

Luciana Paro Scarin Freitas

“Discriminação entre Pacientes Normais e
Hemiplégicos Utilizando Plataforma de Força e
Redes Neurais”

Ilha Solteira – SP

Dezembro/2011

Luciana Paro Scarin Freitas

**“Discriminação entre Pacientes Normais e
Hemiplégicos Utilizando Plataforma de Força e
Redes Neurais”**

Orientador: Prof. Dr. Marcelo Carvalho Minhoto Teixeira

Co-orientadora: Profa. Dra. Mara Lúcia Martins Lopes

Dissertação apresentada ao Programa
de Pós Graduação em Engenharia
Elétrica da Faculdade de Engenharia -
UNESP – Campus de Ilha Solteira,
para obtenção do título de Mestre em
Engenharia Elétrica.

Área de Conhecimento: Automação.

Ilha Solteira – SP

Dezembro/2011

FICHA CATALOGRÁFICA

Elaborada pela Seção Técnica de Aquisição e Tratamento da Informação
Serviço Técnico de Biblioteca e Documentação da UNESP - Ilha Solteira.

- F866d Freitas, Luciana Paro Scarin.
Discriminação entre pacientes normais e hemiplégicos utilizando plataforma de força e redes neurais / Luciana Paro Scarin Freitas. -- Ilha Solteira : [s.n.], 2011 83 f. : il.
- Dissertação (mestrado) – Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de Conhecimento: Automação, 2011
- Orientador: Marcelo Carvalho Minhoto Teixeira
Co-orientador: Mara Lúcia Martins Lopes
Inclui bibliografia
1. Rede MLP. 2. Rede neural ARTMAP. 3. Plataforma de força.
4. Região plantar. 5. Hemiplégico.



UNIVERSIDADE ESTADUAL PAULISTA
CAMPUS DE ILHA SOLTEIRA
FACULDADE DE ENGENHARIA DE ILHA SOLTEIRA

CERTIFICADO DE APROVAÇÃO

TÍTULO: Discriminação entre Pacientes Normais e Hemiplégicos Utilizando Plataforma de Força e Redes Neurais

AUTORA: LUCIANA PARO SCARIN FREITAS

ORIENTADOR: Prof. Dr. MARCELO CARVALHO M TEIXEIRA

CO-ORIENTADORA: Profa. Dra. MARA LÚCIA MARTINS LOPES

Aprovada como parte das exigências para obtenção do Título de Mestre em Engenharia Elétrica ,
Área: AUTOMAÇÃO, pela Comissão Examinadora:

Prof. Dr. MARCELO CARVALHO M TEIXEIRA

Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira

Prof. Dr. APARECIDO AUGUSTO DE CARVALHO

Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira

Prof. Dr. MÁRCIO ROBERTO COVACIC

Departamento de Engenharia Elétrica / Universidade Estadual de Londrina

Data da realização: 02 de dezembro de 2011.

Ao meu esposo Ricardo Luiz Barros de Freitas.

À minha filha Lorena Scarin Freitas.

Aos meus pais:

José Antonio Scarin

e

Luiza Izabel Paro Scarin.

Dedico

Aos meus irmãos:

Lucila Paro Scarin Correia

e

Leandro Paro Scarin.

À minha família.

Aos meus amigos.

Ofereço

Aqueles que passam por nós, não vão sós,
não nos deixam sós. Deixam um pouco de si,
levam um pouco de nós. (O Pequeno Príncipe)

AGRADECIMENTOS

Agradeço, primeiramente, a Deus, por sempre me amparar e confortar nos momentos difíceis e, principalmente, por me dar o dom da vida.

Agradeço a todas as pessoas que me incentivaram e me apoiaram durante o mestrado. Primeiramente e principalmente a meu esposo Ricardo Luiz Barros de Freitas, que sempre esteve ao meu lado em todas as horas, que sempre lutou bravamente para me incentivar em minha formação pessoal, acadêmica e profissional e por ter me dado uma linda filha, a Lorena Scarin Freitas que é nossa razão de viver.

A minha filha Lorena Scarin Freitas que é o grande amor da minha vida, pela qual dedico todos os meus dias e meus esforços.

Aos meus pais Luiza Izabel Paro Scarin e José Antonio Scarin que dedicaram suas vidas em prol da minha formação e que sempre estiveram ao meu lado.

Aos meus irmãos Lucila e Leandro amados e fiéis companheiros que sempre me amparam.

Aos cunhados Patrícia e Eduardo e aos meus sobrinhos Arthur e Ana Júlia.

Ao meu orientador, o professor Marcelo Carvalho Minhoto Teixeira por ter me proporcionado a oportunidade de realizar este trabalho, aprimorar os meus conhecimentos e por orientar minhas ações direcionando os meus estudos. A sua esposa Vera pela doçura, compreensão e amizade.

A minha co-orientadora, a professora Mara Lúcia Martins Lopes, que, além de grande amiga, esteve sempre presente me orientando em minhas necessidades até mesmo nos momentos mais delicados de sua vida. A toda a sua família que com muita paciência, amor e carinho acolheram a mim e a minha família. E especialmente ao seu filho Matheus que em muitos momentos me cedeu à atenção de sua mãe.

Aos meus sogros Luiz Carlos e Zoraide que nos apoiam estando presentes em todos os momentos mais difíceis.

Ao professor Aparecido Augusto de Carvalho pela colaboração direta ao meu trabalho, pelo apoio, pela paciência e atenção. A sua esposa Marlene pela amizade.

Ao professor Carlos Roberto Minussi pela atenção, orientação e amparo nos momentos de necessidades.

Aos professores do Departamento de Engenharia Elétrica, Anna Diva Plasencia Lotufo, Edvaldo Assunção, Ricardo Tokio Higuti, Rubén Augusto Romero Lázaro.

Aos meus familiares e amigos que de muitas formas, em muitas ocasiões, deram valiosas contribuições durante a realização deste trabalho.

RESUMO

Neste trabalho descreve-se o desenvolvimento de duas redes neurais que identificam e classificam dados da distribuição do peso corporal na região plantar de pessoas normais e hemiplégicas. Esses dados são experimentais e foram obtidos através da utilização de uma plataforma de força contendo 48 sensores. As arquiteturas utilizadas para esta aplicação foram as redes neurais MLP (Multilayer Perceptron) com o algoritmo retropropagação (backpropagation), e ARTMAP Nebulosa. A escolha de tais arquiteturas se deve ao treinamento (supervisionado) o qual associa de forma direta a distribuição de força plantar com os respectivos pacientes (normais e hemiplégicos). Ambas as arquiteturas, MLP e ARTMAP Nebulosa, conseguiram fazer a discriminação entre quase todas as pessoas normais e hemiplégicos. A rede neural ARTMAP Nebulosa possui a vantagem de efetuar a classificação de forma rápida e eficiente. Esta aplicação é importante nas áreas de Podologia, Posturologia e Podoposturologia, pois propicia ao profissional de saúde uma nova metodologia de diagnóstico.

Palavras-chave – Rede MLP. Rede neural ARTMAP. Plataforma de força. Região plantar. Hemiplégico.

ABSTRACT

This work describes the development of two neural networks that identify and classify data distribution of plantar body weight of normal or hemiplegic individuals. The architectures used for this application were, respectively, MLP neural networks (Multilayer Perceptron) with backpropagation algorithm, and Fuzzy ARTMAP. The choice of such architectures was due to the training (supervised training) which directly associates the distribution of plantar force with the patients (normal or hemiplegic). The input data used for training and diagnosis of the neural networks were obtained from a force plate, with 48 sensors, containing measurements of the weight distribution on the plantar region (right and left) of normal or hemiplegic patients. Both architectures, MLP and Fuzzy ARTMAP, were able to discriminate almost all normal and hemiplegic patients. The Fuzzy ARTMAP neural network was more efficient than MLP neural network in the classification of the patients. This application is important in areas of Podiatry, Posturology and Podoposturology because it can help the health care professionals.

Keywords – MLP Neural network. Fuzzy ARTMAP neural network. Force plate. Plantar region. Hemiplegic.

LISTA DE ILUSTRAÇÕES

Figura 3.1 - Ossos do pé direito, vista dorsal.	30
Figura 3.2 - O triângulo equilátero e seus vértices.	31
Figura 3.3 - Abóbada plantar sustentada por três arcos.	31
Figura 3.4 - Pontos de apoio do pé direito.	32
Figura 3.5 - Vista interna da abóbada plantar do pé direito.	33
Figura 3.6 - Padrão patológico da hemiplegia.	35
Figura 4.1 - Constituintes da célula neuronal.	40
Figura 4.2 - Modelo do neurônio de McCulloch-Pitts.	41
Figura 4.3 - Funções de ativação.	42
Figura 4.4 - Rede neural artificial.	44
Figura 4.5 - Treinamento supervisionado.	46
Figura 4.6 - Treinamento não supervisionado.	47
Figura 4.7 - Rede neural ADALINE.	48
Figura 4.8 - Fluxo de processamento do algoritmo com as fases <i>forward</i> e <i>backward</i>	50
Figura 4.9 - Arquitetura básica de uma rede ARTMAP.	53
Figura 4.10 - Arquitetura básica de uma rede ARTMAP Nebulosa.	56
Figura 5.1 - Foto da Plataforma de Força.	61
Figura 5.2 - Interface do programa de aquisição de dados desenvolvido em LABVIEW.	62
Figura 5.3 - Representação da arquitetura neural MLP utilizada.	64
Figura 5.4 - Fluxograma do treinamento desenvolvido em MATLAB.	68
Figura 5.5 - Fluxograma da classificação desenvolvido em MATLAB.	70

LISTA DE TABELAS

Tabela 5.1 - Parâmetros da rede neural MLP e respectivos valores, utilizados para a fase de treinamento e diagnóstico.....	65
Tabela 5.2 - Especificação dos parâmetros da rede neural.....	66
Tabela 6.1 - Exemplo de dados do pé esquerdo de pessoas hemiplégicas.	72
Tabela 6.2 - Exemplo de dados do pé direito de pessoas hemiplégicas.	73
Tabela 6.3 - Exemplo de dados do pé esquerdo de pessoas normais.	73
Tabela 6.4 - Exemplo de dados do pé direito de pessoas normais.	74
Tabela 6.5 - Classificação da MLP: pessoas normais (0,8) e hemiplégicos (0,9).	75
Tabela 6.6 - Classificação da ARTMAP Nebulosa: pessoas normais (1) e hemiplégicas (0)..	76

SIMBOLOGIA

Símbolo	Descrição	Símbolo	Descrição
w	pesos.	W_a	padrões de entrada.
$f(.)$	função não-linear.	W_b	padrões de saída.
X_k	valores reais ou binários.	W_{ab}	associada ao módulo Inter-ART.
ϖ	peso da ligação.	N_a	número de pares da entrada.
η	taxa de treinamento.	N_b	número de pares da saída.
δ	erro calculado.	M_a	número de componentes dos vetores de entrada.
γf	derivada da função transferência.	M_b	número de componentes dos vetores de saída.
y	saída do neurônio.	α	parâmetro de escolha.
k	número de iterações.	β	parâmetro taxa de treinamento.
J	categoria ativa ARTa.	$\rho_a, \rho_b, \rho_{ab}$	parâmetros de vigilância.
K	categoria ativa ARTb.	$\wedge$	operador nebuloso.

SIGLAS

ART	Redes Neurais Artificiais.
ARTa	Sub-redes.
ARTb	Sub-redes.
ARTab	Inter-ART.
AVC	Acidente Vascular Cerebral.
MLP	<i>Multilayer Perceptron.</i>
RNA	Redes Neurais Artificiais.
SOM	<i>Self Organizing Map.</i>

SUMÁRIO

1	INTRODUÇÃO GERAL	18
1.1	Introdução	18
1.2	Objetivo	21
1.3	Justificativa	21
1.4	Organização dos Capítulos	22
2	ESTADO DA ARTE	25
2.1	Definição do Problema	25
2.2	Análise das Principais Referências Bibliográficas	25
3	BIOMECÂNICA HUMANA	29
3.1	Estrutura do Membro Inferior	29
3.1.1	Ossos do Membro Inferior	29
3.1.2	A abóboda plantar	30
3.2	Acidente Vascular Cerebral (AVC) ou Acidente Vascular Encefálico (AVE)	33
3.2.1	Hemiplegia	34
3.2.2	Padrão Postural	34
3.2.3	Algumas Alterações Morfofisiológicas após um AVC	35
3.3	Baropodômetro	36
3.4	Baropodometria	36
4	REDES NEURAIS	39
4.1	Redes Neurais	39
4.2	Neurônio Biológico	40
4.3	Neurônio Artificial	41
4.4	Estrutura das Redes Neurais Artificiais	42
4.5	Treinamento ou Aprendizado	45
4.5.1	Treinamento Supervisionado	45
4.5.2	Treinamento Não Supervisionado	46
4.6	Modelos de Redes Neurais	47
4.6.1	Modelo ADALINE	47
4.6.2	Modelo MADALINE	48
4.6.3	Redes MLP (<i>Multilayer Perceptron</i>)	48

4.6.4 Rede ART (<i>Adaptative Resonance Theory</i>).....	51
4.6.5 Rede ARTMAP	52
4.6.6 Rede ARTMAP Nebulosa (<i>Fuzzy</i>)	54
5 METODOLOGIA	61
5.1 Introdução	61
5.2 Utilização da Rede MLP	63
5.3 Utilização da Rede ARTMAP Nebulosa	65
5.3.1 Treinamento.....	66
5.3.2 Classificação.....	69
6 RESULTADOS E DISCUSSÃO	72
6.1 Medições	72
6.2 Rede Neural MLP	74
6.3 Rede Neural ARTMAP Nebulosa	75
6.4 Discussão	76
7 CONCLUSÃO	80
REFERÊNCIAS	81

CAPÍTULO 1

1 INTRODUÇÃO GERAL

Neste capítulo é apresentada uma revisão bibliográfica sobre o sistema nervoso, neurônios artificiais, redes neurais artificiais, medições de força na região plantar dos pés, conceitos básicos sobre hemiplegia, os objetivos e a justificativa para a execução deste trabalho.

