

UNIVERSIDADE FEDERAL DE SANTA CATARINA
CURSO DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

UTILIZANDO REDES NEURAIIS NO
RECONHECIMENTO DE PADRÕES CEFALOMÉTRICOS

Paulo Roberto Bertholdi

Dissertação apresentada ao
Curso de Pós-Graduação em Ciência da Computação
da Universidade Federal de Santa Catarina
como requisito parcial para a obtenção
do título de Mestre em Ciência da Computação

Florianópolis, novembro de 2002

UTILIZANDO REDES NEURAIIS NO RECONHECIMENTO DE PADRÕES CEFALOMÉTRICOS

Paulo Roberto Bertholdi

Esta Dissertação (Tese) foi julgada adequada para a obtenção do título de Mestre em Ciência da Computação Área de Concentração Sistemas de Conhecimento e aprovada em sua forma final pelo Programa de Pós-Graduação em Ciência da Computação.

Universidade Federal de Santa Catarina - Florianópolis, 31 de outubro de 2002

Prof. Fernando Álvaro Ostuni Gauthier, Dr.

Coordenador do Curso

Banca Examinadora

Prof. Paulo Sergio da Silva Borges, Dr.

Orientador

Prof. Walter Celso de Lima, Dr.

Prof. João Bosco da Mota Alves, Dr.

Prof. Luiz Fernando Jacinto Maia, Dr.

Oferecimento

A todos os pesquisadores, professores e profissionais que vislumbram a interdisciplinaridade como o único caminho para a evolução da ciência e do conhecimento humano.

Aos corajosos cientistas que não foram vencidos pelos interesses políticos, econômicos, ou pelo próprio ego.

Aos corpos sem família ou sobrenome que em vida por vezes recebiam contribuições e hoje nos laboratórios anatômicos contribuem com a ciência e a humanidade.

Agradecimentos

A palavra interdisciplinaridade é hoje parte do meu vocabulário graças a pessoas que direta ou indiretamente estimulam minha atitude polivalente. Sou grato...

...ao meu pai um historiador, poeta, filósofo e poliglota, pessoa de invejável conhecimento.

...a minha mãe, pessoa de fibra, fé e esperança, professora aposentada que encontra no trabalho sua fonte de juventude.

...aos professores Renato Sabbatini e Moacyr Menendes da USP e UNICAMP, componentes dos grupos de pesquisa de Tecnologia e Computação em Saúde, por endossar meu ingresso nessa área.

...ao professor Galvão - UFB, dentista, médico, antropólogo e matemático, espelho para o meu trabalho.

...ao professores Walter Lima - UFSC, médico e engenheiro, pelo privilégio de avaliar meu trabalho.

...aos professores João Bosco Alves e Jacinto Maia - UFSC, pelo enriquecimento nas áreas de ciência da computação, vida e piada.

...as Universidades de Cape Town, Cambridge, USP, UNICAMP, UNOESC e outras centenas de entidades e pessoas que propiciaram a base de conhecimento para este trabalho.

...aos amigos e colegas da Ciência da Computação, Simão, Murakami, Rosa Sprigcio, Luciane e outros.

...aos colegas professores da Odontologia, Adgar Bittencourt, Deise Bortoluzzi, Avrun Kotliarenko, Cláudia Wesoloski, Fabiola Iagher, Jovani Steffani, Dulce Zanini e João Manes por acreditarem no meu trabalho como pesquisador e professor.

O coordenador que apoiou o ingresso de um dentista no curso foi enfático em dizer que muitos mestrados da área da computação desistiriam. Isto realmente aconteceu, mas ao fim dessa jornada lá estavam o dentista e o professor concluindo um trabalho de inteligência artificial aplicada a cefalometria.

...ao ex-coordenador, professor e orientador Paulo S. S. Borges, um dos profundos conhecedores de I.A. neste país, sinceramente obrigado.

Sumário

LISTA DE FIGURAS	VIII
LISTA DE QUADROS	X
LISTA DE REDUÇÕES	XI
RESUMO	XII
ABSTRACT	XIII
1 INTRODUÇÃO.....	1
1.1 CONSIDERAÇÕES INICIAIS.....	1
1.2 MOTIVAÇÃO.....	1
1.3 OBJETIVOS.....	2
1.3.1 <i>Objetivo Geral</i>	2
1.3.2 <i>Objetivos Específicos</i>	2
1.4 ESTRUTURA DO TRABALHO.....	2
2 O PROBLEMA DE CLASSIFICAÇÃO DO CRÂNIO ÓSSEO HOMINÍDEO.....	4
2.1 CEFALOMETRIA.....	5
2.1.1 <i>Definição</i>	5
2.1.2 <i>A Importância e Áreas de Utilização</i>	5
2.1.3 <i>Histórico</i>	6
2.2 ANTROPOLOGIA FÍSICA.....	9
2.3 CARACTERÍSTICAS ANATÔMICAS.....	10
2.3.1 <i>Crescimento Craniano</i>	11
2.3.2 <i>Idade Biológica</i>	12
2.3.3 <i>Diferenças Sexuais</i>	13
2.3.4 <i>Tipos Geométricos – Raciais</i>	14
2.3.5 <i>Anomalias</i>	17
3 REDES NEURAIS.....	18
3.1 DEFINIÇÃO.....	18

3.2 HISTÓRICO.....	18
3.3 PARADIGMAS.....	20
3.4 CAPACIDADES E RESTRIÇÕES.....	20
3.5 APLICAÇÕES.....	21
3.6 A CAPACIDADE DE RECONHECER PADRÕES.....	23
3.6.1 <i>O conhecimento do Especialista em Anatomia Cefalométrica.....</i>	23
3.6.2 <i>A aprendizagem da Rede Neural.....</i>	24
3.7 ANALOGIA NEUROBIOLÓGICA.....	25
3.8 TOPOLOGIA.....	28
3.9 PROCESSO DE APRENDIZAGEM.....	32
3.10 ALGORITMO DE APRENDIZADO.....	35
3.11 PROCESSO DE TREINAMENTO DA REDE NEURAL.....	38
4 UTILIZANDO REDES NEURAIS NO RECONHECIMENTO DE PADRÕES CEFALOMÉTRICOS.....	41
4.1 TÉCNICAS PROPOSTAS POR OUTROS AUTORES.....	41
4.2 TÉCNICA UTILIZANDO REDES NEURAIS.....	52
4.2.1 <i>Metodologia de obtenção de dados cefalométricos.....</i>	54
4.2.2 <i>Pré-Processamento dos Dados.....</i>	58
4.3 SELEÇÃO DOS CONJUNTOS DE TREINAMENTO E TESTE.....	58
4.4 CONFIGURAÇÃO DA REDE NEURAL.....	59
4.4.1 <i>Seleção do Paradigma Neural.....</i>	59
4.4.2 <i>Determinação da Topologia.....</i>	59
4.4.3 <i>Determinação dos Parâmetros do Algoritmo e das Funções de Ativação.....</i>	59
4.5 TREINAMENTO DA REDE NEURAL.....	60
4.6 TESTE DA REDE NEURAL.....	60
4.7 ANÁLISE DO DESEMPENHO DA REDE NEURAL.....	61
5 CONCLUSÕES E RECOMENDAÇÕES.....	67
5.1 CONCLUSÕES.....	67
5.2 LIMITAÇÕES DA PESQUISA.....	67

5.3 TRABALHOS FUTUROS.....	68
6 REFERÊNCIAS BIBLIOGRÁFICAS.....	69

Lista de figuras

Figura 01 - Visão errônea de um Neandertal	5
Figura 02 - Visão correta de um Neandertal	5
Figura 03 - Primeiros estudos métricos da cabeça - Leonardo da Vinci	6
Figura 04 - Plano de Camper	7
Figura 05 - Cefalometria após a descoberta dos raios x	8
Figura 06 - Estudo Cefalométrico em Crânios de Sambaquis	9
Figura 07 - Estudo Cefalométrico em Crânios de Sambaquis	9
Figura 08 - Crescimento Craniano Comparado ao Facial	11
Figura 09 - Processo de ossificação (Suturas Visão Externa)	12
Figura 10 - Processo de ossificação (Suturas Visão Interna)	12
Figura 11 - Pontos cefalométricos - Crânio Feminino	13
Figura 12 - Pontos cefalométricos - Crânio Masculino	13
Figura 13 - Plano horizontal do crânio	15
Figura 14 - Plano lateral do crânio	15
Figura 15 - Plano posterior do crânio	16
Figura 16 - Plano frontal do crânio	16
Figura 17 - Plano fronto-nasal do crânio	17
Figura 18 - Reconstrução realista da estrutura crânio-facial de “Luzia”	23
Figura 19 - Áreas neuronais específicas visão, motor, etc..	26
Figura 20 - Neurônio biológico	27
Figura 21 - Neurônio artificial	28
Figura 22 - O primeiro modelo de neurônio artificial	29
Figura 23 - Rede Perceptron	29
Figura 24 - Redes ADALINE / MADALINE	30
Figura 25 - Função ou-exclusivo (XOR)	30
Figura 26 - Camadas intermediárias	31
Figura 27 - Neurônio em atividade	32
Figura 28 - Treinamento do Perceptron	34
Figura 29 - Funções de ativação	34

Figura 30 - Mínimo global - Exemplo de superfície de erro - backpropagation.	36
Figura 31 - Esquema de treinamento Backpropagation	37
Figura 32 - Craniômetro de Galvão	43
Figura 33 - Pontos e reparos anatômicos localizados no crânio hominídeo	52
Figura 34 - Pontos e reparos anatômicos - Homo Sapiens	52
Figura 35 - Pontos e reparos anatômicos - Neandertal	52
Figura 36 - Reconhecer padrões não importando o objeto de estudo	53
Figura 37 - Cefalometria do crânio masculino	55
Figura 38 - Grupo racial	56
Figura 39 - Idade aproximada	57
Figura 40 - Análise do Desempenho da Rede Neural	66

Lista de quadros

Quadro 01 - Cérebro humano versus computador	25
Quadro 02 - Neurocomputador versus computador convencional	26
Quadro 03 - Neurocomputador versus computador convencional	26
Quadro 04 - Distâncias cefalométricas	41
Quadro 05 - Pontos cefalométricos	44
Quadro 06 - Distância Glabelo – Occipital	44
Quadro 07 - Distância Básio-Násio	45
Quadro 08 - Distância Básio-Próstio	45
Quadro 09 - Distância Próstio-Násio	45
Quadro 10 - Distância Bi-zigomática	46
Quadro 11 - Distância MAE/ENA	46
Quadro 12 - Distância MAE/L	46
Quadro 13 - Aspecto qualitativo da Glabela	47
Quadro 14 - Aspecto qualitativo da Apófise Mastóidea	47
Quadro 15 - Quadro comparativo de acertos por sexo	48
Quadro 16 - Quadro comparativo de acertos totais de crânios examinados	49
Quadro 17 - Casos em que os dois métodos falharam no diagnóstico do sexo	49
Quadro 18 - Determinação do Sexo	55
Quadro 19 - Determinação do Grupo Racial	56
Quadro 20 - Determinação da Idade Aproximada	57
Quadro 21 - Critérios de análise do desempenho da Rede Neural	61
Quadro 22 - Análise do desempenho da Rede Neural - 1	62
Quadro 23 - Análise do desempenho da Rede Neural - 2	63
Quadro 24 - Análise do desempenho da Rede Neural - 3	64
Quadro 25 - Análise do desempenho da Rede Neural - 4	65
Quadro 26 - Análise do desempenho da Rede Neural - 5	65

Lista de reduções

G - Glabela

MAE - Meato Acústico Externo

ENA - Espinha Nasal Anterior

L - Lâmbda

N - Násio

TSM - Trígono Supra Meático

IM - Insisura Mastóide

APM - Ápice do Processo Mastóideo

I - Ínio

Ee - Eurio esquerdo

Ed - Eurio direito

ML - Metalâmbda

BA - Básio

B - Bregma

P - Próstio

Me - Malar esquerdo

Md - Malar direito

LN - Largura Nasal

GO - distância glabela-occipital

BN - distância básico-násio

BZ - distância bizigomática

BP - distância basio-próstio

PN - distância próstio-násio

AM - Apófise Mastóidea

RESUMO

A Inteligência Artificial tem sido um dos principais campos de estudo na área da Ciência da Computação tentando resolver problemas de difícil solução. Todos os problemas são difíceis até que sua solução seja conhecida (**Fogel, 1995**). Os métodos de abordagem de problemas de difícil solução encontram na Inteligência Artificial respostas satisfatórias através de paradigmas como os modelos conexionistas baseados na estrutura neuronal do cérebro humano. As Redes Neurais surgiram com o intuito de obter resultados satisfatórios comparados aos sistemas especialistas, que falham em área de competência não restrita. Essa característica é imprescindível quando tratamos problemas voltados ao âmbito biológico, pois é preciso interagir com o meio, reconhecer padrões, adaptar-se e estabelecer processos indutivos e dedutivos.

A Ciência da Computação tem propiciado a evolução do conhecimento na área de Ciência Biológica e da Saúde. Citando pesquisas como o Projeto Genoma, visualizamos a Ciência da Computação não apenas como fator auxiliar, mas sim como fator limitante no desenvolvimento destas pesquisas. Isso têm direcionado grande número de trabalhos de defesa de tese voltados para a área de Ciência Biológica e da Saúde objetivando a aplicação de Inteligência Artificial em processos de classificação e diagnóstico, onde os métodos convencionais falham ou a precisão não alcança um valor de confiança suficiente.

A proposta deste trabalho é utilizar as Redes Neurais como ferramenta no processo de classificação cefalométrica de um indivíduo. A Cefalometria utiliza métodos estatísticos convencionais para obtenção destes resultados, estudando um universo de indivíduos restritos a áreas geopoliticamente isoladas ou com pouco cruzamento racial. A aplicação de Redes Neurais como Método de Classificação Cefalométrica pode aproximar a precisão dos resultados a um valor de confiança suficiente comparada aos métodos atuais.

