evolutivo de adequar sua estrutura conforme os dados apresentados.

#### 5.4 Análise Geral dos Resultados

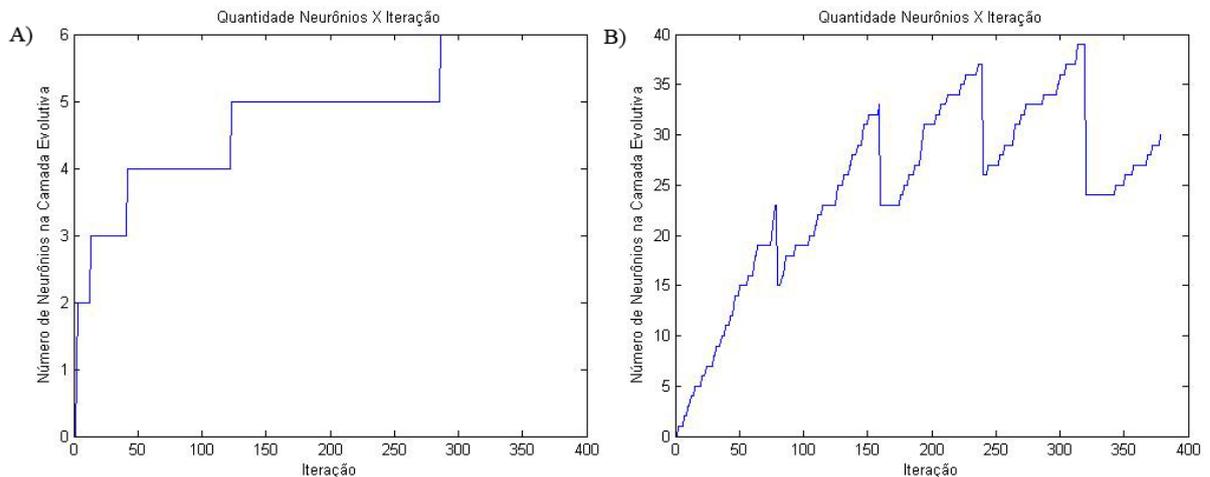
Uma síntese dos melhores resultados obtidos neste estudo é apresentada na Tabela 22. Os melhores resultados foram encontrados nas topologias com maior número de neurônios na camada oculta: (i) abordagem RMS com 45 neurônios na camada oculta e (ii) abordagem Pico/Atraso com 90 neurônios na camada oculta. Observa-se que a maior taxa de acerto e o menor EQM na fase de teste são obtidos pela Rede *Time-Delay* (TDNN),

Figura 38 – Matriz de Confusão Abordagem Pico/Atraso usando eMLP



Fonte: Resultados da pesquisa

Figura 39 – Relação da Quantidade de Neurônios X Iterações: A) Abordagem RMS B) Abordagem Pico/Atraso



Fonte: Resultados da pesquisa

com 99,3% de padrões classificados corretamente em sua abordagem própria, que utiliza série temporal.

Nota-se que em todos os casos da MLP, a abordagem Pico/Atraso, que apresenta um maior número de entradas, obteve as maiores taxas de acerto. Já a eMLP foi a única em que a abordagem RMS, com um número menor de entradas, obteve melhor desempenho (96.7%), o que pode ser justificado pelo fato de que rede tende a se tornar mais complexa

**Tabela 22 – Resultados nos melhores casos por método**

Método	Abordagem	EQM	Taxa de acerto
MLP + Algoritmo Genético	RMS	0.1851	79.0%
	Pico/Atraso	0.1081	87.1%
MLP + Backpropagation	RMS	0.1205	90.4%
	Pico/Atraso	0.1202	94.4%
MLP + Levenberg Marquardt	RMS	0.0829	95.6%
	Pico/Atraso	0.0792	96.0%
MLP + Híbrido	RMS	0.1079	95.7%
	Pico/Atraso	0.0521	98.4%
Rede Neural Time-Delay	Própria	0.0197	<b>99.3%</b>
eMLP	RMS	-	96.7%
	Pico/Atraso	-	95.6%