1.1 Introdução

Todo ser humano possui um Sistema Nervoso que, entre outras funções, é responsável pelo ajuste do organismo ao ambiente. Ele é capaz de identificar as necessidades internas do corpo e produzir respostas que se adaptam a elas. O Sistema Nervoso controla as funções orgânicas do corpo e a interação deste com o ambiente. É composto pelo sistema nervoso central que é responsável por processar informações, e pelo sistema nervoso periférico que é responsável pela condução dessas informações pelo corpo.

As células nervosas, denominadas neurônios, são responsáveis pelo recebimento e transporte de informações, por meio de alterações elétricas, os chamados impulsos elétricos. No cérebro humano, os neurônios captam os sinais através de inúmeras estruturas finas chamadas dendritos (terminais de entrada) e enviam atividades elétricas através de um longo e fino suporte conhecido como axônio (terminal de saída) (MENDES; CARVALHO, 1997).

O neurônio artificial é baseado no neurônio biológico, sendo assim, uma rede neural artificial é um grupo de neurônios artificiais interconectados interagindo de uma forma combinada, ou seja, um estímulo é aplicado na entrada da rede, e após algumas operações satisfatórias, encontra-se uma saída desejada.

Haykin (2001) define Redes Neurais Artificiais (RNA) como “processadores paralelamente distribuídos, constituídos de unidades de processamento simples, que têm uma propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso” (HAYKIN, 2001). “Elas se assemelham ao cérebro humano em dois aspectos: a) o conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizado e forças de conexão entre neurônios, conhecidas como pesos sinápticos; b) são utilizadas para armazenar o conhecimento adquirido” (HAYKIN, 2001).

Segundo Lima e Labidi (1999), as Redes Neurais Artificiais podem ser definidas como conjuntos bem estruturados de unidades de processamento, interligadas por canais de

comunicação, cada qual tendo um determinado peso correspondente a um valor numérico. Elas consistem de unidades de processamento (neurônios) conectadas entre si formando uma disposição estrutural de camadas e conexões entre as camadas.

As Redes Neurais atualmente são aplicadas em diversas áreas de pesquisa para resolver problemas da vida real. Elas são muito utilizadas na Engenharia, Biologia, Medicina, entre outras. Neste trabalho tem-se o objetivo de enfatizar o estudo das redes neurais artificiais em Aplicações Biomédicas.

O corpo humano, como todos os corpos materiais, é submetido às leis da gravidade. Para que esteja em equilíbrio estável, seu centro de gravidade deve estar no centro de sua base de sustentação. Qualquer desequilíbrio, seja ele segmentar ou articular, deverá ser compensado no mesmo plano por um desequilíbrio igual, mas em sentido oposto. De acordo com as particularidades anatômicas, a compensação poderá ocorrer sobre um ou vários segmentos, sobre uma ou várias articulações, em um ou vários planos. (FREITAS, 2008).

O pé é um órgão da base de sustentação que determina a estática do corpo devido à sua colocação no solo. O homem se estabiliza no seu ambiente por uma integração de informações que procedem dos receptores visuais (olhos), vestibular (ouvido) e plantar (pés). É suficiente alterar uma ou mais dessas informações para modificar sua estabilização (ESTREMOTE, 2010).

As alterações no apoio plantar são geralmente interpretadas pelos pés, que, em um contexto geral, são divididos em três regiões distintas: região do calcâneo, que representa a pressão exercida pelo calcâneo; região do meio do pé, que representa os apoios exercidos, geralmente, pela parte externa do arco dos pés; e região dos dedos, que representa o apoio dos dedos.

A adaptação do pé ao membro inferior e à cintura pélvica é uma fisiologia fundamental para a compreensão dos problemas estáticos. Um movimento pélvico ou uma má posição pélvica acarreta uma adaptação do pé. Uma deformação do pé é sempre responsável por uma má posição pélvica (BIENFAIT, 1995).

A hemiplegia é uma paralisia dos músculos de um lado do corpo, ou seja, um hemicorpo, contra lateral ao lado do cérebro em que ocorreu o AVC (Acidente Vascular Cerebral). Esta alteração na função motora pode levar a déficits na coordenação dos movimentos, fraqueza de músculos específicos, tônus anormal, ajustes posturais anormais,

movimentos sinérgicos anormais e falta de mobilidade entre estruturas da cintura escapular (FREITAS, 2008).

A hemiplegia é clinicamente considerada como sendo uma paralisia dos músculos de um lado do corpo, contra lateral ao lado do cérebro em que ocorreu o AVC. Esta alteração na função motora pode levar a déficits na coordenação dos movimentos, fraqueza de músculos específicos, tônus anormal, ajustes posturais anormais, movimentos sinérgicos anormais e falta de mobilidade entre estruturas da cintura escapular (CACHO et al, 2004).

Este trabalho foi desenvolvido utilizando, como instrumento para a obtenção dos dados, uma Plataforma de Força para aplicações Biomédicas, desenvolvida pelo grupo do Laboratório de Sensores do Departamento de Engenharia Elétrica da Faculdade de Engenharia de Ilha Solteira – SP. Esta plataforma foi estudada e projetada inicialmente pelo Engenheiro Ricardo Luiz Barros de Freitas (FREITAS, 2008), composta por 48 sensores distribuídos na região plantar que possibilita a identificação da distribuição da força plantar.

Clinicamente, é mais relevante examinar pressões sob áreas específicas dos pés do que a pressão no pé como um todo. Teoricamente, os pés podem ser divididos em seções cada vez menores, porém, ainda que informações mais precisas possam ser obtidas, pode haver perda de informação a respeito da função global dos pés (FREITAS, 2008).

Uma amostra de dados foi utilizada através da realização de testes com pacientes, aprovada pelo Comitê de Ética em Pesquisa da Faculdade de Ciências e Tecnologia da UNESP - Presidente Prudente (Processo nº 160/2007).

As medições, em pacientes normais e hemiplégicos, foram realizadas no Laboratório de Sensores do Departamento de Engenharia Elétrica da Faculdade de Engenharia de Ilha Solteira - SP, da UNESP pelo Fisioterapeuta Mário Márcio Estremote, utilizando a Plataforma de Força.

Os dados dos pacientes, obtidos com o auxílio da plataforma, foram apresentados às redes neurais MLP (*Multilayer Perceptron*), com o algoritmo retropropagação (*backpropagation*) e à Rede Neural ARTMAP Nebulosa, que foram capazes de analisá-los e classificá-los em pacientes normais ou hemiplégicos.

1.2 Objetivo

Este trabalho tem por objetivo o desenvolvimento de um *software*, utilizando-se Redes Neurais, para realizar a classificação dos pacientes amostrados como normais ou hemiplégicos, e que possa classificar outros pacientes, relacionando-os direta ou indiretamente com as avaliações descritas pelos profissionais da área.

1.3 Justificativa

No mercado, a oferta de equipamentos, que aferem os parâmetros biofísicos relacionados com alterações de equilíbrio humano, efetuam medidas objetivas, numéricas e qualificam as forças nas regiões plantares é muito pequena. Esses poucos equipamentos que existem possuem custos exorbitantes, além de não serem capazes de qualificar os pacientes e relacionar as eventuais disparidades com manifestações clínicas relacionadas previamente pelo indivíduo, dentro de várias áreas do domínio da saúde.

O baropodômetro é um exemplo típico, pois é uma tecnologia de difícil acesso para a grande maioria das clínicas, instituições, associações, hospitais e centros de reabilitação. Não é produzido em território nacional e apresenta custo elevado. O instrumento trabalha com análises de regiões dos pés e não em pequenas áreas. Ele não é capaz de classificar nenhum tipo de paciente, ou doença. Ele somente mostra valores de peso em áreas selecionadas.

A Baropodometria é um exame objetivo e quantitativo que analisa a pressão plantar sobre uma plataforma composta de sensores, que visa mensurar e comparar as pressões desenvolvidas nos diferentes pontos da região plantar na posição em pé, estática ou em marcha (ESTREMOTE, 2010).

Considerando esses aspectos, foi implementado um equipamento que possibilita aos indivíduos uma avaliação em suas proporcionalidades de descarga de peso plantar, em pequenas áreas. Com os dados coletados o clínico/avaliador poderá fazer um diagnóstico mais preciso do paciente. Mesmo assim, faz-se necessária uma análise subjetiva dos dados para determinar a condição do paciente, caracterizando-o (classificando) como normal ou hemiplégico.

Com a adequação das Redes Neurais Artificiais para avaliar os dados coletados pela plataforma de força, será possível contribuir para a análise subjetiva do profissional da área, pois as redes e os programas desenvolvidos irão, imediatamente, apresentar a condição do paciente. A combinação da plataforma com os *softwares* de análise utilizando Redes Neurais

Artificiais irá enriquecer o sistema desenvolvido, principalmente devido à capacidade de análise imediata das informações.

A avaliação com a inclusão da análise das condições atuais do paciente é essencial para estabelecer um programa de recuperação motora. Assim, o desenvolvimento de um sistema de processamento com Redes Neurais Artificiais e a análise da medição de forças da região plantar, com baixo custo, versátil e com portabilidade, deverá ser muito benéfica para a comunidade brasileira de fisioterapeutas, médicos e terapeutas ocupacionais, além de contribuir para a realização de pesquisas em Fisioterapia, Posturologia e Biomecânica.

No elevado número de atendimentos clínicos realizados neste país, é grande o contingente de indivíduos que apresentam comprometimento no sistema neuro-músculo-esquelético. O equipamento proposto é indicado para a avaliação clínica destes pacientes e contribuirá para aprimorar o diagnóstico, propiciando um tratamento eficaz e um prognóstico positivo (FREITAS, 2008).

Durante a realização deste trabalho não foi encontrado nenhum programa de análise para diferenciar pessoas normais e hemiplégicas nos equipamentos disponíveis para a Engenharia Biomédica.

1.4 Organização dos Capítulos

O trabalho foi organizado em sete capítulos, da seguinte forma:

No Capítulo 2 é feito um estudo do estado da arte, no qual é definido o problema proposto e realizada a análise das principais referências bibliográficas relacionadas com o trabalho.

O Capítulo 3 aborda os conceitos relacionados à estrutura dos membros inferiores, acidente vascular cerebral, hemiplegia, posturologia, baropodômetro e baropodometria.

O Capítulo 4 descreve os principais conceitos relacionados às Redes Neurais Artificiais: neurônios biológicos, neurônios artificiais, Redes Neurais MLP (*Multilayer Perceptron*), Rede Neural ART (*Adaptive Resonance Theory*), Rede Neural ARTMAP, Rede Neural ARTMAP Nebulosa.

No Capítulo 5 é apresentada a metodologia, o desenvolvimento e a utilização das Redes Neurais MLP e ARTMAP Nebulosa para a aplicação na discriminação de pacientes normais e hemiplégicos.

No Capítulo 6 são apresentados os resultados obtidos através da aplicação das arquiteturas de redes neurais artificiais (MLP e ARTMAP Nebulosa) na identificação de pacientes (normais e hemiplégicos) através da distribuição de forças plantares e, posteriormente, discussões com relação aos resultados obtidos.

O Capítulo 7 apresenta as conclusões e contribuições deste trabalho, retratando também, as sugestões para possíveis trabalhos futuros.

CAPÍTULO 2

2 ESTADO DA ARTE

Neste capítulo, apresenta-se o estado da arte em relação à aplicabilidade e uso de Redes Neurais Artificiais para a classificação de problemas da fisiologia humana. Neste contexto, são abordadas as publicações sobre as redes neurais na literatura especializada, utilizadas nesse trabalho.

2.1 Definição do Problema

Nos últimos anos há uma grande preocupação do ser humano em identificar e solucionar os diversos problemas da fisiologia humana, oriundos dos mais diferentes fatores. A partir desta necessidade muitos pesquisadores foram estimulados a desenvolverem seus trabalhos em um novo ramo da ciência.

Em função do processo de globalização mundial é fundamental e necessário que se tenha maior agilidade nas tomadas de decisões. Essa necessidade torna-se mais necessária ainda quando se trata das questões que envolvem a área médica, ou seja, quando estão diretamente ligadas a sobrevivência e bem estar dos seres humanos.

A qualificação do profissional é extremamente importante e os materiais e recursos dos quais dispõem para realizarem seus diagnósticos também possuem uma grande relevância. Na área médica, esses diagnósticos são realizados de acordo com os dados disponíveis e a experiência adquirida pelo profissional no seu cotidiano de trabalho. Contudo, em relação às doenças o tempo muitas vezes é relevante. Sendo assim a utilização da plataforma de força e a classificação realizada pela rede neural é de grande utilidade, pois agiliza o trabalho, permitindo uma interferência mais precisa e imediata, apontando quais as medidas que devem ser tomadas para que o paciente tenha maiores possibilidades de cura.

2.2 Análise das Principais Referências Bibliográficas

Neste trabalho serão analisadas as Redes Neurais Perceptron Multi-Camadas (MLP) e ARTMAP. Estas análises restringirão às principais referências que fazem uso desses conceitos e métodos associados a estes temas.