Palavras-chave: Inteligência Artificial, Redes Neurais, Cefalometria, Identificação de um indivíduo.

ABSTRACT

Artificial Intelligence has been one of the main matters in Computational Science area that tries to find solutions for difficult problems or those ones whereas is impossible to be solved. All the problems are difficult until their solution be known. **(Fogel 1995)**. Approaching methods for difficult problems can get answers by paradigms like connexionistic models based on human brain neuronal structures. Neural Networks appeared intending to obtain satisfactory results compared to Specialist System that fails in unrestricted competence area. This characteristic is needful when we work out in problems pertaining to biological scopes causer we need to interact with the environment, recognizing patterns and adapting ourselves to establish inductive and deductive process.

Computational Science has been providing knowledge evolution in Biological Science and Health area. Mentioning researches such as Genome Project we foresee Computational Science not only as an auxiliary factor but also a limitable one for these researches development. So this has been guiding a great number of works for thesis presentations involving Biological Science and Health areas aiming the use of Artificial Intelligence in diagnosis and classification processes whereas conventional methods or precision does not reach enough reliability.

Cephalometry, an Biological Science area for studying human cranial measures, uses conventional statistical methods to obtain anthropomorphic characteristics studying an universe of individuals, restricted to an isolated geopolitical areas, or with few racial crossing. The proposal for using Neural Network as a Cephalometric classification method aims, in this work, to approach results in precision and accuracy an enough reliable value compared to the actual methods.

Keywords: Artificial Intelligence, Neural Networks, Cephalometries, An individual's identification.

1 Introdução

1.1 Considerações Iniciais

A aplicação da ciência da computação tem contribuído fortemente para o avanço das pesquisas nas áreas das ciências biológica e da saúde, onde algumas das mais importantes pesquisas seriam retardadas ou até abandonadas se não fossem utilizados meios como processamento de informações e cálculos através do computador. Vários dos principais benefícios ocorrem em processos como o mapeamento genético humano, a automatização de laboratórios, a modelagem de estruturas químicas, as análises de diagnósticos e a conexão entre bancos de dados de centros de pesquisa.

A crescente disponibilidade de informações é fundamental na área das ciências biológica e da saúde, sendo este o propósito do presente trabalho que está contido dentro deste escopo abrangente e, em particular, trata da pesquisa voltada à identificação de crânios hominídeos através de mensurações.

O problema da metodologia de classificação cefalométrica vem sendo tradicionalmente abordado através de métodos estatísticos e cognitivos, estando, contudo sujeita a uma alta taxa de erros, pois a dinâmica de cruzamento entre raças e os movimentos populacionais alteram constantemente os padrões de classificação tradicionais, gerando resultados incorretos.

Deve-se reconhecer que o esforço em compreender o mundo na forma dinâmica, como os seres vivos, é muito maior do que na forma estática, sendo indispensável aos novos pesquisadores um conhecimento mais abrangente envolvendo todas as áreas científicas. Este é o futuro da ciência.

1.2 Motivação

A necessidade de resultados mais acurados na identificação de um crânio hominídeo é de grande importância para estudos de movimentos populacionais, de desenvolvimento crânio-encefálico, da medicina, da odontologia e da antropologia, o que tem estimulado o trabalho de especialistas em cefalometria de vários centros de pesquisas mundiais. Observando que os métodos de identificação atualmente utilizados são resultantes dos estudos na área de matemática estatística, onde podem ocorrer erros

inaceitáveis durante o processo de classificação de um crânio e a generalização de métodos não adaptáveis para os diferentes povos do planeta.

Especialistas em cefalometria ou mesmo profissionais de área de saúde com bom conhecimento de características cranianas visualmente observáveis, são capazes de identificar o sexo e a idade aproximada de um crânio com relativa margem de acerto. O conhecimento destes profissionais pode ser comparado à capacidade de aprendizagem de uma rede neural, que poderá obter resultados mais próximos do real.

1.3 Objetivos

1.3.1 Objetivo Geral

Classificar cefalometricamente crânios ósseos hominídeos utilizando redes neurais como ferramenta mais adequada comparativamente aos métodos antropológicos atualmente empregados.

1.3.2 Objetivos Específicos

Atingir maior precisão no processo de classificação do crânio hominídeo.

Demonstrar a confiabilidade do método de classificação utilizando redes neurais em comparação aos métodos baseados em fórmulas estatísticas.

Propor o desenvolvimento de programas para determinação cefalométrica de um crânio baseado em redes neurais.

1.4 Estrutura do Trabalho

O capítulo um faz uma introdução ao tema tratado, definindo os objetivos gerais e específicos a serem alcançados e a metodologia utilizada.

O capítulo dois aborda o problema de classificação do crânio ósseo hominídeo e como tem sido tratado na visão dos especialistas da área, define o que é cefalometria sua importância, área de utilização e histórico, posteriormente conceitua antropologia física e finalmente descreve as características anatômicas do crânio hominídeo de forma a acrescentar conhecimentos da área biológica a área de ciência da computação.

O capítulo três leva a compreensão sobre redes neurais, conceitua analogia neurobiológica e redes neurais, analisa a capacidade de reconhecimento de padrões de

um especialista em anatomia cefalométrica e descreve o processo de aprendizagem de uma rede neural.

O capítulo quatro compara as técnicas de classificação cefalométrica propostas por outros autores e a técnica de classificação cefalométrica utilizando redes neurais, observando as vantagens e restrições pertinentes. Descreve a complexidade da metodologia de obtenção de dados cefalométricos, iniciando o processo de eleição do método de reconhecimento de padrões e do algoritmo de aprendizagem, bem como os processos de treinamento, interrogação e análise da rede neural e os resultados obtidos.

O capítulo cinco observa as conclusões e recomendações sobre o trabalho apresentado, as limitações da pesquisa realizada e os trabalhos que futuramente poderão ser desenvolvidos para auxiliar os estudos de redes neurais aplicadas na área biológica e da saúde.

2 O problema de classificação do crânio ósseo hominídeo

Mesmo quando se fala em determinar cefalometricamente um indivíduo, não se deve esquecer que a classificação do crânio ósseo hominídeo baseia-se em observações estatísticas e que por isto mesmo, não há nenhum método antropológico que seja infalível, ou 100% correto. Portanto admite-se sempre uma margem de erro que deve ser controlada e prevista. **GALVÃO (1998).**

O problema de classificação do crânio ósseo hominídeo reduziu-se com a melhoria dos métodos de análise estatística empregados e conhecimentos de fisiologia e anatomia humana. Foram desenvolvidos inclusive programas de classificação de crânios empregados na área de medicina legal (ANTROPOL) com o objetivo de acelerar os cálculos dos métodos desenvolvidos e facilitar a interface com o usuário.

Os processos de classificação fazem uso desses métodos e conhecimentos com o objetivo claro de obter uma classificação a mais próxima possível do real. Destacam-se os trabalhos de: **PEIXOTO (1931); GILES & ELLIOT (1963); GOMEZ (1967); FÁVERO (1973); ALMEIDA JR. & COSTA JR. (1974); CHIARUGI apud ALMEIRA JR. & CAMPS (1976); BONNET (1978); PEREIRA & ALVIM (1979); GALVÃO (1994).**

Existem atualmente duas metodologias de obtenção de dados para classificar um crânio ósseo hominídeo:

Os métodos qualitativos são baseados em observações dos acidentes anatômicos através de suas formas e aspectos puramente morfológicos, contudo devido a alterações naturais, patológicas e mesmo do observador, esta metodologia está mais sujeita a erros.

Os métodos quantitativos são baseados em mensurações numéricas e objetivas, que são submetidas a uma análise estatística que, a depender da amostra e do objetivo podem ser feitas por vários métodos: análise de função discriminante, regressão logística, etc...

No entanto os estudos cefalométricos restringem-se a populações com pouco ou nenhum cruzamento racial os resultados obtidos são satisfatórios, mas como o movimento e o cruzamento de raças é dinâmico a margem de erro tende a aumentar e os métodos não são auto-adaptáveis ou não acumulam novos parâmetros de conhecimento (processo de aprendizagem).

2.1 Cefalometria

2.1.1 Definição

Cefalometria é o estudo das medidas e determinação de pontos e reparos do crânio humano através de radiografia ou craniometria.

2.1.2 Importância e Áreas de Utilização

A necessidade de estudos aprofundados sobre cefalometria e craniometria se torna evidente em situações onde resultados equivocados ou com pouca base de fundamentação, levam a interpretações errôneas e por vezes absurdas. Na figura (**Fig.1**) observa-se a ilustração do esqueleto neandertal de Chapelle-aux-Saints descoberto na França em 1908, e publicado no Illustrated London New com o seguinte título: *An accurate reconstruction of the prehistoric cave man whose skull was found in the Department of Correze.*



An accurate reconstruction
of the Prehistoric Cave Man

Figura 1

Visão errônea de um neandertal



Figura 2

Visão correta de um neandertal

O erro de reconstrução de um neandertal se torna obvio através da figura (**Fig.2**) desenhada em por **Jay Matternes (1981)** para um trabalho de ilustração científica, com os atuais conhecimentos de cefalometria e craniometria. Destaca-se também a palavra

“*accurate*” (acurada), que tem, de forma enganada, o sentido de “precisão”, tornando-se inadequada para a interpretação de leitores com conhecimento científico.

Conclui-se que a necessidade de identificação de um crânio através de métodos que obtenham resultados mais acurados direciona o enriquecimento de informações em áreas como:

- antropologia, na identificação de grupos evolutivos e classificação dos mesmos.
- medicina, na identificação para fins forenses, alterações genéticas e de crescimento craniano.
- odontologia, na identificação para fins forenses, estudo do crescimento crânio-facial, ortodontia.
- movimentos populacionais, no estudo dos grupos étnicos e povoamento do planeta.

2.1.3 Histórico

Ainda que não usasse medidas, **HIPÓCRATES (460-375 a.C.)**, pioneiro da antropologia física, deixou numerosas descrições de variações na forma dos crânios, mas parece caber a **Leonardo da Vinci (1452-1519)** os primeiros estudos métricos da cabeça, estabelecendo proporções entre linhas e segmentos (**Fig.3**).



Figura 3

Os primeiros estudos métricos da cabeça - Leonardo da Vinci

Posteriormente **Pieter Camper (1780)** descreve o ângulo facial formado pela intersecção do Plano de Camper (que passa pelo centro do meato acústico externo e pela base do nariz) com a linha facial (tangente à parte mais proeminente do osso frontal). Dois anos após a morte de Pieter Camper, é publicado o seu célebre trabalho “Dissertação sobre as variantes naturais da fisionomia”. O ângulo facial, de acordo com Camper, tem para o europeu 80 graus; para o negro 70 graus; para o orangotango 58 graus; para o macaco 42 graus.




Figura 4
Plano de Camper

Na Alemanha, em München (1877) e Berlin (1880), é tentado, sem resultados, estabelecer-se um método comum para a observação dos crânios. Somente no XIII Congresso Geral da Sociedade de antropologia Alemã (realizado em Frankfurt-am-Maine em 1882) é definitivamente aprovado o **Plano de Von Lhering** e aceito, universalmente, como plano de orientação do crânio. Todas as observações e descrições do crânio passaram a serem feitas na suposição de que o crânio está com este plano na horizontal. O plano tomou o nome de **Plano Horizontal de Frankfurt** que passa pela borda superior e externa dos meatos acústicos externos, direito e esquerdo, e pelo ponto mais baixo na margem da órbita esquerda.

A cefalometria radiográfica tem seu marco inicial imediatamente após a descoberta dos Raios X, por **Wilhelm Conrad Röntgen (1895)**. Ao nascer, herdava das artes e da craniometria um valioso acervo de conhecimentos.

BJÖRK & WELCKER (1896), um ano após a descoberta dos Raios X, recomendam as radiografias da cabeça para estudar o perfil ósseo, e **BERGLUND (1914)**, relaciona o perfil ósseo com o perfil tegumentar.

PACINI (1921) imobiliza a cabeça do paciente com ataduras de gaze, toma radiografias com o plano sagital paralelo à película radiográfica, usa a distância de dois metros entre fonte geradora de Raios X e a película. Em 1922 publica *Röntgen Rays - Anthropometry of the skull*, onde propõe a transferência dos pontos craniométricos usados na antropologia para a radiografia e posteriormente estuda através deste material o desenvolvimento, classificação e desvios da normalidade na estrutura do crânio.




Figura 5

Cefalometria após a descoberta dos Raios X

HOFRATH publica em junho de 1931 na Alemanha, um trabalho considerado clássico na literatura mundial utilizando um Cefalostato de Korkhaus, no qual introduz modificações, descrevendo minuciosamente a sua técnica radiográfica e análises cefalométricas.

Dentre muitos se destaca o primeiro trabalho publicado no Brasil sobre cefalometria computadorizada de que se tem notícia, **SALVEGO (1981)** “**Análise cefalométrica por computador**”, Tese de Mestrado, Faculdade de Odontologia de Piracicaba, UNICAMP, SP.

2.2 Antropologia física

Pela definição de **Fróes da Fonseca (1929)** e **Roquette Pinto (1953)**, “A antropologia é a biologia comparativa dos grupos humanos, encarados do ponto de vista do sexo, da idade, da constituição e da raça”.

Entre as várias divisões da antropologia enfoca-se nesse trabalho a antropotipologia que estuda os tipos constitucionais, o sexo, a idade, e as características individuais e a antropometria que através das medidas, ângulos e projeções das diferentes partes do corpo ou das suas características mensuráveis fornecem as informações de identificação às áreas de utilização.