**Fonte: Resultados da pesquisa**

na medida em que a tarefa de classificação torna-se mais difícil. Esta característica acaba por distingui-la das demais ferramentas em estudo, tendo em vista que estas apresentam topologia fixa e não são capazes de alterá-la conforme a tarefa de classificação proposta. Essa particularidade resulta em um melhor desempenho global, tornando a eMLP mais robusta com relação a alteração dos dados de entrada sem a necessidade de alteração de parâmetros. Porém o sistema proposto neste trabalho, restringe-se a apenas a 3 padrões da imagética motora, então todos os métodos abordados são válidos para a classificação online.

O pior desempenho é encontrado no algoritmo genético, com 87,1% de acerto na abordagem Pico/Atraso, porém o algoritmo híbrido obteve o melhor desempenho para a MLP, com 98.4% de acerto para a abordagem Pico/Atraso. Em outras palavras, é fundamental o uso de um algoritmo de busca local em pós-processamento.

## 6 CONCLUSÃO

Neste trabalho foi realizado um estudo experimental, baseado em redes neurais artificiais, para reconhecimento de padrões em sinais de eletroencefalograma para classificação da imagética motora: movimentos imaginário das mãos, pés e língua, para aplicação em dispositivos e controles externos de interfaces cérebro-máquina. Para tal, encontrar a melhor topologia da rede neural e o algoritmo de aprendizagem a ser utilizado na classificação de padrões pode determinar um melhor desempenho do sistema, a fim de obter a maior taxa de padrões classificados corretamente.

Para o treinamento das RNAs, três abordagens distintas são utilizadas: a série temporal do sinal EEG; a RMS da série temporal, que é uma medida estatística da magnitude de uma quantidade variável, e o Pico e Atraso da série temporal, onde o pico corresponde a amplitude máxima do sinal e o atraso refere-se ao tempo que demorou para atingir este pico. A TDNN utiliza unicamente a série temporal, na MLP a abordagem Pico/Atraso se destaca com as maiores taxas de acerto, já a eMLP tende a se tornar mais complexa na medida em que a tarefa de classificação torna-se mais difícil, sendo assim, a abordagem RMS se destaca.

A TDNN se destacou das demais RNAs em relação ao seu desempenho, obtendo 99.3% de padrões classificados corretamente em seu melhor caso. Em seguida, a MLP com treinamento híbrido, que, neste estudo, combina as vantagens de busca global do Algoritmo Genético com as vantagens de busca local do *Backpropagation*, destaca-se dos demais treinamentos realizados para a MLP, obtendo taxa de acerto de 98.4%. Por fim, a eMLP obtém 96.7% de acerto em seu melhor caso, levando em consideração que ela executa uma única época de treinamento. Pela observação dos aspectos analisados, os modelos estudados alcançam resultados satisfatórios para a classificação da imagética motora em sinais de EEG, considerando a situação e as classes em questão.

A intenção do estudo experimental é de classificação de dados emphonline e restringe-se a 3 padrões da imagética motora (movimentos da mãos, pés e língua); assim, o treinamento com os métodos propostos são eficientes para classificação online. O presente estudo proporciona embasamento teórico e prático para o desenvolvimento de sistemas de reconhecimento de padrões baseados em redes neurais artificiais para classificação de sinais bioelétricos, para que em seguida os mesmos possam ser aplicados em controle de máquina.

### 6.1 Trabalhos futuros

O treinamento híbrido é um dos destaques deste estudo, este método pode combinar duas ou mais técnicas de aprendizagem, para ajuste dos pesos sinápticos de uma rede neural artificial, com o objetivo de unir as vantagens e superar limitações individuais de cada técnica. Este método permite construir sistemas mais robustos, resolver problemas

mais complexos, dentre outras vantagens. Sendo assim, tem-se como sugestão de trabalhos futuros, comparar outros métodos no algoritmo híbrido além dos utilizados neste estudo.