Os primeiros conceitos das redes neurais artificiais (RNAs) surgiram na década de 40, mais especificamente em 1943 com o trabalho precursor de McCulloch e Pitts (MCCULLOCH; PITTS, 1943).

Em 1949 o psicólogo Donald Hebb, demonstrou que a capacidade da aprendizagem em redes neurais vem da alteração da eficiência sináptica, isto é, a conexão somente é reforçada, se tanto as células pré-sinápticas quanto as pós-sinápticas estiverem excitadas.

Em 1958 Roseblatt desenvolveu o *perceptron*, que é uma das estruturas neurais mais empregadas na literatura especializada. No ano de 1960 surgiu a rede ADALINE (*ADaptive Llinear NEtwork*) e a rede MADALINE (*Many ADALINE*), proposta por Widrow e Hoff.

Em 1974, Werbos apresentou o algoritmo retropropagação (*backpropagation*) que possui a capacidade de treinar redes multicamadas (WERBOS, 1974). Em 1982, o físico e biólogo Hopfield relatou a utilização de redes simétricas para otimização, através de um algoritmo de aprendizagem que estabilizava uma rede binária simétrica com realimentação.

A década de 70 foi um período em que praticamente não houve nenhum estudo sobre redes neurais, em decorrência do impacto dos trabalhos de Minsky e Papert (BRAGA et al., 1998, p.3) e a falta de verbas para a pesquisa sobre redes neurais artificiais (HAYKIN, 2001, p.66).

A partir dos anos 80, os estudos sobre redes neurais passaram a receber mais destaque e muitas pesquisas na área vêm sendo desenvolvidas e que associadas ao uso de diferentes hardwares são capazes de obterem ótimos desempenhos.

Uma das mais importantes características das Redes Neurais Artificiais refere-se a capacidade de generalização, ou seja, produzir respostas para padrões de entradas que são similares, mas não idênticos, aos padrões apresentados à rede durante o seu treinamento. Quando uma rede multicamadas é treinada com o algoritmo retropropagação (*backpropagation*) (WERBOS, 1974), objetiva-se que ela seja capaz de aprender com os dados correspondentes ao padrão de entrada, e que seja capaz de classificar satisfatoriamente a quaisquer padrões de entrada.

Este trabalho foi desenvolvido utilizando o treinamento supervisionado e o algoritmo retropropagação (*backpropagation*), que é um dos algoritmos mais difundidos para treinamento das redes supervisionadas. (WERBOS, 1974; WASSERMAN, 1989).

Na classificação de quaisquer dados de entrada haveria um melhor desempenho se a rede não precisasse recomeçar seu treinamento do ponto inicial a cada vez que fossem apresentados novos padrões de entrada, ou seja, se a rede fosse capaz de preservar o conhecimento adquirido anteriormente. Uma família de RNA denominada ART (*Adaptive Resonance Theory*) foi desenvolvida para resolver essa necessidade, que é baseada na Teoria da Ressonância Adaptativa (CARPENTER; GROSSBERG, 1991c).

A origem da Teoria da Ressonância Adaptativa pode ser atribuída a Von der Malsburg, em 1973, que foi um dos primeiros a apresentar uma rede neural artificial com característica auto-organizável e influenciou o trabalho de Teuvo Kohonen e Steven Grossberg (ANAGNOSTOPOULOS, 2001).

A primeira arquitetura baseada na teoria da ressonância adaptativa é a rede Grossberg, denominada GN (*Grossberg Network*) (GROSSBERG, 1976). A rede GN apresenta duas camadas: a primeira é responsável pela normalização dos dados de entrada; e a segunda realiza a seleção dos padrões de saída e os armazena na memória de curto prazo.

A arquitetura ART1, baseada no modelo de Grossberg, foi desenvolvida para realizar agrupamentos de padrões binários, por Carpenter e Grossberg em 1987, realizando o treinamento não supervisionado (CARPENTER; GROSSBERG, 1987a). No mesmo ano, 1987, a ART1 foi estendida para manipular padrões com valores reais e a arquitetura foi designada ART2 (CARPENTER; GROSSBERG, 1987b).

A rede ARTMAP, composta por dois módulos ART, foi a primeira arquitetura baseada na teoria da ressonância adaptativa adequada para a tarefa de classificação, apresentando treinamento supervisionado (CARPENTER et al., 1991a). Em 1992, a arquitetura ARTMAP foi estendida para ARTMAP Nebulosa para a classificação de padrões com valores reais, usando o treinamento supervisionado (CARPENTER et al., 1992).

Várias pesquisas estão sendo realizadas desde então e têm sido desenvolvidas muitas variações da arquitetura ART. Tais pesquisas objetivam melhorar as propriedades de generalização destas arquiteturas, ou seja, proporcionam uma maior eficiência de rapidez no processamento da rede e também na precisão de resultados. Dentre as diversas variações pode-se citar: PROBART (MARRIOT, 1995), ART-EMAP (CARPENTER; ROSS, 1995), ARTMAP GAUSSIANA (WILLIAMSON, 1996), ARTMAP-FD (CARPENTER et al., 1997), ARTMAP Boosted (VERZI et al., 1998), μ ARTMAP (GOMÉS-SÁNCHEZ et al., 2002), etc.

CAPÍTULO 3

3 BIOMECÂNICA HUMANA

No presente capítulo estão apresentados os conceitos relacionados à estrutura dos membros inferiores, acidente vascular cerebral, hemiplegia, posturologia, baropodômetro e baropodometria. Assim, possibilitará ao leitor um maior entendimento deste trabalho realizado e da aplicabilidade da plataforma de força que está sendo utilizada.

3.1 Estrutura do Membro Inferior

O membro inferior desempenha funções vitais, como a deambulação e de sustentação do peso corporal. A sua integridade é essencial para que estas funções cotidianas se processem de maneira eficaz. A partir da movimentação coordenada do membro inferior, o ser humano pode se locomover e se apoiar sobre seus pés. Para a realização da locomoção deve existir uma harmonia articular, muscular e de outras estruturas.


3.1.1 Ossos do Membro Inferior

Os ossos do membro inferior são: o fêmur, a tíbia, a fíbula e o pé (talus, calcâneo, tarso, metatarso e falange).

O pé leva o ser humano a tomar contato físico direto e imediato com seu meio ambiente. A sua constante exposição e suscetibilidade a lesões motivaram, além da proteção especializada (calçados), o desenvolvimento de diagnósticos que visam um estudo detalhado sobre a distribuição da descarga de peso, análises diversas sobre os conteúdos da marcha e soluções para acometimentos patológicos. Para melhor compreender estes aspectos se faz necessário um estudo anatômico, topográfico e fisiológico das estruturas do pé.

A estrutura do esqueleto é complexa, e responsável por funções variadas como apoio, equilíbrio, impulso, absorção de impacto e postura. A Figura 3.1 ilustra os principais ossos do pé (KAPANDJI, 1990).

Figura 3.1 - Ossos do pé direito, vista dorsal.



Fonte: Kapandji (1990).

Os ossos são unidos por meio das articulações e envolvidos pela musculatura, das quais surgem os tendões que tracionam os ossos, realizando os movimentos desejados.


Um conjunto estrutural muito importante para a compreensão das descargas de pesos sobre o pé é a abóbada plantar e/ou arcos plantares.

3.1.2 A abóbada plantar

A abóbada plantar é um conjunto arquitetônico que associa harmoniosamente todos os elementos ósteo articulares, ligamentares e musculares do pé. Graças à sua mudança de curvatura e elasticidade, o pé pode adaptar-se às desigualdades de um terreno e transmitir ao solo os esforços e o peso do corpo, nas melhores condições mecânicas, para circunstâncias muito variadas. As alterações que diminuem ou afetam suas curvaturas, acometem gravemente o apoio no plano horizontal e repercutem obrigatoriamente sobre a corrida e a marcha, ou mesmo sobre a posição em repouso (FREITAS, 2008).

O pé apoia-se no solo através de três pontos A, B e C, que estão dispostos em um plano horizontal, nos vértices de um triângulo equilátero, como se observa na Figura 3.2 (KAPANDJI, 1990).


Figura 3.2 - O triângulo equilátero e seus vértices.



Fonte: Kapandji (1990).

Segundo Kapandji (1990), a abóbada plantar é semelhante, á uma vela triangular inflada pelo vento. Seu vértice nitidamente levado para trás e o peso do corpo se aplica sobre seu vertente posterior em um ponto (situado no centro do dorso do pé), como mostra a Figura 3.3.

Figura 3.3 - Abóbada plantar sustentada por três arcos.




Fonte: Kapandji (1990).

A abóbada não forma um triângulo equilátero propriamente dito, mas possui três arcos e três pontos de apoio, que correspondem à cabeça do primeiro metatarsiano (A), à cabeça do quinto metatarsiano (B) e às tuberosidades posteriores do calcâneo (C). Estes pontos de apoio estão compreendidos na zona de contato com o plano horizontal, ou impressão plantar.

Os esforços se dividem em três direções, para os três pontos de apoio da abóbada, (KAPANDJI, 1990), para o apoio anterior e interno (A), para o apoio anterior e externo (B) e para o apoio posterior (C), como se pode observar na Figura 3.4.


Figura 3.4 - Pontos de apoio do pé direito.



Fonte: Kapandji (1990).

A forma da abóbada plantar é semelhante a uma vela triangular inflada pelo vento, na qual seu vértice é nitidamente levado para trás e o peso do corpo se aplica sobre seu vertente posterior (flecha) em um ponto situado no centro do dorso do pé, como observado na Figura 3.5.

Figura 3.5 - Vista interna da abóbada plantar do pé direito.



Fonte: Kapandji (1990).

Além destes três pontos de apoio, o hálux (dedo maior), que não possui falange média, e as falanges dos dedos dos pés são ossos mais curtos que os da mão, contribuem com uma parcela significativa na distribuição das descargas de peso, parcela esta que é ainda mais perceptiva na fase de duplo apoio da execução da marcha.

Existem algumas patologias nos membros inferiores que levam o indivíduo a apresentar problemas de equilíbrio, disfunção na marcha e, até perda total da capacidade de deambulação. Várias patologias ou traumas causam uma desarmonia, tanto nos segmentos do membro inferior, como nas estruturas do pé. O AVC (Acidente Vascular Cerebral), por exemplo, é uma doença que acarreta problemas motores cognitivos e sensoreomotores, e que muito tem preocupado especialistas e profissionais da reabilitação, que buscam subsídios e soluções precisas para avaliar e tratar os indivíduos acometidos por esta doença.

3.2 Acidente Vascular Cerebral (AVC) ou Acidente Vascular Encefálico (AVE)

O AVC ou AVE, também chamado de derrame, pode ser definido como uma agressão vascular que provoca uma lesão no cérebro, resultando em déficits neurológicos. Um AVC caracteriza-se por uma interrupção ou extravasamento do fluxo sanguíneo para uma área específica do cérebro, resultando em lesão cerebral decorrente da falta de oxigênio.

O termo Acidente Vascular Cerebral (AVC), significa o comprometimento súbito da função cerebral, causado por inúmeras alterações histopatológicas que envolvem um ou vários vasos sanguíneos intracranianos ou extra-cranianos.

3.2.1 Hemiplegia

Hemiplegia é uma disfunção funcional que paralisa um lado do corpo, ocasionando um déficit sensorial e motor, podendo ocorrer outros sintomas que produzam incapacidades como afasia, disartria e defeitos do campo visual, com comprometimento mental e intelectual (FREITAS, 2008).

A hemiplegia é caracterizada pela perda do controle motor de um lado do corpo. É comprovada a incapacidade típica de mover o braço e a perna. Sabe-se que na hemiplegia não ocorre apenas o comprometimento do braço e da perna, mas sim um comprometimento global de um lado do corpo que interferirá na seletividade do movimento do tronco.

A instabilidade da marcha e os distúrbios neuromusculares causados pelo AVC, constituem um dos principais fatores que resultam na queda. As quedas representam o maior problema de saúde pública entre pessoas idosas e resulta em significativa taxa de morbidade e mortalidade (FREITAS, 2008).

Estudos mostram que a incidência de quedas varia de 23% a 50% em pacientes hemiplégicos crônicos, o que é muito maior do que numa comunidade de idosos que não sofreram AVC (11% a 30%) (ESTREMOTE, 2010).


Uma das principais preocupações das quedas é que 26% das pessoas que sofreram uma queda, com lesão, começam a evitar situações que exijam maiores capacidades de equilíbrio, levando a declínios adicionais nas capacidades de andar e equilíbrio (FREITAS, 2008).

3.2.2 Padrão Postural

Os membros superiores, na hemiplegia, estão severamente envolvidos, desenvolvendo padrões consistentes como: flexão das extremidades superiores, flexão do cotovelo, adução e rotação interna do ombro, flexão de punho e dedos e pronação do antebraço. A cabeça está voltada para o lado hemiplégico e o rosto para o lado oposto, a escápula é retraída e o ombro deprimido. O tronco é posteriorizado (projetado para frente) no lado hemiplégico, com flexão lateral para o mesmo lado. O membro inferior, no padrão extensor, tem a pelve posteriorizada no lado afetado e elevado; o quadril estendido, aduzido e

internamente rodado. O joelho é estendido, há flexão plantar com inversão, os dedos são fêtidos e aduzidos, como se observa na Figura 3.6 (EGGERS, 1982).

Figura 3.6 - Padrão patológico da hemiplegia.



Fonte: Eggers (1982).