A arqueologia no Brasil realmente não é muito divulgada, porém, importantes descobertas foram realizadas em nosso território como o crânio pertencente à mulher mais antiga da América datada em 11.500 anos e o estudo de craniometria radiográfica em população pré-histórica do litoral meridional brasileiro.

Destaca-se esta segunda como uma das mais significativas pesquisas morfológicas realizadas em populações pré-históricas do Brasil, através do material ósseo humano exumado nas lapas e abrigos sob-rochas da área arqueológica de Lagoa Santa (MG) e nos sambaquis e acampamentos de coleta do litoral sul-sudeste, cognominados por **LACERDA (1985)** como "HOMEMS DO SAMBAQUI" (**Fig. 6-7**).



Figura 6




Figura 7

Estudo cefalométrico em crânios de Sambaquis

Através da mesma metodologia cefalométrica utilizada na comparação de outros grupos pré-históricos brasileiros, 29 crânios de indivíduos adultos, incluindo material procedente dos acervos Museu do Sambaqui de Florianópolis (6 masculinos e 2 femininos), foram radiografados em norma lateral, a uma distância de 1,5 metros, pelo método usual em Cefalometria Radiográfica, **PEREIRA & COL. (1984)**.

As grandezas craniométricas foram medidas com régua milimetrada e transferidor com aproximação de 0,5mm e 0,5⁰ respectivamente. Foram utilizadas as análises de **TWEED (1964)**, **STEINER (1953)**, **INTERLANDI (1971)** e o ângulo "Y" de **DOWNS (1948)** onde constataram nas amostras, características de populações caucasóides e índios lenguas, do Paraguai.

2.3 Características anatômicas

As características volumétricas e medidas de reparos anatômicos observados na antropometria são de maior relevância quando se estuda a craneometria e ou cefalometria. Os resultados das características do crânio são os principais dados para um bom anatomista definir com alguma margem de erro o sexo, idade e tipo geométrico-racial.

Alguns pontos e reparos anatômicos serão indicados nas figuras relacionadas aos textos a seguir com o objetivo de orientar sua localização a pessoas de outras áreas científicas.

2.3.1 Crescimento Craniano

Os estudos relativos ao crescimento craniano do homem atual demonstram, que ao nascer, o comprimento total do crânio é de 60 a 65% do seu tamanho final. Aos 2 ou 3 anos é de cerca de 85% e aos 5 ou 7 anos é de 90% comparado ao crânio adulto. O crescimento ósseo da face se estende por muitos anos e sofre alterações mesmo acima dos 80 anos de forma randômica, principalmente na reabsorção óssea do processo alveolar da maxila e mandíbula e distorção da mandíbula.

A escolha da região craniana para este trabalho é justificada por duas razões, o crescimento craniano é bem menos alterado do que o crescimento facial (**Fig. 8**) e que a região craniana nos estudos de necropsia e de fósseis humanos está geralmente melhor preservada que a região facial.



Figura 8

Volume craniano aos 7 anos semelhante ao adulto.

2.3.2 Idade biológica


As suturas são articulações onde as margens contíguas dos ossos são unidas por uma fina camada de tecido fibroso (**CHARLES MAYO GOSS, A.B., M.D.**).

A observação das suturas cranianas apresenta uma forma de avaliação razoável quando efetuada cuidadosamente para obter o cálculo aproximado da idade biológica do indivíduo

Com o passar do tempo formam-se interdigitações atravessadas por pontes de tecido ósseo. Este processo de ossificação é lento e ocorre com certo padrão, em épocas diferentes da vida, mas guardando certa constância, de forma tal que as suturas coronária, sagital e lambdóide podem ser divididas cronologicamente.


A ocorrência de equívocos ou dubiedades é grande, uma vez que em 30% dos casos, não há coincidência entre os valores etários calculados pelo apagamento das suturas cranianas, e a idade real do indivíduo (**GALVÃO apud BONNET**).

A amplitude de erro é em média dez anos e, às vezes, até maiores e que não se consegue precisar. Apesar das dificuldades anteriormente citadas este trabalho propõe que com uma base de dados maior para treinamento da rede neural esta margem de erro diminuirá. Basicamente o processo de ossificação em relação à idade biológica é apresentado na figura abaixo (**Fig. 9-10**).



Suturas Visão Externa

Figura 9



Suturas Visão Interna

Figura 10

2.3.3 Diferenças sexuais

Até a puberdade há pequena diferença entre o crânio masculino e feminino. O crânio adulto feminino é em geral mais leve e menor, e sua capacidade é cerca de 10% menor que a do masculino. No crânio feminino as cristas musculares, locais de inserção muscular, não são tão marcadas e a **G** (Glabela), Arcos Superciliares, Apófises Mastóides são menos proeminentes. As distâncias entre o **MAE**(Meato Acústico Externo) e **ENA**(Espinha Nasal Anterior), **MAE** e **L**(Lâmbda), **MAE** e **G**, **MAE** e **N** (Násio), **TSM**(Triângulo Supra Meático) e **IM**(Incisura Mastóide), **MAE** e **APM**(Ápice do Processo Mastóideo) e **MAE** e **I**(Ínio) são relativamente menores no sexo feminino (Fig. 11-12).

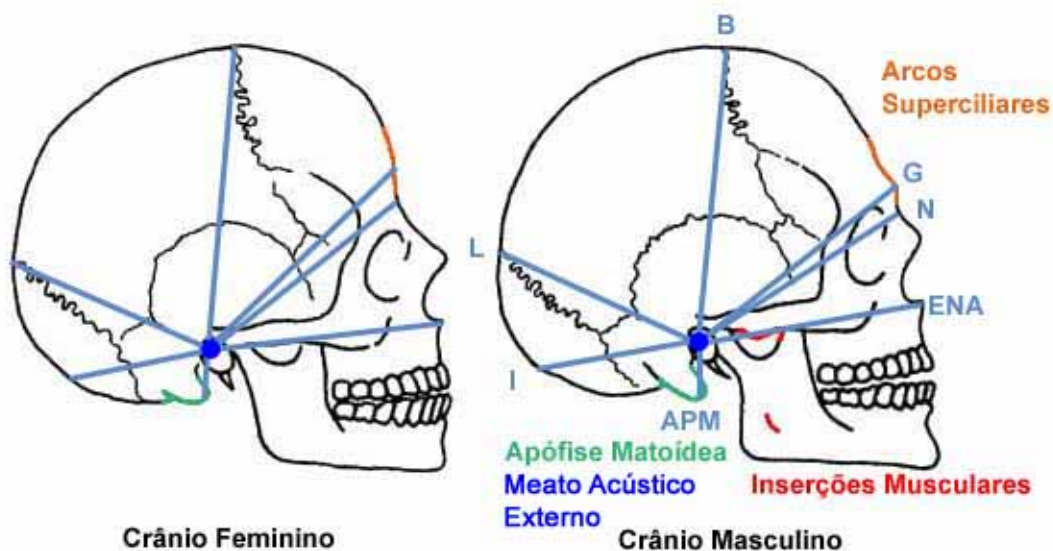


Figura 11

Figura 12

Pontos cefalométricos e reparos anatômicos

2.3.4 Tipos Geométricos – Raciais

O estudo da diversidade genética das populações humanas ocupa um lugar singular, na medida em que não visa um controle, mas conhecer. Ao contrário das concepções antigas, ele revela que quase todas os genes estão presentes em todas as populações, e que o que varia é apenas a frequência desses genes. Isso significa que a estrutura demográfica é contínua em todo o planeta, sem limites demográficos ou biológicos nítidos. “A única explicação para essa semelhança de repertório dos genes é a de uma origem comum há relativamente pouco tempo, e a existência de uma população também comum, há mais de cem mil anos, que provavelmente colonizou o conjunto do planeta” **PITTE (1998, Museu do Homem, Paris-França).**

Após a movimentação das massas populacionais através do desenvolvimento dos meios de transporte, houve um aumento da miscigenação e, hoje, constitui num caldeirão de misturas de populações. A cor da pele e dos cabelos, a forma do nariz e das maçãs do rosto não significam muito no plano genético. Os melanésios na Nova Caledônia, Oceania, se assemelham bastante fisicamente aos bantos da África; no entanto, sob o ponto de vista genético, são grupos humanos os mais distantes entre si. Por outro lado, os coreanos e os turcos, que vivem a mais de 10.000km de distância e que não se assemelham fisicamente, possuem 85% de seus genes em comum, os indianos e tunisianos possuem 72% e os japoneses e índios do Amazonas possuem 65% dos genes em comum.

As diferenças raciais encontradas teriam como um dos principais fatores o isolamento geográfico e por consequência pode-se definir apenas alguns grupos bem anteriores ao período de movimentação das massas populacionais. A classificação mais empregada é aquela que reconhece três “Troncos Raciais”, ou “Raças Maiores”: Mongolóide, Caucásóide e Negróide. **VESENTINI; DOMENECH; PADILHA & BOLIVAR (1996)**

As classificações raciais pelas dificuldades já apresentadas são determinadas pelas características geométricas do crânio.

No Plano Horizontal, a largura máxima com o comprimento máximo do crânio representado pela fórmula **Índice Horizontal** = $(Ee-Ed/G-ML) \times 100$ onde **Ee**(Eurio esquerdo), **Ed**(Eurio direito), **G**(Glabela), **ML**(Metalâmbda): Doliocrânio, Mesocrânio, Braquicrânio (**Fig. 13**).




Figura 13

Plano horizontal do crânio

No Plano Lateral, a altura máxima com seu comprimento máximo representado pela fórmula **Índice Lateral** = $(BA-B/G-ML) \times 100$ onde **BA**(Básio), **B**(Bregma), **G**(Glabela), **ML**(Metalâmbda): Hipsicrânio, Mesocrânio, Platicrânio (**Fig. 14**).

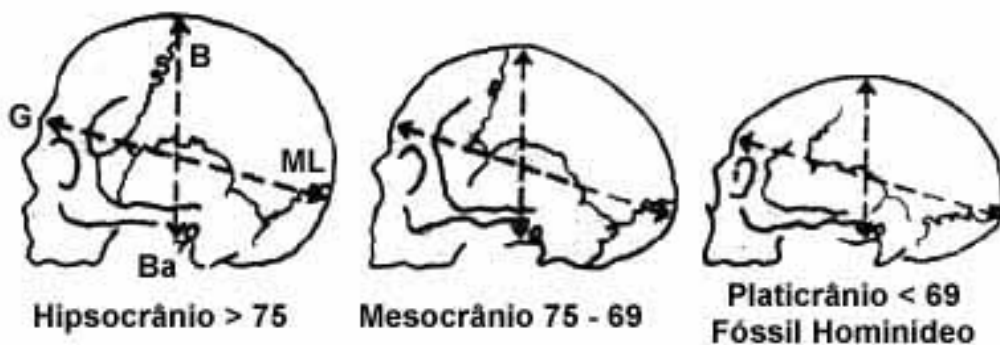


Figura 14

Plano Lateral do crânio

No Plano Posterior, a altura máxima com a largura máxima representado pela fórmula **Índice Posterior** = $(BA-B/Ee-Ed) \times 100$ onde **BA**(Básio), **B**(Bregma), **Ee**(Eurio esquerdo), **Ed**(Eurio direito): Estenocrânio, Metiocrânio, Tapinocrânio (**Fig. 15**)..




Figura 15
Plano posterior do crânio

No Plano Frontal, altura máxima da face com a largura máxima da face representado pela fórmula **Índice Frontal** = $(N-P/Me-Md) \times 100$ onde **N**(Násio), **P**(Próstio), **Me**(Malar esquerdo), **Md**(Malar direito): Dolicofacial, Mesofacial, Braquifacial (**Fig. 16**)..




Figura 16
Plano frontal do crânio

No **Plano Frontal Nasal**, na altura nasal com a largura nasal representado pela fórmula **Índice Nasal = $(LN/N-ENA) \times 100$** onde **LN**(Largura Nasal), **N**(Násio), **ENA**(Espinha Nasal Anterior): Leptorrino, Mesorrino, Platirrino (**Fig. 17**).




Figura 17

Plano fronto nasal do cranio

2.3.5 Anomalias

As anomalias cranianas não foram consideradas, pois a proposta do tema apresentado trabalha com um padrão de normalidade dos dados obtidos, mas não descarta a possibilidade de inclusão em trabalhos futuros visando à compreensão destas anomalias.

3 Redes neurais

3.1 Definição

As Redes Neurais Artificiais (RNAs – conhecidas também como processamento paralelo distribuído, sistemas neuromórficos, computadores biológicos e neurocomputadores) são sistemas computacionais de implementação em hardware ou software inspirados na estrutura (e em menor grau, no funcionamento) do sistema nervoso biológico, principalmente o cérebro humano. Segundo modelos matemáticos procura-se imitar as habilidades computacionais dos neurônios humanos artificialmente, que pelo alto paralelismo e interconexões podem resolver problemas onde as técnicas tradicionais de IA tem sucesso limitado.

3.2 Histórico

Este histórico resumido apresenta as pesquisas e os fatos mais relevantes sobre as RNAs sem desmerecer outras contribuições importantes. A seqüência cronológica é descrita a seguir:

1943 - O neurofisiologista **Warren Mcculloch** (MIT) e matemático **Walter Pitts** (Un. Illinois) sugeriram a construção de uma máquina baseada no cérebro humano. Tal idéia fundamentou-se em uma analogia feita entre as células nervosas vivas e o processamento eletrônico.

1949 - O Livro “*The organization of behavior*”, **Donald Hebb** propôs uma lei de aprendizagem específica para as sinapses dos neurônios, introduzindo o modelo básico de rede de auto-organização.

1958 - Perceptron: concebido por **Frank Fosenblatt**. Consistia em uma rede neural de 2 camadas, usando o modelo de aprendizado supervisionado aplicado ao reconhecimento de caracteres, entre outros empregos.