Sugere-se também analisar outras bases de dados a fim de verificar se haverá significancia estatística. Neste trabalho foram utilizadas três abordagens distintas para tratar os dados da base (Série Temporal, RMS e Pico/Atraso), sendo assim é possível extrair outras variáveis, como por exemplo variáveis obtidas a partir de transformada de *Fourier*, wavelets, entre outras; com o objetivo de obter novos resultados.

## REFERÊNCIAS

- AFFENZELLER, M. et al. **Genetic Algorithms and Genetic Programming: Modern Concepts and Practical Applications**. [S.l.]: Hall/CRC, 2009.
- ALVES, F. A. S.; NEUMANN, A. M. M.; GOUVEA, M. M. Bengala inteligente neural baseada em aprendizagem por reforço para deficientes visuais. 2014.
- ANGELOV, P.; ZHOU, X. Evolving fuzzy systems from data streams in real-time. Institute of Electrical and Electronics Engineers (IEEE), sep 2006.
- ARAUJO, A. **Comparação de arquiteturas de redes neurais para sistemas de Reconhecimento de padrões em narizes artificiais**. Dissertação (Mestrado) — Universidade Federal de Pernambuco, 2004.
- BERGER, H. Über das elektrenkephalogramm des menschen. **Deutsche Medizinische Wochenschrift**, Thieme Publishing Group, v. 60, n. 51, p. 1947–1949, dec 1929.
- BERGER, H. On the electroencephalogram of man. **Science**, American Association for the Advancement of Science (AAAS), v. 168, n. 3931, p. 562–563, may 1969.
- BISHOP, C. M. **Neural Networks for Pattern Recognition**. New York, NY, USA: Oxford University Press, Inc., 1995. ISBN 0198538642.
- BOTTI, A. et al. Classificação pseudoonline de tarefas mentais para uma interface cérebro-computador. **X SBAI – Simpósio Brasileiro de Automação Inteligente**, 2011.
- BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. **Time Series Analysis: Forecasting and Control**. 4th. ed. [S.l.: s.n.], 1994.
- BRAGA, A. de P.; CARVALHO, A. P. de; LUDERMIR, T. B. **Redes Neurais Artificiais Teoria e Aplicações**. [S.l.: s.n.], 2000.
- BROCKWELL; J., P.; DAVIS, R. A. **Time series: theory and methods**. [S.l.]: Springer Science & Business Media, 2013.
- BURGES, C. et al. Learning to rank using gradient descent. In: **Proceedings of the 22Nd International Conference on Machine Learning**. New York, NY, USA: ACM, 2005. (ICML '05), p. 89–96. ISBN 1-59593-180-5.
- CALVETE, H. I.; GALE, C.; IRANZO, J. A. An efficient evolutionary algorithm for the ring star problem. **European Journal of Operational Research**, Elsevier BV, v. 231, n. 1, p. 22–33, nov 2013. Disponível em: <<http://dx.doi.org/10.1016/j.ejor.2013.05.013>>.
- COIMBRA, A. J. F. **Análise computadorizada de sinais bioelétricos**. Dissertação (Mestrado) — Universidade Federal de Santa Catarina, 1994.
- DECETY, J.; INGVAR, D. H. Brain structures participating in mental simulation of motor behavior: a neuropsychological interpretation. **Acta Psychologica**, Elsevier BV, v. 73, n. 1, p. 13–34, feb 1990.
- DODONOV, E.; MELLO, R. F. de. Predição por meio de atrasos no tempo: Tdnn for estudo sobre abordagens de extração, classificação e predição de comportamento de processos. **ICMC/USP**, 2008.