A capacidade de executar movimentos seletivos é perdida em quase todos os casos de hemiplegia e essa perda de movimentos delicados e individualizados é mais visível no membro superior, no qual o paciente não consegue mover seletivamente o cotovelo, punho ou dedos. Mas a ausência de movimentos isolados afeta também os membros inferiores, prejudicando a marcha (BOBATH, 1990).

3.2.3 Algumas Alterações Morfofisiológicas após um AVC

A evolução de um paciente após um AVC pode ser prejudicada devido à instalação de algumas sequelas. Os problemas mais comuns são:

- O desprezo do lado hemiplégico. Depois de um AVC, o paciente hemiplégico se defronta subitamente com duas metades de seu corpo que ele percebe de forma diferente e que não mais trabalham em conjunto;
- Assimetria;
- Movimento anormal;

- Ausência de reações automáticas;
- Falta de coordenação em ambas às mãos;
- Deficiência sensitiva;
- Distúrbios cognitivos, perceptivos e comportamentais;
- Incontinência urinária e fecal;
- Acometimento da fala, visão e audição;
- Desorientação;
- Ataxia;
- Paralisia facial.

3.3 Baropodômetro

O Baropodômetro é um equipamento tecnológico, desenvolvido para medir as pressões exercidas pelos pés e suas influências no caminhar e na postura corporal das pessoas. Ele apresenta um alto custo, sendo assim, seu uso na grande maioria das clínicas, instituições, associações, hospitais e centros de reabilitação é dificultado.

Os exames são realizados através de uma plataforma fixa e de uma palmilha baropodométrica, especialmente dotados de centenas de microsensores, que fazem os registros dinâmico e estático. Os dados são armazenados em *softwares* especiais que avaliam a pressão em cada ponto do pé e os seus respectivos picos de força, além de acompanhar a dinâmica completa do passo (contato, apoio, propulsão, velocidade e distância) e os possíveis desvios e equilíbrio posturais.

Para o clínico preparado e experiente, os dados obtidos através de um sistema de Baropodometria possibilitam interpretação dos fatores que podem, direta ou indiretamente estar causando os sintomas ou deformidades verificadas ou relatadas pelo paciente.

3.4 Baropodometria

A Baropodometria é um exame objetivo e quantitativo que analisa a pressão plantar sobre uma plataforma composta de sensores, que visa medir e comparar as pressões desenvolvidas nos diferentes pontos da região plantar na posição em pé, estática ou em marcha (ESTREMOTE, 2010).

Este tipo de avaliação é realizado através de sensores pressóricos de alta sensibilidade, permitindo com que seja realizada a medição da distribuição pressórica estática em posição ereta do corpo.

Esta avaliação constitui o fundamento científico da eficácia de muitos procedimentos conservadores ou cirúrgicos das afecções dos pés e possibilita quantificar as pressões do pé direito, esquerdo, pressões na parte anterior, posterior e no médio pé, até a repartição, modificação, hiperpressão e distribuição das pressões (ESTREMOTE, 2010).

CAPÍTULO 4

4 REDES NEURAIS

Neste capítulo são abordados os conceitos de Redes Neurais Artificiais, neurônios biológicos, neurônios artificiais, Redes Neurais MLP (*Multilayer Perceptron*), Rede Neural ART (*Adaptive Resonance Theory*), Rede Neural ARTMAP, Rede Neural ARTMAP Nebulosa, suas funcionalidades e aplicações, proporcionando os respectivos entendimentos necessários para a realização deste trabalho.

4.1 Redes Neurais

A principal motivação para o estudo de redes neurais artificiais é o reconhecimento de que o cérebro processa informações de uma forma inteiramente diferente da realizada por um computador digital convencional. Dados incompletos e inconsistentes podem ser processados pelo cérebro por meio do uso da experiência adquirida, podendo-se afirmar que o mesmo, em muitas situações, é tolerante a falhas (HAYKIN, 1998).

As Redes Neurais Artificiais podem ser consideradas modelos matemáticos que se assemelham às estruturas neurais biológicas e que com o auxílio das ferramentas computacionais, adquirem capacidade de aprendizagem e generalização.

Uma rede neural é composta por diversos neurônios artificiais que são conectados de forma apropriada e assim podem gerar comportamentos interessantes e complexos, determinados pela estrutura das ligações (topologia) e pelos valores das conexões (pesos sinápticos). Um dos modelos de neurônio mais conhecido na literatura especializada é o neurônio de McCulloch e Pitts (McCULLOCH; PITTS, 1943).

As redes neurais são capazes de generalizar, ou seja, produzem respostas para padrões de entrada que são similares, mas não idênticos, aos padrões que a rede já conhece. As redes neurais artificiais têm sido aplicadas em muitas áreas com sucesso, dentre elas destacam-se:

Diagnóstico;

Reconhecimento de padrões;

Processamento de Imagens;

Regressão e previsão;


Classificação;

Controle;
 Otimização;
 Tomada de decisão;
 Filtragem de dados;
 Entre outras.

4.2 Neurônio Biológico

O cérebro humano é composto por bilhões de neurônios, que se encontram interligados numa complexa rede de comunicação. Os neurônios são divididos em três seções: o corpo celular, os dendritos e o axônio, cada qual com funções específicas, contudo tais funções também são complementares. A Figura 4.1 ilustra o modelo simplificado das partes de uma célula neuronal (KOVACS, 1996).

Figura 4.1 - Constituintes da célula neuronal.



Fonte: Kovacs (1996).

O corpo celular é a parte central do neurônio e é responsável pela recepção e geração dos impulsos nervosos. Os dendritos têm a função de receber as informações, ou impulsos nervosos de outros neurônios e conduzi-las ao corpo celular e o axônio é responsável por conduzir os sinais, processados pelo corpo celular, para os demais neurônios. As sinapses são, os pontos de contato entre a terminação axônica de um neurônio e o dendrito do outro, capazes de controlar a transmissão de impulsos entre os neurônios.


4.3 Neurônio Artificial

A busca por um modelo computacional que simule o funcionamento das células do cérebro data dos anos 40, com o trabalho de McCulloch e Pitts (1943). Os dois pesquisadores da área biológica propuseram o primeiro modelo matemático do funcionamento de um neurônio. O modelo, por eles apresentado trouxe uma grande contribuição para as discussões sobre o cérebro eletrônico e contribuiu para a criação dos primeiros modelos matemáticos de dispositivos artificiais que buscavam analogias biológicas.

O modelo de McCulloch-Pitts é o mais empregado, principalmente em problemas de reconhecimento de padrão. Rosenblatt (1958) propôs um método inovador de aprendizagem para as redes neurais artificiais denominado *perceptron* e até 1969, muitos trabalhos foram realizados utilizando o *perceptron* como modelo.

A Figura 4.2 descreve o modelo de um neurônio desenvolvido por McCulloch-Pitts (1943), e sua atividade é a soma de “n” entradas ponderadas por seus respectivos “w” pesos. Esta atividade alimenta uma função não-linear $f(.)$ que produz um sinal que será enviado aos demais neurônios.

Figura 4.2 - Modelo do neurônio de McCulloch-Pitts.



Fonte: Widrow e Lehr (1990).

Este modelo é composto por três elementos:


- um conjunto de n conexões de entrada ($x_1, x_2, \dots, x_n$), caracterizadas por pesos ($w_1, w_2, \dots, w_n$);

- um somador (+) para acumular os sinais de entrada; ponderados pelas respectivas sinapses do neurônio (pesos).

- uma função $f(\cdot)$ de ativação que limita o intervalo permissível de amplitude do sinal de saída (y) a um valor fixo.

A ativação do neurônio artificial é feita por uma função denominada função de ativação. A Figura 4.3 mostra alguns exemplos de funções de ativação mais empregadas.

Figura 4.3 - Funções de ativação.



Fonte: Freitas (2011).

4.4 Estrutura das Redes Neurais Artificiais

As redes neurais artificiais são modelos que buscam simular o processamento de informação do cérebro humano. Redes Neurais Artificiais são sistemas de processamento de informações formadas pela interconexão entre unidades simples de processamento, chamadas de neurônios artificiais. Os neurônios artificiais recebem essa denominação porque foram originados a partir de um modelo matemático de um neurônio biológico. Os neurônios se unem por meio de conexões sinápticas, sendo que a principal propriedade desta arquitetura é a sua capacidade de aproximação universal e de aprendizado.

As redes neurais artificiais são formadas por unidades de processamento. Essas unidades, geralmente são conectadas por canais de comunicação que estão associados a determinados pesos e fazem operações apenas sobre seus dados locais, que são entradas recebidas pelas suas conexões. A operação de uma unidade de processamento, proposta por McCulloch e Pitts em 1943, pode ser assim representada:


- sinais são apresentados à entrada;
- cada sinal é multiplicado por um número, ou peso, que indica a sua influência na saída da unidade;
- é feita a soma ponderada dos sinais que produz um nível de atividade;
- se este nível de atividade exceder certo limite (*threshold*) a unidade produz uma determinada resposta de saída.

A maioria dos modelos de redes neurais possui alguma regra de treinamento, na qual os pesos de suas conexões são ajustados de acordo com os padrões apresentados, ou seja, elas aprendem através de exemplos. Arquiteturas neurais são tipicamente organizadas em camadas.

As redes neurais têm sua arquitetura, basicamente, organizada em camadas, com unidades que podem estar conectadas às unidades da camada anterior ou posterior. Usualmente, as camadas são classificadas em três grupos: camada de entrada, na qual os padrões são apresentados à rede; camadas intermediárias ou escondidas, nas quais é feita a maior parte do processamento através das conexões ponderadas; e, camada de saída, na qual o resultado final é concluído e apresentado (CARPENTER; GROSSBERG, 1987a).

Uma Rede Neural Artificial consiste de elementos de processamento (neurônios) e suas conexões (sinapses). Cada neurônio pode ter várias entradas, porém somente uma saída. Cada saída pode ser utilizada como entrada a vários neurônios (através de ramificações). Assim, cada neurônio pode receber várias entradas procedentes de outros neurônios. Cada conexão entre neurônios possui um peso que determina sua contribuição na decisão de disparo, controlando, desta forma, os estímulos. A Figura 4.4 ilustra uma rede neural artificial (WIDROW; LEHR, 1990).

Figura 4.4 - Rede neural artificial.



Fonte: Widrow e Lehr (1990).

Em relação à sua estrutura, as redes neurais podem ser classificadas em dois tipos: redes recorrentes (*feedback*) e redes não-recorrentes (*feedforward*).

As Redes Neurais Recorrentes são assim definidas porque possuem laços de realimentação, ou seja, contém conexões das saídas de uma determinada camada para a entrada da mesma ou de camadas anteriores. As entradas de um neurônio são as saídas dos demais neurônios da camada anterior. As redes que possuem esta estrutura desenvolvem uma memória em longo prazo nos neurônios internos.

As Redes Neurais Não-recorrentes caracterizam-se estruturalmente por estarem dispostas em camadas. Nestas redes neurais cada camada de neurônios recebe sinais somente das camadas anteriores, ou seja, elas não possuem laços de realimentação. Esta rede, também chamada de *feedforward* não possui memória, sendo que, sua saída é exclusivamente determinada em função da entrada e dos valores dos pesos.

As redes neurais artificiais se diferenciam pela sua arquitetura e pela forma como os pesos associados às conexões são ajustados durante o processo de aprendizado. A arquitetura de uma rede neural restringe o tipo de problema no qual a rede poderá ser utilizada, e é definida pelo número de camadas (camada única ou múltiplas camadas), pelo número de neurônios em cada camada, pelo tipo de conexão entre os neurônios (*feedforward* ou *feedback*) e por sua topologia (HAYKIN, 2001).

Uma propriedade muito importante de uma rede neural artificial é a capacidade que possui de aprender por meio de exemplos e fazer inferências sobre o que aprendeu,

melhorando, assim, gradativamente o seu desempenho. As redes neurais utilizam um algoritmo de aprendizagem cuja tarefa é ajustar os pesos de suas conexões (BRAGA; CARVALHO; LUDEMIR, 2000).

Aprendizagem é um processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira pela qual a modificação dos parâmetros ocorre (HAYKIN, 2001).

4.5 Treinamento ou Aprendizado

Dentre todas as características das redes neurais, uma das mais importantes é a habilidade de aprender e com isso melhorar seu desempenho. A rede é treinada de maneira que um conjunto de entrada produza o conjunto de saída desejada, ou pelo menos consistente (WASSERMAN, 1989).

O processo de treinamento é realizado através de ajustes aplicados aos seus pesos, e quando concluído com sucesso, a rede neural atinge uma solução generalizada para uma classe de problemas.

O algoritmo de aprendizado é definido para um determinado conjunto de regras que devem ser bem definidas para alcançarem a solução de um problema de aprendizado. Treinar uma rede neural significa ajustar os pesos da rede de forma que a saída coincida com o valor desejado para cada entrada.


Existem muitos tipos de algoritmos de treinamento específicos para determinados modelos de redes neurais. Eles se diferem pelo modo como os pesos são modificados. Outro aspecto importante é a maneira como a rede neural se relaciona com o ambiente. Existem duas formas básicas de treinamento de redes neurais: o treinamento supervisionado e o treinamento não supervisionado.

4.5.1 Treinamento Supervisionado

O treinamento supervisionado consiste do ajuste de pesos de uma rede neural para fornecer saídas desejadas, considerando-se o conjunto de padrões de entrada (WIDROW; LEHR, 1990). A rede deve receber um conjunto de entradas padronizadas e seus respectivos padrões de saída. Um dos algoritmos de treinamento supervisionado mais utilizados é o

algoritmo retropropagação (*backpropagation*) proposto por Werbos em 1974. A Figura 4.5 ilustra o funcionamento do treinamento supervisionado.