1960 - Rede ADALINE (*ADaptive Linear NEwork*) e MADALINE (*Many ADALINE*) perceptron proposto por **WIDROW & HOFF**. Utilizavam saídas analógicas em arquiteturas de 2 camadas.

1962 - Memistor Corporation empresa de circuitos neurais digitais fundada por **WIDROW** que desenvolvia processadores para redes neurais.

1969 - Fim das verbas destinadas a pesquisa de redes neurais artificiais. **MINSKY & PAPER**T apresentam provas matemáticas das limitações e franquezas do perceptron. Entretanto devem ser citados alguns pesquisadores que realizaram, nos anos 60 e 70, importantes trabalhos sobre modelos de Redes Neurais em visão, memória, controle e auto-organização, como: **AMARI, ANDERSON, COOPER, COWAN, FUKUSHIMA, GROSSBERG, KOHONEN, VON DER MALSBERG**.

1982 - **HOPFIELD** relatando a utilização de redes simétricas para otimização

1986 - Aplicação do método de Backpropagation por **RUMELHART, HILTON & WILLIANS** que introduziram esta técnica de treinamento para redes com mais de uma camada, MLP.

3.3 Paradigmas

Na IA existem paradigmas que pretendem justificar como um comportamento inteligente pode emergir a partir de implementações artificiais em computadores. Os dois paradigmas são chamados de:

Simbolista, onde a solução de um problema é visto como um processo essencialmente algoritmo.

Conexionista, que procura implementar modelos cognitivos artificiais para reproduzir as capacidades naturais do cérebro humano. Desta forma tarefas tais como a associação, categorização e percepção de traços marcantes, capacidades auto-organizacionais realizadas naturalmente pelo cérebro humano, poderão ser reproduzidas pelo processo computacional.

3.4 Capacidades e restrições

Redes neurais artificiais podem ser consideradas como metodologia de resolver problemas característicos da inteligência artificial. **BARRETO (1998)**.

Citamos a seguir algumas capacidades e restrições das RNAs:

- Redes "feedforward" com uma única camada intermediária são consideradas estimadores universais estatisticamente consistentes para a maioria dos problemas.

- Não existem métodos de aprendizado capazes de criar informação que não esteja contida na base de dados de treinamento. Isso significa que o desempenho da rede depende bastante do tamanho do conjunto de dados usado no treinamento da rede.

- Uma grande restrição das RNAs está na sua incapacidade de prover explicações lógicas para os resultados alcançados, tal qual pode ser feito pelos sistemas baseados em regras.

- As RNAs podem ser vistas como "caixas pretas", nas quais quase não se sabe porque a rede chega a um determinado resultado, uma vez que os modelos não apresentam justificativas para suas respostas **BARON (1995)**.

- O tempo de treinamento de redes neurais utilizando *backpropagation* tende a ser muito longo (milhares de ciclos para se chegar a níveis de erros aceitáveis). Este problema é ainda mais crítico se as redes estiverem sendo simuladas em computadores

seriais (CPU deve calcular as funções para cada unidade e suas conexões separadamente).

•Dificuldade de definir a arquitetura ideal da rede (grande o suficiente para conseguir obter as representações internas necessárias e, ao mesmo tempo, pequena o suficiente para apresentar um treinamento rápido).

•Não existem regras claras para a definição de quantas unidades devem existir nas camadas intermediárias, quantas camadas, ou como devem ser as conexões entre essas unidades. **MENDES & CARVALHO (1998)**.

3.5 Aplicações

Atualmente, muitos estudos vêm sendo realizados para a utilização de Redes Neurais Artificiais, que se constituem em uma tecnologia computacional emergente, em tarefas práticas nas quais as abordagens computacionais tradicionais não vêm obtendo bons resultados. Entre estas tarefas podem ser citados:

- Resolução de problemas
- Reconhecimento e classificação de padrões
- Processamento de Sinais
- Controle de processos
- Otimização
- Previsão

Redes Neurais Artificiais têm propriedades particulares muito interessantes, como capacidade de se adaptar ou aprender, de generalizar e de agrupar ou organizar dados. Por isso, são mais apropriadas em aplicações nas quais é necessário capturar associações ou descobrir regularidades num conjunto de padrões e o volume, número de variáveis ou a diversidade dos dados são muito grandes.

A área de Redes Neurais Artificiais vem vivenciando um rápido crescimento e recebendo grande atenção por parte da mídia e em conferências técnicas. Muitos sistemas computacionais vêm sendo implementados utilizando Redes Neurais em aplicações nas mais diversas áreas, tais como: engenharia, medicina, biologia, sociologia, lingüística, finanças, administração. Essa é uma área extremamente multidisciplinar, e interessa a pessoas muito diferentes:

- Cientistas de computação, que querem utilizar as propriedades de processamento de informação das redes neurais e projetar sistemas com capacidade de aprendizado.
- Estatísticos, que utilizam redes neurais como modelos mais flexíveis para classificação ou regressão não-linear.
- Engenheiros, que podem explorar as capacidades das redes em muitas áreas como processamento de sinais e controle automático.
- Físicos, para a modelagem de fenômenos e em muitas outras tarefas.

- Cientistas Cognitivos, que usam redes neurais como uma ferramenta para descrição de modelos mais simples de pensamento e consciência.
- Biólogos, genética, estudos de comportamento populacional, fisiologia.
- Filósofos e outros, por razões diversas.

3.6 A capacidade de reconhecer padrões

3.6.1 O conhecimento do Especialista em Anatomia Cefalométrica

Os seres humanos são bons no reconhecimento de padrões. Recebemos dados do mundo à nossa volta através dos nossos sentidos e somos capazes de reconhecer a fonte dos dados. Frequentemente, somos capazes de fazer isso quase que imediatamente e praticamente sem esforço. Podemos, por exemplo, reconhecer um rosto familiar de uma pessoa embora esta pessoa tenha envelhecido desde o último encontro, identificar uma pessoa familiar pela sua voz ao telefone, apesar de uma conexão ruim e distinguir um ovo fervido que é bom de um ruim pelo seu cheiro. Os humanos realizam o reconhecimento de padrões através de um processo de aprendizagem. Esta aprendizagem é observada na capacidade de especialistas em cefalometria obterem uma reconstrução realista da estrutura crânio-facial de “Luzia” um dos mais antigos fósseis hominídeos encontrados no Brasil (**Fig. 18**).



Figura 18

Reconstrução realista da estrutura crânio-facial de “Luzia”

3.6.2 A aprendizagem da Rede Neural

A propriedade que é de importância primordial para uma rede neural é a sua habilidade de aprender a partir de seu ambiente e de melhorar o desempenho através da aprendizagem. A melhoria do desempenho ocorre com o tempo de acordo com alguma medida preestabelecida. Uma rede neural aprende acerca do seu ambiente através de um processo iterativo de ajustes. Idealmente, a rede se torna mais instruída sobre o seu ambiente após cada iteração do processo de aprendizagem.

Há atividades demais à noção de aprendizagem para justificar a sua definição de forma precisa. Além disso, o processo de aprendizagem depende do ponto de vista, o que causa dificuldades em se obter um consenso sobre uma definição precisa do termo. A aprendizagem do ponto de vista de um psicólogo, por exemplo, é bastante diferente da aprendizagem em um sentido de sala de aula. Reconhecendo que o interesse particular se concentra nas Redes Neurais Artificiais, utiliza-se a seguinte definição de aprendizagem.

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 **MENDEL & MCCLAREN, (1970)**.

3.7 Analogia neurobiológica

O projeto de uma rede neural é motivado pela analogia com o cérebro, que é uma prova viva de que o processamento paralelo tolerante a falhas é não somente possível fisicamente, mas também rápido e poderoso. **HAYKIN (1994)**.

Este campo de estudo mantém dependências disciplinares com a cibernética, a psicologia, a neurobiologia, a matemática e a física. A analogia entre o Cérebro Humano, Computador Convencional e Neurocomputador é facilmente observada através dos aspectos comparativos apresentados no **Quadro 1** , Cérebro Humano versus computador e **Quadro 2** , Neurocomputador versus Computador Convencional.

Cérebro	Computador Convencional
Aprende	Executa operações lógicas
Resposta a um estímulo = 0.2 a 1 seg.	Processamento muito rápido = 2ns
Processamento altamente paralelo 60 trilhões de conexões	Processamento seqüencial
Processamento tolerante a falhas	Processamento preciso
Tratamento de problemas abrangentes	Tratamento de problemas restritos
Armazenamento de informações de forma adaptativa	Armazenamento de informações de forma estática (endereçada)

Quadro 1
Cérebro humano versus computador

Neurocomputador	Computador Convencional
Aprende	Executa operações lógicas
Processamento lento	Processamento muito rápido
Processamento paralelo Estrutura conexionista	Processamento seqüencial
Processamento tolerante a falhas	Processamento preciso
Tratamento de problemas abrangentes	Tratamento de problemas restritos
Armazenamento de informações de forma adaptativa	Armazenamento de informações de forma estática (endereçada)
Sem mecanismo de explicação	Logicamente explicável

Quadro 2

Neurocomputador versus Computador Convencional

O sistema nervoso é formado por neurônios, conjunto extremamente complexo de células, essenciais na determinação do funcionamento e comportamento do corpo humano. Os neurônios se diferem por funções e topologias específicas importantes, mas o principal objeto de estudo nas mais variadas áreas é a compreensão do processo de aprendizagem do neurônio do córtex cerebral (**Figura 19**) .




Figura 19

Áreas neuronais específicas visão, motor, etc..

A comunicação dos neurônios é feita através de regiões chamadas sinapses, onde a extremidade do corpo celular, tomando como exemplo dois neurônios, entram em contato e através das qual os impulsos nervosos são transmitidos entre eles. Os impulsos recebidos por um neurônio (A), em um determinado momento, são processados e, após atingir um dado limiar de ação, o neurônio (A) dispara, desencadeando o potencial de ação, que se propaga como onda de despolarização pelo axônio até a sinapse com outro neurônio (B). Através de um mecanismo de exocitose vesículas regionais liberam um mediador químico (neurotransmissor), que então estimulara os receptores (dendritos) do neurônio (B), podendo ou não desencadear uma nova onda de despolarização. Este processo depende da geometria da sinapse e o tipo de neurotransmissor podendo diminuir ou aumentar a polaridade da membrana pós-sináptica, inibindo ou excitando a geração dos pulsos no neurônio seguinte.

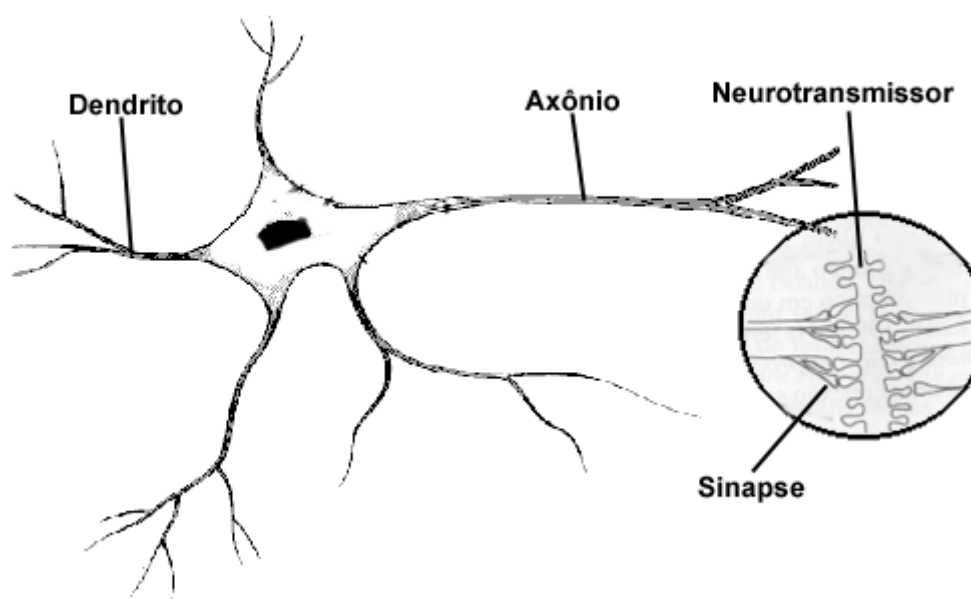


Figura 20
Neurônio biológico

O neurônio artificial k é uma estrutura lógico-matemática que procura simular a forma, o comportamento e as funções de um neurônio biológico (**Fig. 20**). Na simulação de estrutura os dendritos foram substituídos por entradas X_n e o axônio pela saída Y . Na simulação do comportamento a diminuição ou aumento da polaridade da membrana pós-sináptica foi substituída pelos pesos W_{kn} , os impulsos recebidos e processados foram substituídos pela função soma Σ e o limiar de disparo foi substituído pela função de ativação F (**Fig. 21**).




Figura 21

Neurônio artificial

3.8 Topologia

A topologia de uma rede neural representa as interconexões entre os neurônios artificiais e sua organização a nível de camadas. A configuração da topologia influencia o desempenho das RNAs. Não existe um meio de determinar uma boa topologia, pois depende muito mais da complexidade do problema a ser tratado e do número e qualidade dos exemplos de treinamento fornecidos para o aprendizado. Apesar de algumas dicas e truques para a escolha da topologia, não existe alguma muito conclusiva. Desta forma a determinação é feita de forma empírica testando topologias até ser encontrada uma adequada. Uma nova abordagem é a utilização de algoritmos genéticos para a determinação da topologia proposta por **MURRAY (1994)**.

Para uma compreensão da evolução na topologia das RNAs, inicia-se com o primeiro modelo de neurônio artificial desenvolvido por **McCulloch e Pitts (1943)**, baseadas no sistema nervoso humano (**Fig. 22**).




Figura 22

O primeiro modelo de neurônio artificial

ROSENBLATT (1958) idealizou o modelo de perceptron com 2 camadas através de aprendizado supervisionado. Esse modelo era capaz de resolver alguns problemas simples de classificação (**Fig.23**).