FAUSETT, L. **Fundamentals of Neural Networks**. 1. ed. [S.l.]: New Jersey: Printice Hall, 1994.

GALTON, F. **Inquiries into human faculty and its development**. [S.l.]: London: Macmillan, 1883.

GENTILI, R.; PAPAXANTHIS, C.; POZZO, T. Improvement and generalization of arm motor performance through motor imagery practice. **Neuroscience**, Elsevier BV, v. 137, n. 3, p. 761–772, jan 2006.

GOLDBERG, D. E. **Genetic Algorithms in Search, Optimization and Machine Learning**. 1st. ed. Boston, MA, USA: Addison-Wesley Longman Publishing Co., Inc., 1989. ISBN 0201157675.

GOUVEA, M. M. A neural-based gradient optimization in large power systems. **WSEAS Transactions on systems**, v. 11, 2012.

GRAIMANN, B.; ALLISON, B. Brain–computer interfaces: a gentle introduction. 2010. Disponível em: <[http://www.springer.com/cda/content/document/cda\\_downloaddocument/9783642020902-c1.pdf?SGWID=0-0-451015086-p173959822](http://www.springer.com/cda/content/document/cda_downloaddocument/9783642020902-c1.pdf?SGWID=0-0-451015086-p173959822)>.

HAGAN, M. T.; MENHAJ, M. B. Training feedforward networks with the marquardt algorithm. **Trans. Neur. Netw.**, IEEE Press, Piscataway, NJ, USA, v. 5, n. 6, p. 989–993, nov. 1994. ISSN 1045-9227.

HANAKAWA, T.; DIMYAN, M. A.; HALLETT1, M. Motor planning, imagery, and execution in the distributed motor network: A time-course study with functional mri. **Cerebral Cortex**, Oxford University Press (OUP), v. 18, n. 12, p. 2775–2788, mar 2008.

HASSOUN, M. **Fundamentals of Artificial Neural Networks**. [S.l.]: MIT Press, 1995.

HAYKIN, S.; NETWORK, N. **A comprehensive foundation**. 2. ed. [S.l.]: Neural Networks, 2004.

HSU, W.-Y. Fuzzy hopfield neural network clustering for single-trial motor imagery eeg classification. **Expert Syst. Appl.**, v. 39, n. 1, p. 1055–1061, 2012. Disponível em: <<http://dblp.uni-trier.de/db/journals/eswa/eswa39.html#Hsu12b>>.

IVES, M. J. **Fundamentals of EEG technology**. [S.l.: s.n.], 1989.

KASABOV, N. **Ecos: Evolving connectionist systems and the eco learning paradigm**. 1998.

KASABOV, N. **Evolving Connectionist Systems**. 1. ed. [S.l.]: Springer Verlag, 2003.

KOTTAIMALAI, R. Eeg signal classification using principal component analysis with neural network in brain computer interface applications. **IEEE International Conference on Emerging Trends in Computing**, 2013.

LANG, K. J.; WAIBEL, A. H.; HINTON, G. E. A time-delay neural network architecture for isolated word recognition. **Neural Networks**, Elsevier BV, v. 3, n. 1, p. 23–43, jan 1990.

LEHNERTZ, K. **Nonlinear interdependence in intracranial EEG recordings during verbal learning and memory tasks.** [S.l.]: Epilepsia, 1999. v. 40.

LEITE, D. F.; COSTA, P.; GOMIDE, F. Sistema conexionistas evolutivos. **SBAI**, 2009.

LI, M. et al. Recognition method of limb motor imagery EEG signals based on integrated back-propagation neural network. **The Open Biomedical Engineering Journal**, Bentham Science Publishers Ltd., v. 9, n. 1, p. 83–91, mar 2015.

LOTTE, F. et al. A review of classification algorithms for eeg-based brain–computer interfaces. **Journal of Neural Engineering**, v. 4, n. 2, p. R1, 2007. Disponível em: <<http://stacks.iop.org/1741-2552/4/i=2/a=R01>>.