Figura 4.5 - Treinamento supervisionado.



Fonte: Werbos (1974).


No aprendizado supervisionado a rede neural é treinada com a ajuda de um supervisor, ou seja, de acordo com os dados apresentados na entrada da rede, deverá ser verificado se as saídas são iguais às desejadas. Caso as saídas sejam diferentes das desejadas, então deve-se ajustar os pesos de maneira que a rede armazene o conhecimento almejado. Este processo deve ser repetido com todo conjunto de treinamento, até que o acerto esteja dentro do limite desejado.

4.5.2 Treinamento Não Supervisionado

O treinamento não supervisionado é aplicado quando não se tem um agente externo que determina a resposta desejada de acordo com os padrões de entrada. Consiste no ajuste de pesos de uma rede neural, levando-se em conta somente o conjunto de padrões de entrada. Portanto é um procedimento de treinamento auto-organizável ou auto-supervisionado, pois não necessita da saída desejada e não precisa de supervisores para seu treinamento.

No treinamento não supervisionado a rede trabalha as entradas e as organiza de forma as classificá-las, usando para isso seus próprios critérios, de acordo com a Figura 4.6. Os neurônios são utilizados como classificadores, e os dados de entrada são os elementos de classificação. A auto-organização envolve o processo de competição e de cooperação entre os neurônios da rede.

Figura 4.6 - Treinamento não supervisionado.



Fonte: Werbos (1974).

Na aprendizagem não supervisionada não existe um agente externo para acompanhar o processo de aprendizado. O treinamento inicia-se quando um exemplo é mostrado à rede e termina quando todas as conexões estão devidamente ajustadas (treinadas) para reconhecer os exemplos mostrados à rede (ou pelo menos uma boa parte dos exemplos). A partir deste momento a Rede Neural está pronta para a fase de testes e, a seguir, para a execução.


4.6 Modelos de Redes Neurais

4.6.1 Modelo ADALINE

Praticamente na mesma época em que surgiu o *Perceptron*, os pesquisadores Widrow e Hoff propuseram um modelo matemático chamado ADALINE (*ADaptive LINEar Element*). Ambos os modelos são baseados na ideia de terem elementos de processamento executando operações de soma ponderada e posterior comparação com um valor de limiar.

O modelo de neurônio ADALINE (*ADaptive Linear Element*) (WIDROW, 1990) é mostrado na Figura 4.7, na qual a saída é determinada por uma combinação das entradas.

Figura 4.7 - Rede neural ADALINE.



Fonte: Widrow (1990).

Os componentes do vetor padrão de entrada são ponderados por um conjunto de coeficientes, ou seja, pelo vetor de pesos. A soma das entradas ponderadas é, então, avaliada (calculada), produzindo uma combinação linear correspondente ao produto interno.

No processo de treinamento, os padrões de entrada e de respostas desejadas correspondentes são apresentados à rede neural. Um algoritmo de adaptação, automaticamente, ajusta os pesos de modo que as saídas fiquem próximas dos valores desejados.

4.6.2 Modelo MADALINE

A rede neural MADALINE (*Multi-ADALINE*) é constituída por vários elementos ADALINE. Seu treinamento é mais complexo quando comparado à ADALINE.

4.6.3 Redes MLP (*Multilayer Perceptron*)

Entre os diferentes tipos de arquiteturas de rede, o mais comumente utilizado é o *Perceptron* Multi-Camadas (MLP). Nas redes MLP, cada camada tem uma função específica. A camada de saída recebe os estímulos da camada intermediária e constrói o padrão que será a resposta. As camadas intermediárias funcionam como extratoras de características, sendo que seus pesos são uma codificação de características apresentadas nos padrões de entrada e permitem que a rede crie sua própria representação.

O treinamento supervisionado da rede neural MLP, utilizando retropropagação (*backpropagation*), opera em uma sequência de dois passos. Inicialmente apresenta-se um padrão à camada de entrada da rede, a atividade então passa por todas as camadas da rede até obter uma resposta produzida pela camada de saída. Posteriormente, a saída obtida é comparada com a saída desejada. Caso não esteja dentro do desejado, então o erro é calculado, ou seja, o erro é representado pela diferença entre o valor obtido e o valor desejado. O erro então é propagado a partir da camada de saída até a camada de entrada e os pesos das conexões das camadas internas vão sendo alterados à medida que o erro vai sendo retropropagado, com o objetivo de reduzir o erro até um valor aceitável.

Para as unidades de saída, como são conhecidos os valores desejados e obtidos, o ajuste dos pesos sinápticos é relativamente simples e as mudanças nos pesos deverão ser pequenas. Mas para as unidades das camadas ocultas o processo não é tão simples, pois as unidades das camadas ocultas que apresentarem erros grandes devem ter suas conexões bastante alteradas.

O próximo passo é identificar as fases diferentes no processo de aprendizagem da retropropagação. O algoritmo retropropagação é composto por duas fases, sendo a primeira fase (*feedforward*) na qual as entradas são propagadas pela rede desde a camada de entrada até a camada de saída e, uma segunda fase (*backward*), onde há a propagação dos erros obtidos desde a camada de saída da rede até a camada de entrada. Sintetizando, primeiramente as entradas se propagam entre as camadas da rede, da camada de entrada até a camada de saída, e posteriormente os erros são propagados na direção contrária ao fluxo de entrada.


O desempenho do algoritmo de aprendizagem retropropagação está relacionado com a modelagem adotada na rede neural artificial e também ao conjunto de dados utilizados no processo de ajuste dos pesos sinápticos entre as conexões da rede.

Werbos (1974) apresentou a primeira concepção do algoritmo retropropagação. Contudo foi somente em 1986 que Rumelhart, Hinton e Williams, idealizaram um modo de como ajustar os pesos de uma rede neural das unidades de entrada para a unidade de saída. Os erros observados nas unidades da camada escondida são determinados pelo erro propagado na direção inversa das unidades da camada de saída.

Esse algoritmo de treinamento é supervisionado e utilizam a entrada e a saída desejada para, através de um mecanismo de correção de erros, ajustar os pesos da rede. O treinamento ocorre em duas fases, onde cada fase percorre a rede em um sentido. Estas duas

fases são chamadas de *forward* e *backward*. A Figura 4.8 ilustra o processamento do algoritmo com as fases *forward* e *backward*.

Figura 4.8 - Fluxo de processamento do algoritmo com as fases *forward* e *backward*.



Fonte: Freitas (2011).

O processo esquemático de adaptação dos pesos através do algoritmo *backpropagation*, Propagação dos Erros, consiste nos passos apresentados a seguir:

1º Passo – Calcular erro na camada de saída;

2º Passo – Determinar o erro nas camadas intermédias. O erro é dado pela soma dos erros da camada de saída multiplicados pelos pesos das respectivas ligações.

3º Passo – Propagar todos os erros da mesma forma para as restantes camadas intermediárias até a primeira camada.

Após o cálculo dos erros é necessário corrigir os pesos das ligações entre os neurônios segundo o critério de propagação. O cálculo do novo peso é dado pela equação 01.

$$\varpi(k+1) = \varpi(k) + \eta \delta \frac{\gamma f(e)}{\gamma e} y \quad (01)$$

sendo:

ϖ = peso da ligação;

η	=	taxa de treinamento;
δ	=	erro calculado;
γf	=	derivada da função transferência;
y	=	saída do neurônio;
k	=	número de iterações.

A rede neural faz a análise de convergência, através do algoritmo retropropagação. Os critérios de parada podem ser estabelecidos por um número predefinido de iterações ou até que se atinja um erro pré-estabelecido (diferença entre a resposta obtida e a esperada), ou seja, o treinamento da rede finaliza-se quando essa diferença for menor que uma determinada margem de erro inicial.

4.6.4 Rede ART (*Adaptive Resonance Theory*)

A família de redes neurais ART (*Adaptive Resonance Theory* - Teoria da Ressonância Adaptativa) consiste em arquiteturas que aprendem em tempo real códigos de representação estáveis em resposta a uma sequência arbitrária de padrões de entrada (CARPENTER; GROSSBERG, 1988).

A Teoria da Ressonância Adaptativa surgiu como resultado da tentativa de compreender como sistemas biológicos são capazes de continuar aprendendo, sem o comprometimento da estabilidade dos padrões previamente aprendidos, ou seja, o processo de reconhecimento dar-se-á por um processo de observação de verossimilhança (ressonância). A rede ART possibilita que um sistema seja capaz de aprender conhecimentos novos preservando o conhecimento previamente adquirido e evitando que um novo conhecimento se sobreponha aos conhecimentos prévios.

As redes ART surgiram com o intuito de solucionar o dilema da estabilidade-plasticidade que proporcionam à rede uma aprendizagem estável e convergência rápida. A estabilidade permite a garantia da obtenção de soluções, ou seja, é responsável por agrupar todos os elementos nas classes criadas pelo sistema e a plasticidade, refere-se à capacidade de incluir novos padrões sem a necessidade de reiniciar todo o processo de treinamento, ou seja, a rede é capaz de aprender novos padrões sem perder o aprendizado adquirido anteriormente. A rede também possui como característica a grande velocidade de realização do treinamento e diagnóstico, tornando-a um sistema adequado para aplicação em tempo real.

Uma rede neural ART pode ser qualificada como uma RNA incremental, ou seja, uma RNA capaz de aumentar a sua complexidade à medida que novos padrões são apresentados. Desse modo, não é necessário recomençar seu treinamento do ponto inicial cada vez que aparecem novos padrões de entrada, preservando, por conseguinte, o conhecimento adquirido anteriormente (BRAGA et al., 1998).

Um único neurônio artificial representada essa rede, pois recebe a entrada de várias outras unidades semelhantes. Nas redes ART, o aprendizado é tratado como uma ação dinâmica, de forma que a rede possa continuamente adaptar-se aos novos padrões de entrada.

O aprendizado nas redes ART é não supervisionado, ou seja, a rede consegue aprender tendo como entrada padrões não rotulados, ou seja, sem empregar um mecanismo externo. Nesse tipo de aprendizado, a rede tem a habilidade de formar representações internas para codificar as entradas através de um conjunto de unidades de saída ou representação.

As arquiteturas ART são projetadas de forma que o usuário possa controlar o grau de similaridade entre os padrões agrupados na mesma unidade de saída. Tal controle possibilita que a rede seja mediantemente sensível às diferenças existentes entre os padrões de entrada, e assim, seja capaz de gerar mais ou menos grupos em resposta a esse controle.


4.6.5 Rede ARTMAP

A rede ARTMAP é uma rede composta por dois módulos ART. Ela foi a primeira arquitetura baseada na teoria da ressonância adaptativa apropriada para a tarefa de classificação, apresentando treinamento supervisionado (CARPENTER et al., 1991b). É um sistema com aprendizado supervisionado capaz de auto-organizar o reconhecimento estável de categorias em respostas aos padrões de entrada arbitrários.

A rede refere-se ao arranjo de duas redes neurais ART conectadas através de um módulo inter-ART. As duas redes neurais ART são responsáveis por receberem os estímulos de entrada e de saída e o módulo inter-ART desempenha a função de realizar o “casamento” entre os estímulos de entrada e de saída. Esta rede é denominada ARTMAP (CARPENTER et al., 1992).

A arquitetura ARTMAP é considerada como uma rede mais sofisticada, pois é capaz de treinar e realizar o mapeamento entre dois espaços de vetores, usando o treinamento supervisionado e auto-organizável. A Figura 4.9 mostra a arquitetura da rede ARTMAP (CARPENTER et al., 1992).

Figura 4.9 - Arquitetura básica de uma rede ARTMAP.



Fonte: Carpenter et al. (1992).

A rede ARTMAP tem treinamento supervisionado, realiza um treinamento rápido e estável, possui estabilidade (garante a obtenção de soluções) e plasticidade (capacidade de incluir novos padrões sem a necessidade de reiniciar todo o processo de treinamento).

A rede ARTMAP é composta por duas sub-redes, ARTa, que recebe e processa um determinado padrão de entrada apresentado e ARTb, que constitui a resposta desejada para o padrão apresentado à rede que são interligadas por um módulo de memória associativa, denominado Inter-ART (ARTab), responsável pela verificação se há casamento da entrada (ARTa) e da saída (ARTb). O módulo ARTa aprende a classificar os padrões de entrada apresentados em sua camada e o módulo ARTb desenvolve categorias referentes aos padrões de saída desejado.

A rede ARTMAP realiza o processamento de duas redes ART (ARTa e ARTb), sendo que após a ressonância ser confirmada em cada rede, tem-se a categoria ativa J para a rede ARTa e a categoria ativa K para a rede ARTb.

Todas as matrizes de pesos são iniciadas com valores iguais a 1, ou seja, mostrando que todas as atividades encontram-se inativas. Tais atividades são ativadas à medida que ocorre ressonância entre os padrões de entrada e de saída.

Toda vez que os pares de entrada, associados aos módulos ARTa e ARTb, são confirmados, de acordo com o teste do *match tracking* (processo auto-regulador que maximiza a generalização e minimiza os erros), o par de treinamento será confirmado nas

matrizes de pesos, caso contrário deve-se buscar um outro padrão de entrada, até que o critério seja satisfeito. Através do *match tracking* verifica-se a categoria ativa no ARTa corresponde ao vetor de saída desejada apresentado no ARTb.

As matrizes de pesos associadas à rede ARTa referente aos padrões de entrada W_a , associada à rede ARTb referente aos padrões de saída W_b e a associada ao módulo Inter-ART W_{ab} , possuem a seguinte dimensões:

$$W_a = (N_a \times M_a);$$

$$W_b = (N_b \times M_b);$$

$$W_{ab} = (N_a \times N_b).$$

sendo:

N_a : número de pares da entrada;

N_b : número de pares da saída;

M_a : número de componentes dos vetores de entrada;

M_b : número de componentes dos vetores de saída.