Figura 23

Rede Perceptron

WIDROW & HOFF (1962) propõem a uma rede neural com saídas analógicas, rede ADALINE (ADaptive LInear NEwork) e MADALINE (Many ADALINE) (Fig.24).

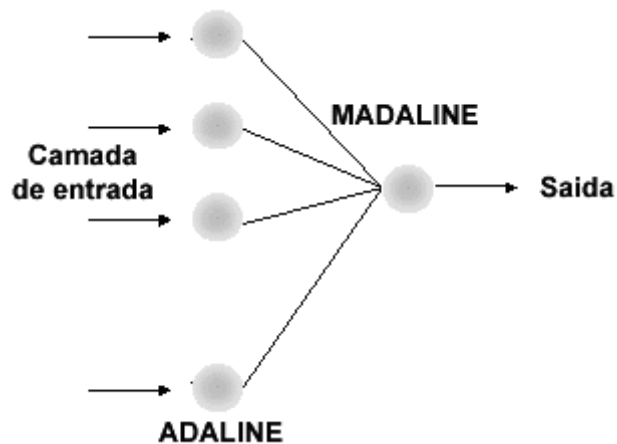


Figura 24
Redes ADALINE / MADALINE

MINSKY & PAPERT (1967) analisaram matematicamente o Perceptron e demonstraram que redes de uma camada não são capazes de solucionar problemas que não sejam linearmente separáveis (Fig.25). Concluíram que não seria possível se construir um método de treinamento para redes com mais de uma camada.




Figura 25
Função ou-exclusivo (XOR)

Através dos trabalhos de **WERBOS (1974); PARKER (1985)** sobre o algoritmo de treinamento backpropagation, **RUMELHART; HINTON & WILLIAMS (1986)**, demonstraram que era possível treinar eficientemente Redes Neurais com camadas intermediárias, resultando no modelo mais utilizado atualmente, as redes Perceptron Multicamadas (MLP) (**Fig.26**), treinadas com o algoritmo backpropagation.

Nessas redes cada camada tem uma função específica classificada em três grupos:

- A camada de entrada é o local onde os padrões são apresentados à rede
- A camadas intermediárias ou escondidas funcionam como extratoras de características, onde ocorre a maior parte do processamento através das conexões ponderadas. Seus pesos são uma codificação de características apresentadas nos padrões de entrada permitindo que a rede crie sua própria representação, mais rica e complexa, do problema.
- A camada de saída recebe os estímulos das camadas intermediárias e constrói o padrão que será a resposta.

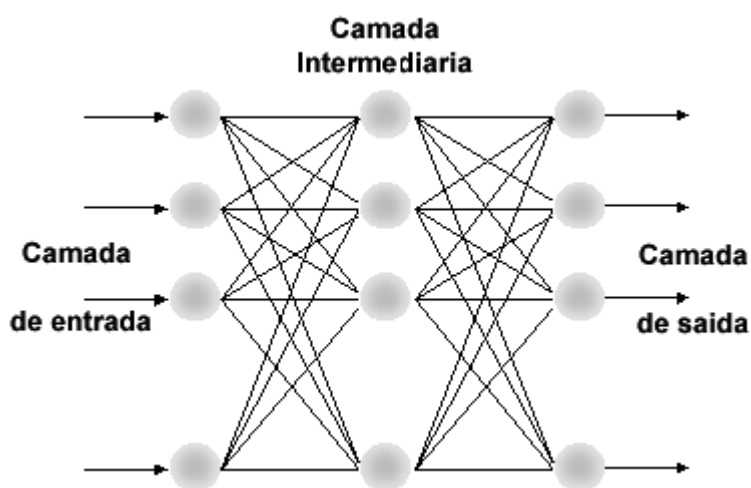


Figura 26


Camadas intermediárias

3.9 Processo de aprendizagem

A importância para a utilização de Redes Neurais nas mais diversas áreas de aplicação se deve a capacidade de aprender através de exemplos e de generalizar sobre os padrões das classes de treinamento, tornando possível o reconhecimento de outros padrões similares, mas não necessariamente idênticos aos utilizados durante o aprendizado. O comportamento "inteligente" de uma Rede Neural Artificial vem das iterações entre as suas unidades de processamento (neurônios artificiais). Uma Rede Neural Artificial é composta por várias unidades de processamento que executam operações apenas sobre seus dados locais. As entradas recebidas pelas suas conexões através de um processo iterativo de ajustes aplicados aos pesos de suas conexões (sinapses), consistem no treinamento da rede neural. Os pesos servem para ponderar a entrada recebida por cada unidade de processamento da rede. Durante esse processo são apresentados exemplos de entradas e saídas e as conexões da rede vão sendo alteradas de forma a minimizar o erro cometido. O aprendizado ocorre quando a rede neural atinge uma solução generalizada para um dado problema.

Basicamente o processo de aprendizagem pode ser resumido da seguinte maneira: **(Fig.27)**

- Sinais são apresentados às entradas X_n .
- Cada sinal é multiplicado por um valor, ou peso W_{kn} , que indica a sua influência na saída da unidade.
- A soma ponderada dos sinais Σ produz um nível de atividade.
- Se este nível de atividade exceder um certo limite (threshold) a função de ativação da unidade F produz uma saída Y igual a 1.
- Caso contrário, a saída Y será igual a 0.



(Fig.27)

Neurônio em atividade

Um fator importante na rede neural é a maneira pela qual se relaciona com o seu ambiente, conhecidos como paradigmas de aprendizagem. Os paradigmas de aprendizagem são:

- Aprendizado supervisionado, quando se utiliza um agente externo que indica à rede a resposta desejada para o padrão de entrada.
- Aprendizado não supervisionado, quando não existe um agente externo indicando a resposta desejada para os padrões de entrada.
- Aprendizado por reforço, quando um crítico externo avalia a resposta fornecida pela rede.

Demonstra-se a seguir (**Fig.28**) o treinamento supervisionado aplicado à um modelo de rede Perceptron, procedimento conhecido como Regra Delta introduzido por **ROSENBLATT (1958)**. Esse treinamento consiste em ajustar os pesos e os *thresholds* de suas unidades para que a classificação desejada seja obtida. Quando um padrão é inicialmente apresentado à rede, ela produz uma saída. Se a saída da rede for diferente da resposta desejada, são realizados os ajustes adequados nos pesos das conexões, de modo a reduzir o erro.

Esquema de treinamento do Perceptron.

Iniciar todas as conexões com pesos aleatórios;

Repita até que o erro E seja satisfatoriamente pequeno ($E = e$)

Para cada par de treinamento (X, d) , faça:

Calcular a resposta obtida O ;

Calcular o erro ($E = O - d$);

Se o erro não for satisfatoriamente pequeno ($E > e$), então:

Atualizar pesos: $W_{novo} = W_{anterior} + \eta E X$;

Nos quais:

O par de treinamento (X, d) corresponde ao padrão de entrada e a sua respectiva resposta desejada;

A taxa de aprendizado η é uma constante positiva, que corresponde à velocidade do aprendizado.

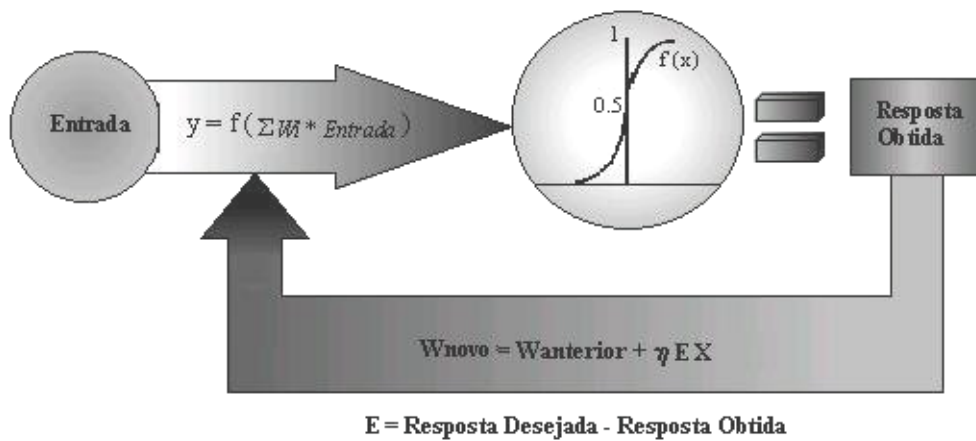


Figura 28
Treinamento do Perceptron

As respostas geradas são calculadas através de uma função de ativação, dadas em função das somas das entradas ponderadas pelos pesos das conexões. São necessárias para a introdução da não-linearidade da rede. Observando-se que redes com camadas intermediárias não seriam melhores que redes sem essas camadas, pois uma composição de funções lineares, é também uma função linear. O que torna as RNAs Multicamadas tão poderosas é exatamente a capacidade de representar funções não-lineares.

Existem vários tipos de função de ativação. As mais utilizadas são: *Hard Limiter*, *Threshold Logic* e *Sigmoid*, mostradas na (Fig. 29).




Figura 29
Funções de ativação.

Os parâmetros da rede são ajustados sob a influência combinada do vetor de treinamento e do sinal de erro. O sinal de erro é definido como a diferença entre a resposta desejada e a resposta real da rede. Este ajuste é realizado passo a passo, iterativamente, com o objetivo de fazer a rede neural emular a aprendizagem supervisionada; supõe-se que a emulação seja ótima em um sentido estatístico. Desta forma, o conhecimento do ambiente disponível a aprendizagem supervisionada é transferido para a rede neural através do treinamento, da forma mais completa possível. Quando esta condição é alcançada, pode-se então dispensar a aprendizagem supervisionada e deixar a rede neural lidar com o ambiente inteiramente por si mesma.

A forma de aprendizagem supervisionada descrita é a aprendizagem por correção de erro. A redução de erros também será abordada no tópico de algoritmos de aprendizagem.

As redes supervisionadas de Perceptron Multicamada com algoritmo Backpropagation de correção do erro serão as mais abordadas por se tratarem das mais utilizadas e pelos bons resultados na maioria das aplicações.

3.10 Algoritmo de aprendizado

A um conjunto preestabelecido de regras bem definidas para a solução de um problema de aprendizagem é denominado algoritmo de aprendizagem. Tem-se na verdade um conjunto de ferramentas representadas por uma variedade de algoritmos de aprendizagem, cada qual oferecendo vantagens específicas.

Os algoritmos de aprendizado podem ser classificados pelo modo como o problema é apresentado (aprendizados supervisionados ou não supervisionados descritos no tópico anterior). No entanto para qualquer que seja o tipo de aprendizado, ele é obtido através de processos de treinamento cuja implementação e eficácia irão depender do algoritmo empregado para adaptação dos pesos. Os principais algoritmos de aprendizado em geral são classificados em duas grandes categorias que refletem o tipo de regra básica empregada:

- Regras de correção de erro, a atualização dos pesos é função direta do erro nas saídas.

- Regras do gradiente descendente, a atualização segue o gradiente negativo de uma função custo para os pesos.

As RNAs que utilizam backpropagation trabalham com a regra delta generalizada, uma variação da regra delta padrão, adequada para redes com múltiplas camadas. A regra delta padrão essencialmente trabalha com funções de ativação lineares resolvendo problemas nos quais a superfície de erro tem a forma de um parabolóide com apenas um mínimo. No entanto, a superfície do erro pode não ser tão simples e as derivadas mais difíceis de serem calculadas. Nestes casos, podem ser utilizadas redes com camadas intermediárias.

Quando as redes ficam sujeitas aos problemas de mínimos locais (*hill-climbing*), utilizamos o processo de redução de erros backpropagation (retropropagação) para que o erro cometido pela rede diminua progressivamente, podendo chegar ao mínimo global. O movimento do ponto de operação sobre a superfície de erro se dá tipicamente na forma de uma caminhada aleatória (**Fig. 30**).




Figura 30

Mínimo global - Exemplo de superfície de erro e treinamento backpropagation.

O algoritmo de aprendizado mais utilizado pelo bom desempenho em aplicações práticas e facilidade em redes neurais é o algoritmo backpropagation, que representa a retropropagação do erro. O backpropagation é um algoritmo de aprendizado supervisionado, por este motivo precisa de um indicador da saída desejada para todos os padrões apresentados. Ele utiliza os pares formados pela entrada e saída desejada para

ajustar os pesos das conexões de uma rede. Sua função de ativação mais comum é a sigmoid. Utilizando o algoritmo backpropagation o treinamento ocorre em dois passos:

FORWARD

Um padrão é apresentado à camada de entrada da rede.

A atividade resultante flui através da rede, camada por camada, até que a resposta seja produzida pela camada de saída.

BACKWARD

A saída obtida é comparada à saída desejada para esse padrão particular.

Se estas não forem iguais, o erro é calculado.

O erro é propagado a partir da camada de saída até a camada de entrada.

Os pesos das conexões das unidades da camada de saída e das camadas intermediárias vão sendo modificados conforme o erro é retropropagado.