MARILU, G. N. M. Reconhecimento de padrões de eeg durante o movimento e imaginação do movimento das mãos. **XXIV Congresso Brasileiro de Engenharia Biomédica**, 2014.

MCCULLOCH, W.; PITTS, W. A logical calculus of ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, v. 5, p. 115–133, 1943.

MCFARLAND, D. J. Design of a brain computer interface system based on electroencephalogram (eeg). **Behavior Research Methods, Instruments, & Computers**, Springer Nature, v. 29, n. 3, p. 337–345, sep 1995.

MEDEIROS, A. A. et al. Implementação de classificador de tarefas mentais baseado em eeg. In: **Anais do 9 Congresso Brasileiro de Redes Neurais**. Ouro Preto, MG: SBRN, 2009. p. 1–5.

MUNZERTA, J.; LOREYA, B.; ZENTGRAFA, K. Cognitive motor processes: the role of motor imagery in the study of motor representations. **Brain research reviews**, v. 60, n. 2, p. 306–326, 2009.

M.VENTOURAS, E. et al. Sleep spindle detection using artificial neural networks trained with filtered time-domain eeg: a feasibility study. **Computer Methods and Programs in Biomedicine**, Elsevier BV, v. 78, n. 3, p. 191–207, jun 2005.

NAEEM, M. Separability of four-class motor imagery data using independent components analysis. **Journal of Neural Engineering**, IOP Publishing, v. 3, n. 3, p. 208–216, jun 2006.

NARENDRA, K. S. “neural networks for control theory and practice. **Proceedings of the IEEE 84**, p. 1385–1406, 1996.

PENNY, W. et al. Eeg-based communication: a pattern recognition approach. **IEEE Transactions on Rehabilitation Engineering**, Institute of Electrical and Electronics Engineers (IEEE), v. 8, n. 2, p. 214–215, jun 2000.

PFURTSCHELLER, G. et al. Eeg-based discrimination between imagination of right and left hand movement. **Electroencephalography and Clinical Neurophysiology**, Elsevier BV, v. 103, n. 6, p. 642–651, dec 1997.

PRASAD, B. D. C. N.; PESNK, P.; SAGAR, Y. A study on associative neural memories. **International Journal of Advanced Computer Science and Applications**, The Science and Information Organization, v. 1, n. 6, 2010.

SPECKMANN, E.-J.; ELGER, C.; GORJI, A. Introduction to the neurophysiological basis of the eeg and dc potentials. **Electroencephalography: Basic Principles**, 1999.

TEPLAN, M. Fundamentals of eeg measurement. **Measurement science review**, p. 1–11, 2002.

WANG, T.; DENG, J.; HE, B. Classifying eeg-based motor imagery tasks by means of time–frequency synthesized spatial patterns. **Clinical Neurophysiology**, Elsevier BV, v. 115, n. 12, p. 2744–2753, dec 2004.

WOLPAW, J.; WOLPAW, E. W. **Brain-computer interfaces: principles and practice**. [S.l.]: Oxford University Press, 2012.

XU, B.; SONG, A. Pattern recognition of motor imagery EEG using wavelet transform. **Journal of Biomedical Science and Engineering**, Scientific Research Publishing, Inc., v. 01, n. 01, p. 64–67, 2008. Disponível em: <<https://doi.org/10.4236/jbise.2008.11010>>.

ZANGEROLAME, F. M. **Monitoramento Analógico e Digital de sinais elétricos cerebrais**. Dissertação (Mestrado) — Cefet RJ, 2009.

ZHANG, B.-L.; ZHANG, H.; GE, S. S. Face recognition by applying wavelet subband representation and kernel associative memory. **IEEE Transactions on Neural Networks**, Institute of Electrical and Electronics Engineers (IEEE), v. 15, n. 1, p. 166–177, jan 2004.