A ativação das categorias (atualização das matrizes de pesos) ocorrerá sempre que houver a ressonância entre os padrões de entrada com os padrões de saída, ou seja, quando os pares de entrada associados aos módulos ARTa e ARTb (referentes, respectivamente, às categorias J e K ativas) forem confirmados, de acordo com o teste do *match tracking*.

4.6.6 Rede ARTMAP Nebulosa (*Fuzzy*)

O modelo neural ARTMAP Nebuloso (*Fuzzy*) (CARPENTER et al., 1992) possui, basicamente, a mesma estrutura abstrata apresentada pelo modelo ARTMAP (CARPENTER et al., 1991). Na rede ARTMAP Nebulosa, similarmente ao modelo ARTMAP, entrada e saída desejadas são apresentadas aos módulos nebulosos ARTa e ARTb, respectivamente, tendo-se as saídas destes módulos associadas no módulo de mapeamento.

A rede neural ARTMAP Nebulosa é uma arquitetura baseada na teoria da ressonância adaptativa e pertence a família das redes ART. Tem como principal característica o agrupamento de todas as entradas em classes, que são criadas durante o processo de treinamento, permitindo assim que a convergência do processo de treinamento seja rápida e estável.

A rede neural ARTMAP Nebulosa incorpora a teoria de conjuntos nebulosos em seus cálculos. Ela é composta por dois módulos ART nebulosos, ARTa e ARTb nebulosos. A diferença entre a rede neural ARTMAP e a rede neural ARTMAP Nebulosa consiste basicamente nos operadores nebulosos, ou seja, enquanto o ARTMAP possui módulos ART, utilizando a teoria dos conjuntos clássica, a rede ARTMAP Nebulosa possui módulos nebulosos ART, ou seja, os módulos ART fazem uso da teoria dos conjuntos nebulosos. A rede ARTMAP Nebulosa requer a normalização e codificação complementar dos padrões de entrada, que duplica a dimensão da rede.

As matrizes pesos associadas aos módulos ARTa (W_a) e ARTb (W_b), assim como com relação ao módulo Inter-ART (W_{ab}), são iniciadas com valores iguais a 1, ou seja, todas as atividades encontram-se inativas. Estas atividades são ativadas à medida que ocorre ressonância entre os padrões de entrada e de saída.


Durante o treinamento supervisionado, a ARTa recebe um padrão de entrada “a” e a ARTb recebe um padrão “b”, sendo que “b” é a predição correta de “a”. Quando uma predição em ARTa não é confirmada por ARTb, a memória associativa inibe o inter-ART. Este processo aumenta a vigilância em ARTa por uma quantidade mínima necessária para que o sistema ative outra categoria em ARTa que iguale a categoria em ARTb, ou para treinar uma nova categoria em ARTa.

A rede neural ARTMAP Nebulosa, assim como a rede ART possui como características a estabilidade e plasticidade. A rede é capaz de realizar um novo aprendizado minimizando o erro predito e maximizando a generalização, através do processo *match tracking* que aumenta o parâmetro de vigilância por uma quantidade mínima necessária para corrigir o erro predito.

O campo de mapeamento controla a regra *match tracking*, que aumenta o parâmetro de vigilância da rede ARTa por uma quantia mínima necessária para corrigir um erro preditivo (MARCHIORI et al., 2002).

A Figura 4.10 mostra a arquitetura da rede ARTMAP Nebulosa (CARPENTER et al., 1992).

Figura 4.10 - Arquitetura básica de uma rede ARTMAP Nebulosa.



Fonte: Carpenter et al. (1992).

A rede ARTMAP Nebulosa possui parâmetros fundamentais para a definição do processo de aprendizagem e diagnóstico. O parâmetro de escolha ($\alpha > 0$) que atua na seleção de categorias; o parâmetro taxa de treinamento ($\beta \in [0,1]$) que controla a adaptação dos pesos sinápticos e os parâmetros de vigilância ($\rho_a, \rho_b, \rho_{ab} \in [0,1]$) para os módulos entrada ARTa, ARTb e Inter-ART respectivamente, controlando a ressonância, definindo o número de classes.

As redes ARTMAP Nebulosa são muito sensíveis às variações em seus parâmetros durante o treinamento. O parâmetro mais crítico é o parâmetro de vigilância (ρ), que quando assume um valor baixo, faz com que a rede permita que padrões não muito semelhantes sejam agrupados na mesma categoria de reconhecimento e assim cria poucas classes, e se for atribuído um valor alto (muito próximo a um), então há pequenas variações nos padrões de entrada que levarão à criação de novas classes.

O algoritmo desta rede neural consiste basicamente os seguintes passos (CARPENTER et al., 1992):

Passo 1: Normalizar os vetores de entrada ARTa e de saída ARTb, se necessário. Inicialmente, todos os valores dos neurônios devem ser normalizados se não estiverem entre 0 e 1;

$a = [a_1, \dots, a_m]$, vetor de entrada, M-dimencional;

$$\bar{a} = \frac{a}{|a|};$$

sendo:

$\bar{a}$ = vetor de entrada normalizado;

$$|a| = \sum_i |a_i|.$$

Passo 2: Codificar os vetores dos módulos ARTa e ARTb. Um novo padrão de entrada deve sofrer uma codificação complementar preliminar para se preservar a amplitude da informação;

$$I_e = [a \ a^c];$$

$$I_s = [b \ b^c].$$

Passo 3: Iniciar os pesos e parâmetros dos módulos ARTa, ARTb e Inter-ART. Deve-se iniciar os pesos (valor 1 = todas as categorias desativadas).

$$w_a=1, \ w_b=1 \text{ e } w_{ab}=1;$$

sendo:

W_a = matriz iniciação de pesos da entrada;

W_b = matriz iniciação de pesos da saída;

W_{ab} = matriz iniciação de pesos do módulo Inter-ART.

Passo 4: Definir os parâmetros utilizados no processamento da rede ARTMAP Nebulosa.

- i) taxa de treinamento: $\beta \in [0,1]$, que controla a velocidade dos pesos sinápticos;
- ii) parâmetro de escolha: $\alpha > 0$, que atua na seleção das categorias;
- iii) parâmetro de vigilância: ρ_a, ρ_b e $\rho_{ab} \in [0,1]$, que controla a ressonância da rede, definindo o número de classes.

Passo 5: Escolha da categoria para os módulos ARTa e ARTb é feita, tal que, $T_{ativo} = \max \{T_i\}$. Se mais de um neurônio está ativo, é escolhido aquele com o menor índice de ordenação.

$$T_k^b = \frac{|b_1 \wedge w_k^b|}{\alpha + |w_k^b|}, \text{ categoria ativa K;}$$

$$T_j^a = \frac{|a_1 \wedge w_j^a|}{\alpha + |w_j^a|}, \text{ categoria ativa J;}$$

sendo:

$\wedge$ = operador AND nebuloso.

Passo 6: Teste de vigilância dos módulos ARTa e ARTb. A ressonância ocorre se é satisfeito o critério de vigilância. Caso contrário, se o critério de vigilância falhar para a categoria escolhida ocorre o *reset* e um novo índice é escolhido (retornar ao passo 5). O processo de busca se repete até que o índice escolhido satisfaça o teste de vigilância.

$$|x_a| = \frac{|a_1 \wedge w_j^a|}{a_1};$$

$$|x_a| \geq \rho_a.$$

$$|x_b| = \frac{|b_1 \wedge w_k^b|}{b_1};$$

$$|x_b| \geq \rho_b.$$

Passo 7: *Match tracking* (teste de ressonância) entre os módulos ARTa e ARTb. Verificação se houve casamento da entrada com a saída. Se não houver casamento deve-se procurar outro índice que satisfaça o teste.

$$|x_{ab}| = \frac{|y_b \wedge w_j^{ab}|}{|y_b|};$$

$$|x_{ab}| \geq \rho_{ab}.$$

Passo 8: Adaptação dos pesos. O vetor (camada F2) dos módulos ARTa, ARTb e inter-ART são atualizados com os novos pesos.

$$w_k^{novo} = \beta(a_1 \wedge w_k^{velho}) + (1 - \beta)w_k^{velho};$$

$$w_j^{novo} = \beta(a_1 \wedge w_j^{velho}) + (1 - \beta)w_j^{velho};$$

$$w_{jk}^{ab} = 1; w_{jk}^{ab} = 0, \text{ se } j \neq J \text{ e } k \neq K.$$

Passo 9: Repetir passos 5 à 7 para todos os pares a serem treinados.

O algoritmo da rede ARTMAP Nebulosa se difere da ARTMAP pelo uso do operador nebuloso $\wedge$ no lugar do operador de interseção $\cap$, assim como ocorre nas redes ART.

CAPÍTULO 5

5 METODOLOGIA

Neste capítulo, descreve-se o desenvolvimento e a aplicação das Redes Neurais Artificiais MLP e ARTMAP Nebulosa, desde o treinamento até a identificação dos pacientes normais e hemiplégicos.

5.1 Introdução

Neste trabalho, foram estudadas e aplicadas a rede neural MLP e a rede neural ARTMAP Nebulosa.

Uma plataforma de força foi utilizada para efetuar medidas de descargas plantares em pessoas voluntárias. A foto da plataforma está ilustrada na Figura 5.1 (foto obtida no Laboratório de Sensores), e a mesma foi construída no Laboratório de Sensores do Departamento de Engenharia Elétrica da UNESP – Campus de Ilha Solteira.

Figura 5.1 - Foto da Plataforma de Força.



Fonte: Freitas (2010).

As aquisições dos dados provieram dos sensores distribuídos na plataforma de força. Esses sensores possuem pequenas esferas com áreas reduzidas que entram em contato com a região plantar do pé direito e do pé esquerdo de cada pessoa, simultaneamente. Essa plataforma possui 48 células de carga, com sensores resistivos, subdivididas em dois conjuntos de 24 células para cada pé.

As informações coletadas através da plataforma são obtidas através de um programa desenvolvido em ambiente LABVIEW (*National Instruments*). Uma interface gráfica representa os sensores da plataforma. A tela do programa da plataforma de força, desenvolvido pelo Grupo de Instrumentação Eletrônica e Sensores da UNESP de Ilha Solteira – SP, utilizada para a visualização da distribuição das forças nas áreas das regiões plantares está ilustrada na Figura 5.2 (URBAN, et al., 2010).

Figura 5.2 - Interface do programa de aquisição de dados desenvolvido em LABVIEW.



Fonte: Urban (2010).

Os dados de cada paciente são gravados em uma linha de um arquivo de dados que contém a extensão “txt”. As medidas são então utilizadas como dados de entrada das redes neurais artificiais.

A coleta de dados dos pacientes normais (sem histórico de queixas no sistema neuro-músculo esquelético) e dos pacientes hemiplégicos foi realizada por dois fisioterapeutas e um terapeuta ocupacional.

Os profissionais realizaram uma análise subjetiva (qualitativa) de cada um dos indivíduos. O exame subjetivo consistiu em olhar, tocar e avaliar o paciente com auxílio somente dos sentidos. Esse exame pode ser bastante preciso para alguém com um bom senso de observação, “morfológico”, mas sempre suscetível de ser influenciado por fatores pessoais.

Ao fim da análise subjetiva, os pacientes foram avaliados objetivamente através do sistema implementado. Foi criado um protocolo no qual o indivíduo era posicionado sobre a

plataforma, em posição confortável, fixava o olhar ao nível do horizonte em um ponto marcado na parede, situado na altura dos olhos, mantendo-se assim, o eixo de equilíbrio estático. Solicitava-se que o indivíduo não realizasse nenhum movimento e nem conversasse durante um intervalo de tempo, para que os dados fossem coletados.

Os dados de 81 indivíduos normais (sem histórico de queixas no sistema neuro-músculo esquelético) e de 10 hemiplégicos foram coletados. Os valores determinados através de cada sensor da plataforma foram normalizados, ou seja, divididos pelo peso total do paciente no ambiente LABVIEW. Assim os dados estão no intervalo 0 a 1.

As pessoas foram separadas em dois grupos, para as fases de treinamento e diagnósticos. Os indivíduos cujos dados compõem ambas as fases são distintos. Todas as pessoas foram classificadas em normais ou hemiplégicas pelos profissionais da área que estavam presentes no processo.

O grupo 1 é responsável pela fase de treinamento e é composto por 50 pessoas normais e 7 hemiplégicas, num total de 57 conjuntos de dados de indivíduos que compuseram os padrões de entrada das redes neurais. Nessa fase a rede neural pode aprender e generalizar, visando a classificação das pessoas.

O grupo 2 é formado pelas pessoas que irão testar a rede. Esse grupo é responsável pela fase de diagnóstico e é composto por 34 conjunto de dados de indivíduos, sendo 31 normais e 3 hemiplégicos. As redes neurais forneceram uma saída referente ao banco de dados (criado pelo grupo 1) e foram usados no diagnóstico.


5.2 Utilização da Rede MLP

A rede neural utilizada inicialmente foi a MLP com algoritmo retropropagação (*backpropagation*), sendo esta arquitetura desenvolvida através de um programa em linguagem baseada em FORTRAN.

O *backpropagation* foi escolhido por ser um algoritmo eficiente, muito conceituado na literatura especializada e por ter o seu treinamento supervisionado. A escolha deste tipo de treinamento se deve a disponibilidade de dados para a classificação das pessoas. Os conjuntos de dados de cada pessoa montaram um banco de dados de entrada que foi diretamente associado à classificação analisada.