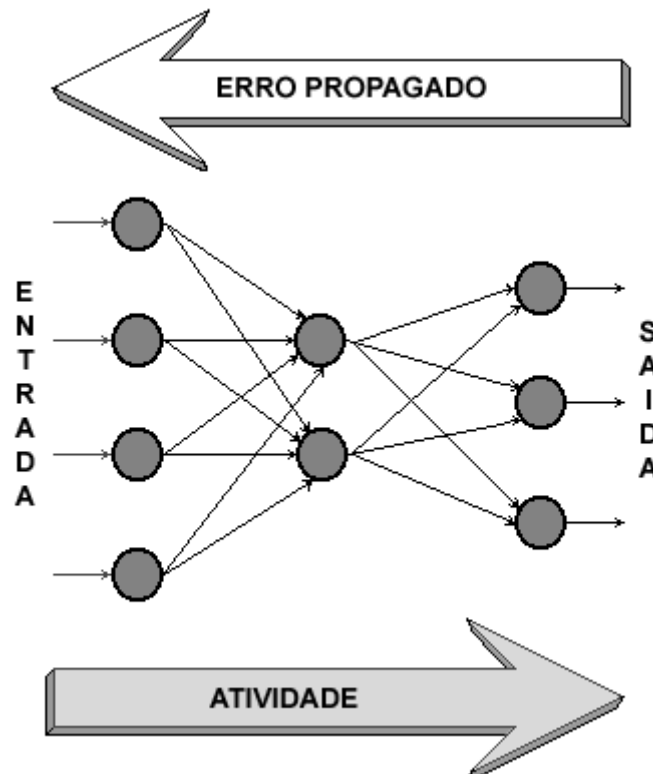


Figura 31

Esquema de treinamento do Perceptron.

Apesar do algoritmo backpropagation ter um bom desempenho, não é ideal pois o treinamento em redes perceptron multicamadas pode demandar muitos passos onde for encontrado um mínimo local que contenha superfícies de erro com longas gargantas, curvas acentuadas ou vales com descidas suaves. **RUMELHART (1986)**, sugeriu a modificação da regra delta generalizada para incluir o termo *momentum* resultando em um aprendizado mais rápido sem levar à uma oscilação do modelo na superfície de erro.

Uma RNA é especificada, principalmente pela sua topologia, pelas características dos nós, pelas regras de treinamento e parâmetros de treinamento.

3.11 Processo de treinamento da rede neural

Apresenta-se neste tópico a metodologia usual de treinamento da rede neural para o desenvolvimento de aplicações.

Coleta de dados

Geralmente, deve ser coletado o maior número de dados possível, dentro dos limites práticos e dos recursos disponíveis. Mas, como defendem **BAILEY & THOMPSON (1990)**, deve haver maior preocupação com a qualidade dos dados do que com o seu volume.

O auxílio de especialistas no domínio do problema é fundamental para uma análise cuidadosa minimizando ambigüidades e erros nos dados. Os dados devem ser significativos e cobrir amplamente o domínio do problema. Ferramentas estatísticas também podem ser utilizadas para auxiliar essa tarefa.

Pré-processamento dos dados.

Primeiramente, estes dados devem ser analisados para identificar as características das variáveis envolvidas e determinar o tipo de pré-processamento apropriado. Segundo a proposição de **STEIN (1993)** as variáveis nominais ou numéricas podem ser normalizadas (escaloadas). As variáveis nominais referentes a classes com categorias mutuamente exclusivas como sexo podem ser normalizadas como: (0,1 = feminino, 0,9 = masculino). As variáveis numéricas (números inteiros ou

reais) podem ser normalizadas (escalonadas) no intervalo entre 0 e 1, através de normalização Euclidiana, logarítmica ou outras funções, tais como tangente hiperbólica, seno, co-seno, etc...

CROOKS (1992) observou que algumas vezes a falta de um valor pode ter um significado que pode ser interpretado (Pergunta: Quantas vezes você foi ao dentista no ano passado? / Resposta: Não me lembro). Isso pode ser interpretado como: (O paciente não vai ao dentista). O tratamento deste problema é a reposição dos valores que estiverem faltando pela melhor suposição possível, geralmente usando um valor esperado ou um valor da média dos valores dos dados, ou, em caso de dados consecutivos, a média de seus vizinhos ou o último valor apresentado.

Separação em conjuntos de dados

Dados de treinamento, que serão utilizados durante o processo de aprendizado da rede.

Dados de teste, que serão utilizados para verificar o desempenho do modelo sob condições reais de utilização.

O próximo passo é colocar esses dados em ordem aleatória para prevenção de tendências associadas à ordem de apresentação dos dados. Pode-se gerar vários “***n*** grupos” de conjuntos e utilizar uma estratégia de “***n*** validações cruzadas”.

Definição da configuração da RNA

A configuração resulta na performance do sistema. Existem metodologias, "dicas e truques", mas normalmente a configuração é de forma empírica, treinando algumas variações de arquiteturas (topologia e parâmetros) e testando cada uma delas. Esta dificuldade tem obtido bons resultados através de algoritmos genéticos para determinação da arquitetura da rede **MENDES (1997)**.

Ela pode ser dividida em três etapas:

1. Seleção do paradigma neural apropriado à aplicação.
2. Determinação da topologia da rede a ser utilizada: o número de camadas, o número de unidades em cada camada, etc.

3. Determinação de parâmetros do algoritmo de treinamento e funções de ativação.

Treinamento da RNA

A inicialização da rede, o modo de treinamento e o tempo de treinamento são fatores a serem considerados para um bom treinamento.

Escolhido o algoritmo de treinamento, são ajustados os valores iniciais dos pesos de forma a diminuir o tempo necessário para o treinamento. A escolha errada destes pesos pode levar a uma saturação prematura, podendo ser necessária uma nova inicialização.

Sempre se faz necessário utilizar algum critério de parada através de um número máximo de ciclos, ou até que se tenha um erro menor que um erro mínimo esperado. Pode ocorrer o que se chama “*over-training*” que é a perda da capacidade de generalização. A rede se especializa no conjunto de dados do treinamento. Assim, deve-se encontrar um ponto ótimo de parada com erro mínimo e capacidade de generalização máxima.

Teste da RNA

Com dados que não foram previamente utilizados testa-se o desempenho da rede. Pode-se ainda analisar o desempenho da rede com cada classe das saídas desejadas onde existe classificação de padrões.

Integração da RNA ao sistema

Após o treinamento e avaliação a rede pode ser integrada aos sistemas do ambiente da aplicação que está apenas citado neste tópico, pois não faz parte do propósito do trabalho.

4 Utilizando Redes Neurais no Reconhecimento de Padrões

Cefalométricos

As Técnicas de cefalometria comparadas utilizam-se dos **métodos quantitativos** para obtenção de dados tanto para as técnicas propostas por outros autores como a técnica utilizando redes neurais.

4.1 Técnicas propostas por outros autores

Foram comparadas duas técnicas, a de **GILES & ELLIOT (1963)** e a de **GALVÃO (1994)**.

GILES & ELLIOT estudaram 1022 crânios e selecionaram 5(cinco) medidas, submetendo-as a análise estatística chegando a uma fórmula, obtendo índice de acerto de 86,9%. Os autores usaram as seguintes medidas:

Distâncias Cefalométricas	
Distância glabella-occipital	GO
Distância básico-násio	BN
Distância bizigomática	BZ
Distância básico-próstio	BP
Distância próstio-násio	PN

Quadro 4
Distâncias Cefalométricas

$$\text{Sexo} = (1,16 \times \text{GO}) + (1,66 \times \text{BN}) + (3,98 \times \text{BZ}) - (1,00 \times \text{BP}) + (1,54 \times \text{PN})$$

O ponto de separação para a função discriminante do sexo nessa fórmula é dado pelo número 891,12. Acima desse número, o sexo é masculino e, abaixo, feminino. Como exemplo, citam o crânio de JEREMY BENTHAM, conhecido filósofo que viveu no século XVIII e cujas medidas são: GO-192mm; BN-105mm; BZ-133mm; BP-85mm e PN-73mm. Aplicando-se a fórmula, tem-se:

$$\text{Sexo} = (1,16 \times 192) + (1,66 \times 105) + (3,98 \times 133) - (1,00 \times 89) + (1,54 \times 73)$$

$$\text{Sexo} = 222,72 + 174,30 + 529,34 - 89 + 112,42 = 949,78$$


Como esse número 949,78 é bem superior a 891,12, conclui-se que esse crânio era realmente de pessoa do sexo masculino.

Na Técnica de **GALVÃO** foram estudados 152 crânios, sendo 62 do sexo feminino e 90 do sexo masculino. Todos pertenceram a indivíduos acima de 20 anos de idade. As mensurações foram feitas em crânios de indigentes no Cemitério de Quinta dos Lázaros em Salvador-Bahia.

Foram medidas as distâncias utilizadas nos dois métodos (Método Quantitativo) e observadas a morfologia da glabella e apófise mastóidea (Método Qualitativo).

Para a obtenção das medidas Glabella-occipital, Básio-násio, Bi-zigomática, Básio-próstio e Próstio-násio, foi utilizado um compasso de ponta romba e um paquímetro de precisão.

Para a obtenção das medidas espinha nasal anterior, centro do meato acústico externo e lambda-centro do meato acústico externo utilizou-se o **Craniômetro de Galvão (Fig. 32)** para padronização das medidas. Estas medidas também podem ser efetuadas utilizando-se duas réguas e metade de um lápis padrão.



Craniômetro de Galvão

Figura 32

Após a coleta dos dados, os mesmos foram aplicados as respectivas fórmulas para análise dos resultados obtidos quanto ao diagnóstico do sexo.

GALVÃO desenvolveu uma fórmula através de análise de regressão logística que permite a determinação do sexo e a probabilidade de chance do crânio pertencer a um ou outro sexo, estabelecendo-se um método de determinação do sexo por caracteres qualitativos e quantitativos do crânio, com índice de acerto de 93,8%. Também desenvolveu o programa para computador, **ANTROPOL**, que executa a fórmula rapidamente. Quando logit ou exponencial é negativo significa que o crânio pertenceu a indivíduo do sexo masculino e positivo ao sexo feminino. O resultado final da equação indica o grau de probabilidade ou índice de confiabilidade.

Pontos cefalométricos	
Glabela	G
Apófise Mastóidea	AM
Meato Acústico Externo	MAE
Espinha Nasal Anterior	ENA
Lambda	L

Quadro 5
Pontos Cefalométricos

MAE/ENA = Distância entre os pontos cefalométricos

e = Constante = 2,71828

AM = 1 = Discreta AM = 0 = Proeminente

G = 1 = Discreta G = 0 = Proeminente

$$\text{Sexo} = \frac{e^{((36,1218 + 5,3846) \times (G + 2,7035) \times ((AM - MAE)/(ENA - MAE/L)))}}{(1 + e^{((36,1218 + 5,3846) \times (G + 2,7035) \times ((AM - MAE)/(ENA - MAE/L)))})}$$

Observando as distâncias glabela-occipital, básico-násio, básico-próstio, próstio-násio e bi-zigmática as tabelas abaixo mostram os seguintes resultados obtidos:

Glabelo – Occipital em mm.					
Sexo	Máxima	Média	Mediana	Moda	Mínima
Masc.	198	179,62	180	181	158
Fem.	191	170,72	170	170	155

Quadro 6
Distância Glabelo – Occipital

Básio-Násio em mm					
Sexo	Máxima	Média	Mediana	Moda	Mínima
Masc.	114	101,05	101	105	90
Fem.	105	96,22	96	96	87

Quadro 7
Distância Básio-Násio

Básio – Próstio em mm					
Sexo	Máxima	Média	Mediana	Moda	Mínima
Masc.	89	54,41	56	62	20
Fem.	93	92,30	93	95	60

Quadro 8
Distância Básio-Próstio

Próstio – Násio em mm.					
Sexo	Máxima	Média	Mediana	Moda	Mínima
Masc.	105	66,88	66	67	51
Fem.	93	62,40	62,50	63	38

Quadro 9
Distância Próstio-Násio

Bi – Zigomática em mm.					
Sexo	Máxima	Média	Mediana	Moda	Mínima
Masc.	173	130,28	130	130	117
Fem.	138	124,90	125	124	110

Quadro 10
Distância Bi-zigomática

Os resultados das distâncias medidas, MAE/ENA (meato acústico externo/espino nasal anterior), MEA/L (meato acústico externo/lâmbda) e os aspectos morfológicos da glabella e apófise mastóidea estão representados nas tabelas a seguir:

Distância MAE/ENA em mm.					
Sexo	Máxima	Média	Mediana	Moda	Mínima
Masc.	108	97,95	98	95	87
Fem.	101	93,37	93,50	92	85

Quadro 11
Distância MAE/ENA

Distância MAE/L					
Sexo	Máxima	Média	Mediana	Moda	Mínima
Masc.	125	106,73	108	105	97
Fem.	117	103,51	103	102	90

Quadro 12
Distância MAE/L

Aspecto qualitativo da Glabela					
Sexo	Total	Discreta	%	Proemin.	Mínima
Masc.	90	10	11,11	80	88,89
Fem.	62	57	91,94	5	8,06

Quadro 13

Aspecto qualitativo da Glabela

Aspecto qualitativo da Apófise Mastóidea					
Sexo	Total	Discreta	%	Proemin.	Mínima
Masc.	90	21	23,33	69	76,67
Fem.	62	56	90,32	6	9,68

Quadro 14

Aspecto qualitativo da Apófise Mastóidea

GALVÃO observou que existe dimorfismo sexual importante entre as medidas das distâncias entre o centro do meato acústico externo e os pontos Gnátio, Próstio, Espinha Nasal Anterior, Glabela, Bregma, Vertex, Lâmbda, Ínio, Apófise Mastóide, Opstocrânio e Gônio, este sendo menos significativo.

- Quando a somatória das medidas acima for maior que 1.000, há tendência do crânio ter pertencido a indivíduo do sexo feminino, com probabilidade de acerto de 83,3%.
- O índice de Baudoin apresenta porcentagem de acerto para o diagnóstico do sexo de aproximadamente 60%, não devendo ser usado isoladamente para esse fim.
- A largura bicondílica, bigoníaca e ângulo mandibular apresentam dimorfismo sexual significativo.

- Os padrões Glabella proeminente, Arcos Superciliares proeminentes, Apófise Mastóide proeminente, Ângulo naso-frontal anguloso, para o sexo masculino, e Glabella discreta, Arcos Superciliares discretos, Apófise Mastóide discreta, Ângulo naso-frontal em curva suave, para o sexo feminino são verdadeiros, no entanto, nem todos os crânios apresentam completamente os padrões descritos acima.
- Com associação dos caracteres qualitativos e quantitativos mais significativos estatisticamente no dimorfismo sexual, o índice de acerto é de 92,9% no sexo feminino e 94,7% no sexo masculino.

Quando os dois métodos GILES & ELLIOT e o de GALVÃO foram comparados quanto ao acerto do diagnóstico do sexo na amostra estudada, foram obtidos os resultados que estão representados pelas tabelas a seguir:

Quadro comparativo de acertos por sexo						
Sexo	Masc.	Acertos	%	Fem.	Acertos	%
Giles& Eliot	90	54	60	62	52	83,87
Galvão	90	79	87,78	62	57	91,94

Quadro 15

Quadro comparativo de acertos por sexo

Quadro comparativo de acertos totais de crânios examinados			
Sexo	crânios examinados	Acertos	%
Giles & Eliot	152	106	69,74
Galvão	152	136	89,47

Quadro 16

Quadro comparativo de acertos totais de crânios examinados

Número de casos em que os dois métodos falharam no diagnóstico do sexo			
Sexo	crânios examinados	Número de casos	%
Masc.	90	7	7,7
Fem.	62	3	4,8
Total	152	10	6,57

Quadro 17

Número de casos em que os dois métodos falharam no diagnóstico do sexo

De acordo com os resultados obtidos, pode-se analisar que as distâncias utilizadas no método de GILES & ELLIOT e no de GALVÃO apresentam valores maiores para o sexo masculino, e todos são estatisticamente significantes. Isto demonstra o relato de vários autores que dizem ser o crânio masculino maior e mais robusto que o feminino no aspecto qualitativo além dos dados aproximarem-se bastante dos resultados quantitativos encontrados pelos autores dos métodos testados. Os acidentes anatômicos Glabella e Apófise Mastóidea apresentaram resultados que refletem o relato de vários autores que dizem ser estes acidentes proeminentes no homem e discretos na mulher.

Quando foram comparados os dois métodos quanto ao acerto do diagnóstico do sexo, o de GALVÃO mostrou-se mais eficaz apresentando índice de acerto de 89,47%, enquanto o de GILES & ELLIOT fez diagnóstico correto em 69,74% dos casos. Analisando os dois métodos em relação ao índice de acerto por sexo, verificou-se que no homem o de GALVÃO acertou 87,78% enquanto o de GILES & ELLIOT apresentou índice de 60%. Na mulher, o índice de acerto apresentado pelo método de GALVÃO foi de 91,94% enquanto o de GILES & ELLIOT apresentou diagnóstico correto em 83,87% dos casos.

Do total de 152 crânios examinados, os dois métodos erraram simultaneamente o diagnóstico do sexo em 10 casos, sendo 7 no masculino e 3 no feminino.

Os resultados apresentados através destes métodos são considerados bons, mas é evidente que a aplicação dos mesmos se restringem a grupos humanos previamente determinados (crânios de indigentes do Cemitério de Quinta dos Lázarus – Salvador – Bahia).

As observações a seguir reforçam as possíveis falhas de classificação cefalométrica como afirmam os autores:

GILES & ELLIOT, 1963, citam que, através do seu trabalho com 408 crânios de negros e brancos americanos, tomando-se 9 medidas (comprimento glabelo-occipital, largura máxima, distância básio-bregma, distância básio, násio, distância máxima

bizigomática, distância básico-próstio, altura próstio-nasio, largura externa no palato, comprimento da apófise mastóide) em 21 combinações diferentes, para a formação de funções discriminantes, com o objetivo de determinar-se o sexo, conseguiram um índice de acerto de 82-89%.

Relatam ainda que testaram seus trabalhos e chegaram à conclusão de que a técnica também pode funcionar com outras populações, desde que sejam adaptados os coeficientes para o "ponto de corte". Os resultados dos escores são comparados a esse ponto para determinação de sexo.

GALVÃO, 1998, cita que os resultados demonstraram um maior índice de acerto pelo seu método não por ser este o mais eficaz, mas por ter sido realizado em amostra nacional. Frequentemente, os Legistas deparam-se com resultados pouco animadores devido à aplicação de metodologias realizadas em amostra de populações que, diversamente da nossa, tem costumes, clima, alimentação e condições sócio-organizacionais bastante diferentes.

4.2 Técnica utilizando Redes Neurais

Apresenta-se a seguir de forma ilustrativa os pontos e reparos anatômicos localizados no crânio hominídeo (**Fig. 33**) e os mesmos pontos e reparos localizados em radiografias cefalométricas de dois hominídeos do sexo masculino de grupos evolutivos distintos (**Fig 34-35**).

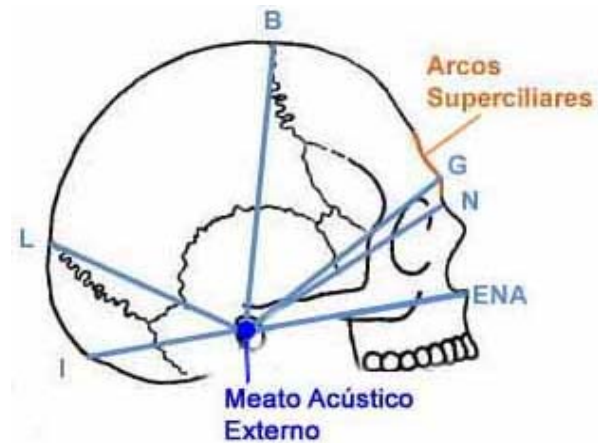


Figura 33

Pontos e Reparos Anatômicos




Figura 34

Homo Sapiens




Figura 35

Neanderthal

As diferenças dos pontos e reparos apresentados nas figuras anteriores são facilmente observáveis mesmo por leigos da área de cefalometria, pois são capazes de perceber as diferenças no contorno e geometria craniana entre o Homo Sapiens e o Neandertal, homínídeos de grupos evolutivos distintos.

Na figura (**Fig. 36**) estes pontos e reparos anatômicos, mesmo que apresentados como padrões geométricos sobrepostos sem o conhecimento prévio da fonte de obtenção desta imagem, ainda sim poderão ser distinguidos por leigos da área de cefalometria.

Esta capacidade do cérebro humano de reconhecer padrões pode ser mimetizada pelas RNAs com finalidades de classificação e identificação não importando o objeto de estudo.




Figura 36

Reconhecer padrões não importando o objeto de estudo.

Tomando por exemplo um aluno de anatomia, ao final do curso o conteúdo da etapa de aprendizagem será aplicado na identificação anatômica, similarmente ao que ocorre nas Redes Neurais. Definidos o método de aprendizagem da RNA e as informações (dados de entrada e saída), treina-se a RNA para testar seus “conhecimentos”. A Rede Neural Artificial fixa seu conhecimento através de pesos sinápticos, processo pelo qual a força de uma informação estimula a rede.

Este reconhecimento de padrões é formalmente definido como o processo pelo qual um padrão de sinal recebido é atribuído a uma classe dentre um número predeterminado de classes categorias. Uma RNA realiza o reconhecimento de padrões

passando inicialmente por uma sessão de treinamento, durante a qual se apresenta repetidamente à rede (RNA) um conjunto de padrões de entrada junto com a categoria à qual cada padrão particular pertence. Mais tarde apresenta-se à rede um novo padrão que não foi visto antes, mas que pertence à mesma população de padrões utilizada para treinar a rede. A rede é capaz de identificar a classe daquele padrão particular com base no conhecimento que a mesma adquiriu da informação contida nos dados de treinamento. Os padrões estabelecidos por uma rede neural podem ser representados por conjuntos de pontos em um espaço de decisão multidimensional, e embora guiado pelo método indutivo, o reconhecimento de padrões realizado por uma rede neural não é de natureza estatística. O espaço de decisão é dividido em regiões, cada uma das quais associada a uma classe. As fronteiras de decisão são determinadas pelo processo de treinamento. A acurácia da construção dessas fronteiras, esta sim, é tornada estatística pela variabilidade inerente que existe dentro das classes e entre as classes.

Seguindo este conceito pode-se simular a capacidade de um especialista em cefalometria, através da alimentação de dados de entrada e saída obtidos pelos métodos cefalométricos e ou craniométricos atualmente empregados. Este processo é descrito a seguir.

4.2.1 Metodologia de obtenção de dados cefalométricos

Foram estudados 140 crânios em laboratórios de anatomia das Universidades do Estado de São Paulo e de Santa Catarina, compostos por 70 crânios masculinos e 70 crânios femininos com idades aproximadas acima de 20 anos, de grupos raciais aleatórios. O processo de escolha de um número igual de crânios femininos e masculinos visa equilibrar o espectro de aprendizagem da rede neural, já o processo de escolha de crânios acima de 20 anos visa evitar pequenas alterações nas mensurações cefalométricas executadas, pois as mudanças antropométricas relativas ao crescimento craniano serão ínfimas.

Para a coleta de dados referentes ao sexo foi utilizado aparelho similar ao Craniômetro de Galvão onde o Meato Acústico Externo é fixado, barras deslizantes paralela são travadas e através de um feixe de laser são medidas com régua de precisão.

A distância entre os pontos cefalométricos TSM/IM foi obtida através de paquímetro. Os valores obtidos foram medidos em milímetros.

Determinação do Sexo Distâncias entre Pontos Cefalométricos em mm.
MAE/ENA = Meato Acústico Externo – Espinha Nasal Anterior
MAE/L = Meato Acústico Externo – Lâmbda
MAE/I = Meato Acústico Externo – Ínio
MAE/G = Meato Acústico Externo – Glabela
MAE/APM = Meato Acústico Externo – Ápice do processo Mastóideo
TSM/IM = Trigono Supra Meático – Incisura Mastoidea

Quadro 18 - Determinação do Sexo

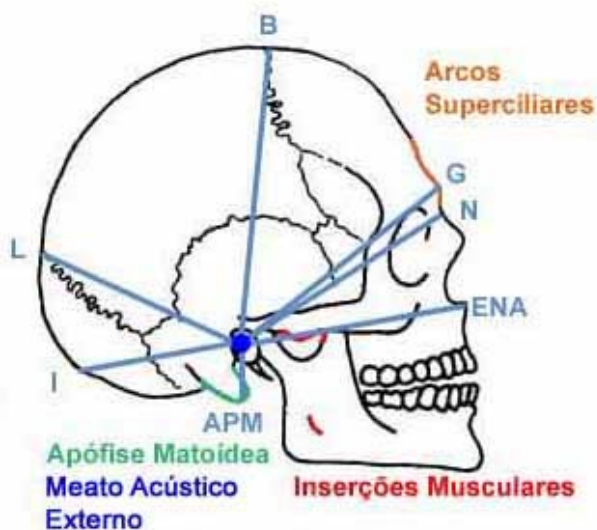


Figura 37

Cefalometria do crânio masculino

Para a coleta de dados referentes ao grupo racial foi utilizado paquímetro de estudo anatômico onde os índices dos planos (**Quadro 19**) foram obtidos através das medidas tomadas em milímetros.

Determinação do Grupo Racial Distâncias entre Pontos Cefalométricos em mm.	
Plano Horizontal	Índice Horizontal = $(Ee-Ed/G-ML) \times 100$
Plano Lateral	Índice Lateral = $(BA-B/G-ML) \times 100$
Plano Posterior	Índice Posterior = $(BA-B/Ee-Ed) \times 100$
Plano Frontal	Índice Frontal = $(N-P/Me-Md) \times 100$
Plano Fronto-Nasal	Índice Nasal = $(LN/N-ENA) \times 100$

Quadro 19 - Determinação do Grupo Racial

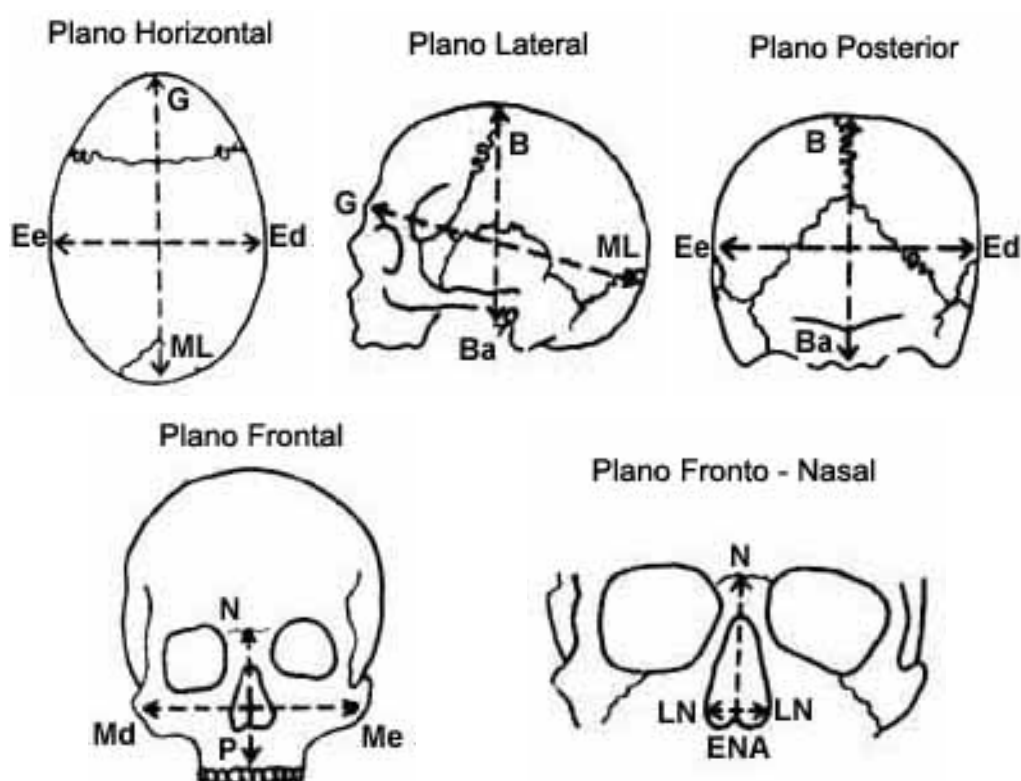


Figura 38
Grupo racial

Para a coleta de dados referentes a idade aproximada foi utilizado paquímetro onde as regiões suturais foram medidas em milímetros e a porcentagem de ossificação arredondada para valores inteiros.