Na Figura 5.3 ilustra-se a arquitetura neural utilizada, observando os dados de entrada (forças plantares medidas pelos sensores dos pés direito e esquerdo) e os dados de saída da rede neural que neste caso é a classificação da pessoa relacionada com a respectiva distribuição de força. Foi utilizada uma representação que fornece a generalização da rede. O valor de saída 0.8 indica uma pessoa é classificada como normal e o valor de saída 0.9 hemiplégica. A escolha desses valores representativos se deve ao fato de que, dados não normalizados podem provocar a saturação da rede neural. Na tentativa de contornar este problema atribuiu-se um valor que estivesse entre 0 e 1. A rede neural foi, então, treinada e após ter sido efetuado o treinamento a rede foi capaz de generalizar a partir de seu aprendizado.

Figura 5.3 - Representação da arquitetura neural MLP utilizada.



Fonte: Freitas (2010).

Os parâmetros utilizados pela rede neural artificial MLP na realização do treinamento estão contidos na Tabela 5.1.

Tabela 5.1 - Parâmetros da rede neural MLP e respectivos valores, utilizados para a fase de treinamento e diagnóstico.

Parâmetros	Aplicação
Número de vetores padrão	17
Número de camadas	3
Número de neurônios por camada	48-60-1
Tolerância	0,009
Taxa de treinamento	0,1
Momento	0,9
Inclinação da função Sigmóide	0,3

Fonte: Freitas (2010).

O processo de treinamento tendo sido finalizado iniciou-se o processo de diagnóstico. Os dados das novas pessoas foram apresentados à rede treinada e então foram obtidas as respectivas saídas, para a classificação das pessoas. Os resultados são valores numéricos próximos de 0,8 para pessoas normais e de 0,9 para pessoas hemiplégicas. Foram utilizadas as regras básicas de aproximação numérica da matemática. Essa aproximação indica a classificação do indivíduo que tenha semelhanças com as pessoas utilizadas no treinamento.

5.3 Utilização da Rede ARTMAP Nebulosa

Um novo software foi desenvolvido, baseado em MATLAB, utilizando a teoria da rede neural ARTMAP Nebulosa. Esse software tem a capacidade de aprender com dados e depois classificar novos dados de acordo com o aprendizado. O programa desenvolvido em MATLAB (*The Language of Technical Computing*), versão 7.2, permitiu o processamento dos dados e apresentou resultados pertinentes à aplicação.

A rede ARTMAP Nebulosa é capaz de fornecer os neurônios vencedores do módulo ARTa representando os dados de entrada das pessoas, os neurônios vencedores do módulo ARTb representando a classificação das mesmas e o resultado da classificação (codificação binária definida previamente).

A rede neural ARTMAP Nebulosa possui características apropriadas a este projeto, por ser supervisionada, possuir um número fixo de camadas com pesos iniciais com valores iguais a 1 e por possibilitar um treinamento rápido e estável.

O programa foi desenvolvido com 11 (onze) arquivos tipo .m para facilitar a execução da Rede ARTMAP Nebulosa, e estão subdivididos em 8 para a fase de treinamento e 3 para a classificação dos indivíduos.

Na classificação das pessoas, foi utilizada uma representação que fornecesse a generalização da rede, portanto, o valor de saída 1 classifica uma pessoa como normal e 0 como hemiplégica.

5.3.1 Treinamento

Inicialmente é feita a leitura dos padrões de entrada, ou seja, são lidos dois arquivos (um das pessoas normais e outro das hemiplégicas) com os conjuntos de dados das pessoas formando vetores de dimensão M em uma matriz de entrada. O programa normaliza esses dados. Em seguida, é feita a leitura dos padrões de saída da rede (outros dois arquivos com as classificações dos respectivos pacientes), também formando vetores de dimensão M em uma matriz de saída.

O programa gera o complemento das matrizes de entrada e de saída, dobrando o tamanho dessas matrizes, permitindo assim a preservação da amplitude das informações.

Os seguintes parâmetros da rede são definidos: parâmetro de vigilância, taxa de treinamento e parâmetro de escolha, de acordo com a Tabela 5.2.

Tabela 5.2 - Especificação dos parâmetros da rede neural.

Item	Valor
Parâmetro de vigilância: ρ_a	0,92
Parâmetro de vigilância: ρ_b	0,999
Parâmetro de vigilância: ρ_{ab}	0,9
Taxa de Treinamento β	1
Parâmetro de escolha α	0,1

Fonte: Freitas (2011).

As matrizes dos pesos foram inicializadas com valores iniciais iguais a 1, indicando assim, que não existe nenhuma categoria ativa.

$$w_a \text{ (padrões de entrada)} = \begin{bmatrix} 111.....1 \\ 111.....1 \\1 \\1 \\ 111.....1 \end{bmatrix}, \text{ dimensão} = 57 \times 96$$

$$w_b \text{ (padrões de saída)} = \begin{bmatrix} 111.....1 \\ 111.....1 \\1 \\1 \\ 111.....1 \end{bmatrix}, \text{ dimensão} = 57 \times 2$$

$$w_{ab} \text{ (matriz Inter - Art)} = \begin{bmatrix} 111.....1 \\ 111.....1 \\1 \\1 \\ 111.....1 \end{bmatrix}, \text{ dimensão} = 57 \times 57$$

A fase de treinamento é iniciada para as duas redes, ARTa e ARTb. O treinamento é realizado individualmente para cada pessoa. A escolha da categoria é realizada para cada um dos módulos ARTa e ARTb. Se existir mais de uma categoria ativa, a categoria escolhida será a que possuir menor índice.


Os testes de vigilância dos módulos ARTa e ARTb são realizados. A ressonância ocorre se os critérios de vigilância forem satisfeitos. Caso não sejam, um novo índice para cada módulo deve ser selecionado e o programa retorna para a escolha da categoria (módulos ARTa e ARTb) na intenção de determinar um novo índice para cada um. Esse processo se repete até que os índices escolhidos satisfaçam aos testes de vigilância.

O teste de ressonância (*Match Tracking*) é realizado entre os módulos ARTa e ARTb. Nesse passo é verificado se ocorreu casamento entre a entrada e a saída. Caso não ocorra volta-se para a escolha da categoria para os módulos ARTa e ARTb para determinar um novo índice para cada um que satisfaça o teste.

A atualização dos pesos sinápticos w_a , w_b e w_{ab} . Assim o treinamento da rede neural está terminado, a rede neural esta pronta para efetuar a classificação dos novos pacientes.

O programa desenvolvido está representado pelo fluxograma ilustrado na Figura 5.4.

Figura 5.4 - Fluxograma do treinamento desenvolvido em MATLAB.




5.3.2 Classificação

A classificação de cada paciente é realizada com a apresentação do conjunto dos dados de entrada à rede neural ARTMAP NEBULOSA. O programa normaliza esses dados das entradas e gera seus complementos, permitindo a preservação da amplitude das informações.

A escolha da categoria para os módulos ARTa é realizada. O índice escolhido é “associado” à matriz W_{ab} . A rede classifica o paciente normal ou hemiplégico de acordo com as informações da matriz W_b . O programa desenvolvido está representado no fluxograma ilustrado na Figura 5.5.

Figura 5.5 - Fluxograma da classificação desenvolvido em MATLAB.



Fonte: Freitas (2011).

CAPÍTULO 6

6 RESULTADOS E DISCUSSÃO

Neste capítulo são apresentados os resultados obtidos com a rede neural MLP e a rede neural ARTMAP Nebulosa, e a classificação das pessoas normais e hemiplégicas.

6.1 Medições

Os conjuntos de dados de entrada das redes neurais correspondem às medidas dos pés direito e esquerdo. Os conjuntos de dados de saída das redes neurais são as classificações dos pacientes.

Nas Tabelas 6.1 e 6.2 são mostrados exemplos dos dados captados, de alguns pacientes da região plantar, medidas através da plataforma para os pés direito e esquerdo relacionados a pessoas hemiplégicas, e as Tabelas 6.3 e 6.4 a pessoas normais. Os dados exemplificados nas tabelas fazem parte de um conjunto de 48 sensores (24 em cada pé) que foram utilizados como dados de entrada em ambas as redes na fase de treinamento.

Tabela 6.1 - Exemplo de dados do pé esquerdo de pessoas hemiplégicas.

Sensor	Sensor	Sensor	Sensor	Sensor
14	15	16	17	18
0,5	0,52	0,48	0,2	0,02
0	0,04	0,41	0,45	0,25
0,53	0,76	0,19	0,16	0,05
0,05	0,35	0,43	0,31	0,19

Fonte: Freitas (2011).

Tabela 6.2 - Exemplo de dados do pé direito de pessoas hemiplégicas.

Sensor 14	Sensor 15	Sensor 16	Sensor 17	Sensor 18
0,5	0,05	0	0	0
0,23	0,05	0	0,07	0,15
0,41	0,36	1,51	0,26	0,25
0 0,5	0,14	0,76	0,26	0,5

Fonte: Freitas (2011).**Tabela 6.3** - Exemplo de dados do pé esquerdo de pessoas normais.

Sensor 14	Sensor 15	Sensor 16	Sensor 17	Sensor 18
0,2	0,23	0,26	0,19	0,03
0,51	0,46	0,31	0,26	0,17
0,07	0,33	0,17	0,14	0
0,27	0,38	0,35	0,22	0,07

Fonte: Freitas (2011).

Tabela 6.4 - Exemplo de dados do pé direito de pessoas normais.

Sensor 14	Sensor 15	Sensor 16	Sensor 17	Sensor 18
0,14	0,23	0,8	0,11	0
0,32	0,22	0,29	0,2	0,25
0,11	0,31	0,26	0,17	0
0,5	0,48	0,77	0,28	0,35

Fonte: Freitas (2011).

Nos resultados de ambas as redes, as análises dos profissionais da área de saúde estarão no item pessoas e a classificação das redes estarão no item classificação das tabelas dos subitens a seguir.

6.2 Rede Neural MLP

As classificações das pessoas estão na Tabela 6.5. O diagnóstico da rede neural capacita ao reconhecimento de quase todas as classificações das pessoas efetuadas por profissionais da área de saúde. A rede neural MLP forneceu os resultados mostrados na Tabela 6.5 (fase de diagnóstico).

Tabela 6.5 - Classificação da MLP: pessoas normais (0,8) e hemiplégicos (0,9).

Nº	PESSOAS	CLASSIFICAÇÃO	Nº	PESSOAS	CLASSIFICAÇÃO
1	0,8	0,8491	18	0,8	0,8121
2	0,8	0,7951	19	0,8	0,7881
3	0,8	0,8753	20	0,8	0,7791
4	0,8	0,8676	21	0,8	0,7836
5	0,8	0,8321	22	0,8	0,8157
6	0,8	0,7932	23	0,8	0,8388
7	0,8	0,8553	24	0,8	0,7969
8	0,8	0,8321	25	0,8	0,7823
9	0,8	0,8481	26	0,8	0,8147
10	0,8	0,7911	27	0,8	0,8331
11	0,8	0,7822	28	0,8	0,8421
12	0,8	0,8147	29	0,8	0,8181
13	0,8	0,8391	30	0,8	0,7989
14	0,8	0,7931	31	0,8	0,8278
15	0,8	0,8253	32	0,9	0,9354
16	0,8	0,8296	33	0,9	0,9355
17	0,8	0,8391	34	0,9	0,9354

Fonte: Freitas (2011).

6.3 Rede Neural ARTMAP Nebulosa

As análises e classificações das pessoas estão mostradas na Tabela 6.6. Na saída real da rede neural foi atribuída uma representação numérica de 1 para indicar pessoas normais e 0 hemiplégicas.

Tabela 6.6 - Classificação da ARTMAP Nebulosa: pessoas normais (1) e hemiplégicas (0).

Nº	PESSOAS	CLASSIFICAÇÃO	Nº	PESSOAS	CLASSIFICAÇÃO
1	Normal	1	18	Normal	1
2	Normal	1	19	Normal	1
3	Normal	1	20	Normal	1
4	Normal	1	21	Normal	1
5	Normal	1	22	Normal	1
6	Normal	1	23	Normal	1
7	Normal	1	24	Normal	1
8	Normal	1	25	Normal	1
9	Normal	1	26	Normal	1
10	Normal	1	27	Normal	1
11	Normal	1	28	Normal	1
12	Normal	1	29	Normal	1
13	Normal	1	30	Normal	1
14	Normal	1	31	Normal	1
15	Normal	1	32	Hemiplégico	0
16	Normal	1	33	Hemiplégico	0
17	Normal	1	34	Normal	1

Fonte: Freitas (2011).

Os resultados da Tabela 6.6 na coluna “pessoas” correspondem à análise feita pelos profissionais da saúde envolvidos neste trabalho, que apontaram o baixo grau de hemiplegia do paciente.

6.4 Discussão

A dificuldade encontrada na realização deste trabalho esteve relacionada ao número reduzido de amostras do grupo de indivíduos hemiplégicos. Esse grupo possui grau de comprometimento leve ou moderado, sendo alguns com pequena presença de padrão, pois realizam sessões de fisioterapia, hidroterapia ou hidroginástica há alguns anos. As pessoas desse grupo apresentavam marcha ceifante, uns em grau moderado e outros leve, dependendo do grau de comprometimento.

As redes puderam ser treinadas com os dados adquiridos pela plataforma para obter a habilidade de generalizar e fornecer as informações desejadas, no caso classificar pessoas normais (no contexto de nunca ter tido hemiplegia) de pessoas hemiplégicas.

A análise poderia ter sido mais precisa se o banco de dados de entrada fosse composto por um número maior de dados de entrada, o que forneceria para a rede neural mais subsídios para melhor discriminação das pessoas.

Os resultados da Tabela 6.5, referentes à saída, tentam corresponder à análise feita pelos profissionais da saúde envolvidos neste trabalho. Os resultados são quase todos equivalentes à classificação dos indivíduos com exceção dos números 3 e 4 que matematicamente aproximam-se de pessoas hemiplégicas e não normais. Isso é considerada uma pequena falha da rede neural MLP, pois o conjunto de hemiplégicos é muito pequeno e faz com que alguns indivíduos normais se aproximem da hemiplegia.

A rede neural ARTMAP Nebulosa apresenta a necessidade de padronizar a base de dados (de entrada e de saída), ou seja, entradas e saídas devem ser grandezas positivas, maiores que zero e inferiores a um, por agregarem os conceitos da lógica nebulosa à arquitetura ARTMAP e também necessitarem de um número maior de pessoas no banco de dados para obter uma maior precisão.

A ARTMAP Nebulosa, na fase de classificação, apresentou como normais todos os indivíduos normais informados (31) e dos 3 hemiplégicos ela classificou corretamente 2, pois o terceiro (pessoa Nº 34) possui um grau de hemiplegia muito baixo, ou seja, muito próximo da normalidade e a rede o classificou como normal, como mostrado na Tabela 6.6.

Os valores numéricos atribuídos aos dados de saída da ARTMAP Nebulosa se devem ao fato que a representação binária dos dados acelera o treinamento da rede neural. A rede neural foi, então, treinada e após ter sido efetuado o treinamento, a rede foi capaz de generalizar a partir de seu aprendizado.

A rede ARTMAP Nebulosa apresentou dificuldades na classificação dos indivíduos hemiplégicos, acarretados em função de termos trabalhado com um número muito pequeno de pessoas com hemiplegia que não apresentam um grau de hemiplegia acentuado.

A rede neural ARTMAP Nebulosa apresentou um treinamento mais rápido, preciso e estável em relação a rede MLP. Considerando o tempo de processamento, a rede neural ARTMAP Nebulosa se sobressai à rede MLP. Em relação ao índice de acertos as duas redes apresentaram desempenhos muito próximos. Porém, a aprendizagem feita através da rede

neural ARTMAP Nebulosa é muito parecida ao processo de aprendizagem do neurônio biológico. Portanto, ela tem a capacidade de aprender uma informação por vez. Se os conjuntos de dados não forem consistentes, ou seja, não apresentarem realmente a relação de hemiplegia suficiente para que ela consiga entender, os dados serão insuficientes para que ela consiga desta forma generalizar a situações não treinadas.

As redes neurais responderam ao aprendizado do mundo criado pelas pessoas hemiplégicas e normais, conseguindo identificar semelhanças ao aprendizado obtido.

Analisando o comportamento das duas redes neurais utilizadas, as falhas apresentadas pela rede MLP foi mais comprometedora do que a rede ARTMAP Nebulosa. O erro de classificar normais em hemiplégicos tem um valor significativo.

CAPÍTULO 7

7 CONCLUSÃO

As classificações obtidas através da rede neural MLP, com algoritmo retropropagação (*backpropagation*), e da rede neural ARTMAP Nebulosa ocorreram quase que plenamente de acordo com as classificações efetuadas por profissionais da área. Elas foram capazes de distinguir os pessoas normais dos hemiplégicos.

As habilidades de adaptação e de aprendizagem das redes neurais trabalhadas foram comprovadas com a utilização da plataforma de força desenvolvida no laboratório de sensores do Departamento de Engenharia Elétrica da UNESP – Campus de Ilha Solteira.

As características de desempenho das redes neurais, ou seja, rapidez de treinamento e flexibilidade de adaptação às diversidades topológicas, propiciam empregá-las para análises das classificações das pessoas e irão auxiliar os profissionais da saúde com respostas imediatas, a fim de diagnosticar os pacientes.

A duas redes neurais utilizadas apresentaram resultados satisfatórios. A rede neural ARTMAP Nebulosa obteve as respostas com grande rapidez e maior precisão do que a rede MLP, sendo que a primeira cometeu uma falha e a segunda duas em 34 amostras.

Ambas as redes conseguiram efetuar classificação de novos dados mesmo com o número pequeno de dados para o treinamento, comprovando assim que as redes neurais tem um futuro promissor na área de saúde.

Baseado no estudo realizado e na eficiência que as redes neurais apresentaram para a identificação e classificação dos indivíduos, propõe-se para continuidade dos trabalhos, realizar um número maior de medições em pacientes normais e, sobretudo em pacientes hemiplégicos. Assim, aumentar o banco de dados para ambas as redes e também, realizar o estudo e a análise de outras redes neurais comparando e verificando a eficiência para melhor quantificar e qualificar as tipologias dos pés.

Uma parte dos resultados obtidos nessa pesquisa foi apresentada no 22º Congresso Brasileiro de Engenharia Biomédica, CBEB 2010, realizado em Tiradentes – Minas Gerais – Brasil (FREITAS et al., 2010).

REFERÊNCIAS

- ANAGNOSTOPOULOS, G. C. **Novel approaches adaptive resonance theory for machine learning**. 2001. 190 f. Dissertation (Doctor), Department of Electrical Engineering, University of Central Florida, Orlando, 2001.
- BIENFAIT, M. **Os desequilíbrios estáticos: filosofia, patologia e tratamento fisioterápico**. São Paulo: Summus Editorial, 1995. p. 149.
- BOBATH, B. **Hemiplegia no adulto: avaliação e tratamento**. São Paulo: Manole, 1990.
- BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDEMIR, T. B. **Fundamentos de redes neurais artificiais**. Rio de Janeiro: Escola de Computação, 1998.
- BRAGA, A. P.; CARVALHO, A. C. P. L. F.; LUDEMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: LTC, 2000.
- CACHO, E. W. A.; MELO, F. R.; OLIVEIRA, R. Avaliação da recuperação motora de pacientes hemiplégicos através do protocolo de desempenho físico Fulg-Meyer. **Revista de Neurociências**. São Paulo. v.12, n.2, p. 94-102, 2004.
- CARPENTER, G. A.; GROSSBERG, S. A. Massively parallel architecture for a self-organizing neural pattern recognition machine. **Computer Vision, Graphics and Image Processing**, New York, v.37, n.1, p.54-115, 1987a.
- CARPENTER, G. A.; GROSSBERG, S. ART2: self-organizing of stable category recognition codes for analog input patterns. **Applied Optics**, New York, v. 26, n.23, p. 4919-4930, 1987b.
- CARPENTER, G. A.; GROSSBERG, S. The ART of adaptive pattern recognition by a self-organizing neural network. **Computer**, New York, v. 21, n.3, p.77-88, Março 1988.
- CARPENTER, G. A.; GROSSBERG, S. **Pattern recognition by self-organizing neural networks**. Massachusetts: The MIT Press, 1991.
- CARPENTER, G. A.; GROSSBERG, S.; REYNOLDS, J. H. ARTMAP: supervised realtime learning and classification of non-stationary data by a self-organizing. **Neural Network**, New York, v. 6, p. 565-588, 1991a.
- CARPENTER, G. A.; GROSSBERG, S.; REYNOLDS, J. H. ARTMAP: supervised real-learning and classification of non-stationary data by a self-organizing neural network. **Neural Network**, New York, v.4, n.5, p.565-588, 1991b.

CARPENTER, G. A.; GROSSBERG, S. **Pattern recognition by self-organizing neural networks**. Cambridge: The MIT Press, 1991c.

CARPENTER, G. A.; GROSSBERG, S. A.; MARKUZON, N.; REYNOLDS, J. H., ROSEN, D. B. Fuzzy artmap: a neural network architecture for incremental supervised learning of analog multidimensional maps. **Proceedings of IEEE Transactions on Neural Networks**, New York, v.3, p.698-713, 1992.

CARPENTER, G. A.; ROSS, W. D. ART-EMAP: a neural network architecture for object recognition by evidence accumulation. **IEEE Transactions on Neural Networks**, New York, v. 6, p. 805-818, 1995.

CARPENTER, G. A.; RUBIN, M. A.; STREILEIN, W. W. ARTMAP-FD: familiarity discrimination applied to radar target recognition. **Proceeding International Conference on Neural Network**, New York, v. 3, p. 1459-1464, 1997.

EGGERS, O. **Terapia ocupacional no tratamento da hemiplegia do adulto**. Rio de Janeiro: Colina, 1982.

ESTREMOTE, M. M. **Medição da descarga de peso na região plantar em pacientes normais e hemiplégicos utilizando plataforma de força**. 2010. 156 f. Dissertação (Mestrado) – Programa de Pós-Graduação em Engenharia Elétrica/ Departamento de Engenharia Elétrica, Universidade Estadual Paulista, Ilha Solteira, 2010.

FREITAS, R. L. B. **Plataforma de força para aplicações biomédicas**. 2008. 136 f. Dissertação (Mestrado) - Programa de Pós-Graduação em Engenharia Elétrica/ Departamento de Engenharia Elétrica, Universidade Estadual Paulista, Ilha Solteira, 2008.

FREITAS, L. P. S.; LOPES, M. L. M.; FREITAS, R. L. B.; CARVALHO, A. A.; TEIXEIRA, M. C. M.; SANCHES, M. A. A.; PONTES, W.; URBAN, M. F. R.; Discriminação entre Pacientes Normais e Hemiplégicos utilizando Plataforma de Força e Redes Neurais. In: CONGRESSO BRASILEIRO DE ENGENHARIA BIOMÉDICA- CBEB, 22., 2010, Tiradentes. **Congresso...** Tiradentes: [s.n.], 2010.

GOMÉS-SÁNCHEZ, E.; DIMITRIADIS, Y. A.; CANO-IZQUIERDO, J. M.; LÓPEZCORONADO, J. μ ARTMAP: use of mutual information for category reduction in Fuzzy ARTMAP. **IEEE Transactions on Neural Networks**, Oxford, v. 13, n.1, p. 58-69, 2002.

- GROSSBERG, S. Adaptive pattern recognition and universal encoding II: feedback, expectation, olfaction, and illusions, **Biological Cybernetics**, Boston, v. 23, p. 187-202, 1976.
- HAYKIN, S. **Neural networks: a comprehensive foudation**. 2. ed. Porto Alegre: Prentice Hall, 1998.
- HAYKIN, S. **Redes neurais: princípios e prática**. Porto Alegre: Bookman, 2001.
- KAPANDJI, I. **A fisiologia articular**. 2. ed. São Paulo: Manole, 1990.
- KOVACS, Z. L. **Redes neurais artificiais fundamentos e aplicações**, São Paulo: EDUSP., 1996. 174 p.
- LIMA, C. M.; LABIDI, S. **Introdução à inteligência artificial**. São Luiz: FAPEMA, 1999.
- MARCHIORI, S. C.; MINUSSI, C. R., LOTUFO, A. D. P. Rede neural ARTMAP nebulosa para análise de estabilidade transitória de sistemas de energia elétrica. **Revista da Sociedade Brasileira de Redes Neurais - Learning and Nonlinear Models**, Rio de Janeiro, v. 1, n. 1, p. 61-78, 2002.
- MARRIOTT, S.; HARRISON, R. F. A modified fuzzy ARTMAP architecture for the approximation of noisy mappings. **Neural Networks**, Sheffield, v. 8, n. 4, p. 619-641, 1995.
- McCULLOCH, W. W.; PITTS, W.A. Logical calculus of the ideas imminent in nervousactivity. **Bulletin of Mathematical Biophysics**, New York, v. 5, n. 2, p. 114-133, 1943.
- MENDES FILHO, E. F.; CARVALHO, A. C. P. L. **Tutorial introdutório sobre redes neurais artificiais**. São Paulo: Departamento de Ciências de Computação e Estatística - USP, 1997.
- URBAN, M. F. R.; SANCHES, M. A. A.; OLIVEIRA, B. M.; ESTREMOTE, M. M.; PONTES, W.; SANTOS, E. A.; ARAÚJO, A. J.; CAPPI, L. O. G.; FREITAS, L. P.S.; CARVALHO, A.C.; CARVALHO, A. A. Programa computacional para aquisição de dados de um sistema de medição de forças plantares. In: CONGRESSO BRASILEIRO DE ENGENHARIA BIOMÉDICA, CBEB, 22., 2010, Tiradentes. **Congresso...** Tiradentes: [s.n.], 2010.

VERZI, S. J.; HEILEMAN, G. L.; GEORGIOPOULOS, M.; HEALY, M. J. Boosting the performance of ARTMAP. In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS – IJCNN, 1998, Anchorage. **Proceedings...** Anchorage: IEEE, 1998. v.1, p. 396-401, 1998. 10.1109/IJCNN.1998.682299.

WASSERMAN, P. D. **Neural computing**: theory and practice: New York, Van Nostrand Reinhold, 1989.

WERBOS, P. J. **Beyond regression**: new tools for prediction and analysis in the behavioral sciences. 1974. 453 f. Thesis (Master), Harvard University, Harvard, 1974.

WIDROW, B.; LEHR, M. A. 30 years of adaptive neural networks: perceptron, madaline, and backpropagation. **Proceedings of the IEEE**, Winston, v. 78, n. 9, p. 1415-1442, 1990.

WILLIAMSON, J. R. Gaussian ARTMAP: a neural network for fast incremental learning of noisy multidimensional maps. **Neural Networks**, Boston, v. 9, n. 5, p. 881-897, 1996.