Determinação da Idade Aproximada Porcentagem de ossificação da Suturas Cranianas	
Região Sutural A1	100% de ossificação = Faixa etária > 20 anos
Região Sutural A2	100% de ossificação = Faixa etária > 25 anos
Região Sutural B1	100% de ossificação = Faixa etária > 30 anos
Região Sutural B2	100% de ossificação = Faixa etária > 30 anos
Região Sutural C	100% de ossificação = Faixa etária > 40 anos
Região Sutural D	100% de ossificação = Faixa etária > 50 anos

Quadro 20 - Determinação da Idade Aproximada

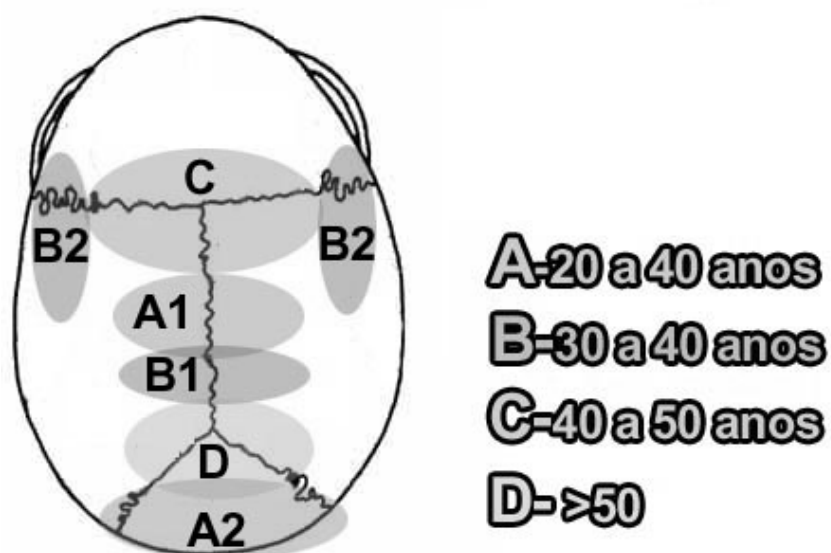


Figura 39

Idade aproximada

4.2.2 Pré-Processamento dos Dados

Os dados foram lançados em uma planilha “Excel” com cuidados rigorosos na digitação eliminando possíveis erros. Os dados das entradas representando 17 medições cefalométricas foram relacionados aos 3 dados das saídas, totalizando 9 características antropomórficas dentro das seguintes normalizações:

SEXO

Fem. = 0.1

Masc. = 0.9

GRUPO RACIAL

Negróide = 0.1

Mongólico = 0.5

Caucásico = 0.9

IDADE

20 a 30 anos = 0.2

30 a 40 anos = 0.3

40 a 50 anos = 0.4

> 50 anos = 0.5

Os índices normalizados seguem o padrão americano decimal para adaptar-se ao QwickNet (ferramenta para Redes Neurais Artificiais).

4.3 Seleção dos Conjuntos de Treinamento e Teste

Foram selecionados para o treinamento 82% ou 114 linhas de dados compostos por 17 dados de entrada e 3 dados de saída por linha. Posteriormente foram copiados da planilha para o conjunto de treino da rede neural.

Para o conjunto de teste da rede neural foram selecionados 18% ou 26 linhas de dados compostos por 17 dados de entrada e 3 dados de saída por linha. Posteriormente foram copiados da planilha para o conjunto de teste da rede neural.

4.4 Configuração da Rede Neural

4.4.1 Seleção do Paradigma Neural

Pelas características do problema tratado (comparações cefalométricas) e estudos sobre outras pesquisas envolvendo rede neural na avaliação de padrões biomórficos optou-se pelo de método de aprendizagem supervisionada sem retroalimentação (*feedforward*).

O algoritmo utilizado inicialmente foi o de retropropagação “*Backpropagation*” pelas justificativas acima descritas. Após alguns ajustes no parâmetro “*momentum*” ocorreu uma pequena melhora na velocidade do aprendizado.

Apesar de obter bons resultados com o “*Backpropagation*” e testar outros, o algoritmo escolhido foi o “*Quickprop*” onde o desempenho foi realmente bom.

Essa melhora no desempenho com o “*Quickprop*” se deve a redução do tempo de convergência. Ela assume que a superfície de erro é localmente quadrática (formando uma parábola) e procura saltar da posição atual para o ponto mínimo da parábola, onde o erro será encontrado e os pesos poderão ser calculados com uma grande aproximação.

No “*Backpropagation*” a descida do gradiente até um mínimo local é lenta para determinar a superfície de erro e com ela a solução desejada.

4.4.2 Determinação da Topologia

Início-se com 1 camada intermediária com 3 neurônios até 2 camadas intermediárias com 6 e 4 neurônios.

O melhor desempenho foi obtido com 1 camada intermediária e 5 neurônios.

4.4.3 Determinação dos Parâmetros do Algoritmo e das Funções de Ativação

Os parâmetros utilizados foram:

Peso máximo da rede = 100

Peso mínimo da rede = -100

Perturbação = 20%

Nível de saturação do neurônio = 80%

Função de ativação da camada intermediária 1 = Logística (sigmóide/não linear)

Função de ativação da última camada = Logística (sigmóide/não linear)

4.5 Treinamento da Rede Neural

Critério de parada

Ativada para treinamento

Limite de treinamento = 1000 ciclos

Limite de erro do treinamento = 0.01

Porcentagem correta = 100%

Propriedade de treinamento

Margem de erro = 0.1(magnitude do erro na saída da rede)

Treinamento

Com a rede configurada inicia-se o treinamento observando o aumento da porcentagem correta na estatística de treino. A porcentagem de acerto aumenta próxima aos 200 ciclos de treinamento.

Salvam-se os pesos

4.6 Teste da Rede Neural

Critério de parada

Ativada para treinamento e teste

Limite de treinamento = 1000 ciclos

Limite de erro do = 0.01

Porcentagem correta = 100%

Carregam-se os pesos

Carrega-se o conjunto de treino

Carrega-se o conjunto de teste

Teste

Com a rede configurada inicia-se o teste da rede observando o aumento da porcentagem correta na estatística de teste. A porcentagem de acerto aumenta próxima aos 200 ciclos atingindo 96,15% de acerto global.

Salva-se o conjunto de saídas

4.7 Análise do desempenho da Rede Neural

Compara-se o conjunto de saídas com o conjunto de teste.

CRITÉRIOS DE ANÁLISE DOS RESULTADOS		
VALORES ABSOLUTOS		
Fem. = 0.1	Negróide = 0.1	20 a 30 anos = 0.2
	Mongólico = 0.5	30 a 40 anos = 0.3
Masc. = 0.9	Caucásico = 0.9	40 a 50 anos = 0.4
		acima 50 anos = 0.5

VALORES APROXIMADOS		
Fem. < 0.6	Negróide < 0.25	20 a 30 anos < 0.295
	Mongólico	30 a 40 anos < 0.395
Masc.	Caucásico => 0.75	40 a 50 anos < 0.495
		acima 50 anos >= 0.495

Quadro 21

Critérios de análise do desempenho da Rede Neural

Ind	SAÍDAS			IDENTIFICAÇÃO CEFALOMÉTRICA		
	O1	O2	O3	SEXO	RAÇA	IDADE
1	0.1003	0.1000	0.4979	Mulher	negróide	mais de 50 anos
2	0.1000	0.8945	0.3246	Mulher	caucasóide	entre 30 e 39 anos
3	0.1001	0.1000	0.2037	Mulher	negróide	entre 20 e 29 anos
4	0.1000	0.1000	0.4781	Mulher	negróide	entre 40 e 49 anos
5	0.1004	0.1000	0.2028	Mulher	negróide	entre 20 e 29 anos
6	0.1020	0.8995	0.2040	Mulher	caucasóide	entre 20 e 29 anos
7	0.1185	0.8909	0.2031	Mulher	caucasóide	entre 20 e 29 anos
8	0.1000	0.1000	0.4163	Mulher	negróide	entre 40 e 49 anos
9	0.1001	0.1000	0.4932	Mulher	negróide	entre 40 e 49 anos
10	0.1000	0.9000	0.4921	Mulher	caucasóide	entre 40 e 49 anos
11	0.1000	0.1000	0.3094	Mulher	negróide	entre 30 e 39 anos
12	0.1000	0.1236	0.2933	Mulher	negróide	entre 20 e 29 anos
13	0.1018	0.8996	0.2039	Mulher	caucasóide	entre 20 e 29 anos
14	0.8996	0.1000	0.2064	Homem	negróide	entre 20 e 29 anos
15	0.8998	0.1003	0.2132	Homem	negróide	entre 20 e 29 anos
16	0.9000	0.1000	0.3174	Homem	negróide	entre 30 e 39 anos
17	0.8991	0.1000	0.2022	Homem	negróide	entre 20 e 29 anos
18	0.8999	0.1000	0.4969	Homem	negróide	mais de 50 anos
19	0.8941	0.8999	0.2022	Homem	caucasóide	entre 20 e 29 anos
20	0.9000	0.1006	0.3067	Homem	negróide	entre 30 e 39 anos
21	0.8998	0.7411	0.4980	Homem	mongóide	mais de 50 anos
22	0.8993	0.1000	0.4976	Homem	negróide	mais de 50 anos
23	0.8998	0.1000	0.4976	Homem	negróide	mais de 50 anos
24	0.8992	0.1000	0.4976	Homem	negróide	mais de 50 anos
25	0.8998	0.1000	0.4971	Homem	negróide	mais de 50 anos
26	0.8999	0.1000	0.4974	Homem	negróide	mais de 50 anos

Quadro 22

Análise do Desempenho da Rede Neural - 1

Ind	TESTE			IDENTIFICAÇÃO CEFALOMÉTRICA		
	T1	T2	T3	SEXO	RAÇA	IDADE
1	0.1	0.1	0.5	Mulher	negróide	mais de 50 anos
2	0.1	0.9	0.3	Mulher	caucasóide	entre 30 e 39 anos
3	0.1	0.1	0.2	Mulher	negróide	entre 20 e 29 anos
4	0.1	0.1	0.5	Mulher	negróide	mais de 50 anos
5	0.1	0.1	0.2	Mulher	negróide	entre 20 e 29 anos
6	0.1	0.9	0.2	Mulher	caucasóide	entre 20 e 29 anos
7	0.1	0.1	0.2	Mulher	negróide	entre 20 e 29 anos
8	0.1	0.1	0.4	Mulher	negróide	entre 40 e 49 anos
9	0.1	0.1	0.5	Mulher	negróide	mais de 50 anos
10	0.1	0.9	0.5	Mulher	caucasóide	mais de 50 anos
11	0.1	0.1	0.4	Mulher	negróide	entre 40 e 49 anos
12	0.1	0.1	0.3	Mulher	negróide	entre 30 e 39 anos
13	0.1	0.9	0.2	Mulher	caucasóide	entre 20 e 29 anos
14	0.9	0.1	0.2	Homem	negróide	entre 20 e 29 anos
15	0.9	0.1	0.2	Homem	negróide	entre 20 e 29 anos
16	0.9	0.1	0.3	Homem	negróide	entre 30 e 39 anos
17	0.9	0.1	0.2	Homem	negróide	entre 20 e 29 anos
18	0.9	0.1	0.5	Homem	negróide	mais de 50 anos
19	0.9	0.9	0.2	Homem	caucasóide	entre 20 e 29 anos
20	0.9	0.1	0.3	Homem	negróide	entre 30 e 39 anos
21	0.9	0.9	0.5	Homem	caucasóide	mais de 50 anos
22	0.9	0.1	0.5	Homem	negróide	mais de 50 anos
23	0.9	0.1	0.5	Homem	negróide	mais de 50 anos
24	0.9	0.1	0.5	Homem	negróide	mais de 50 anos
25	0.9	0.1	0.5	Homem	negróide	mais de 50 anos
26	0.9	0.1	0.5	Homem	negróide	mais de 50 anos

Quadro 23

Análise do Desempenho da Rede Neural - 2

ACERTOS E ERROS DAS SAÍDAS DA REDE NEURAL			
Ind	SEXO	RAÇA	IDADE
1	OK	OK	OK
2	OK	OK	OK
3	OK	OK	OK
4	OK	OK	ERRO
5	OK	OK	OK
6	OK	OK	OK
7	OK	ERRO	OK
8	OK	OK	OK
9	OK	OK	ERRO
10	OK	OK	ERRO
11	OK	OK	ERRO
12	OK	OK	ERRO
13	OK	OK	OK
14	OK	OK	OK
15	OK	OK	OK
16	OK	OK	OK
17	OK	OK	OK
18	OK	OK	OK
19	OK	OK	OK
20	OK	OK	OK
21	OK	ERRO	OK
22	OK	OK	OK
23	OK	OK	OK
24	OK	OK	OK
25	OK	OK	OK
26	OK	OK	OK

PORCENTAGEM DE ACERTOS		
SEXO	100.00	% de acerto
RAÇA	92.31	% de acerto
IDADE	80.77	% de acerto
TOTAL	86.54	% pelo threshold
	96.15	% pela rede neural

Quadro 24

Análise do Desempenho da Rede Neural – 3

INTERPRETAÇÃO DE CLASSES DISTINTAS PELA RNA		
SEXO	Fem.	Masc.
Fem.	13	0
Masc.	0	13
TOTAL	13	13

Quadro 25

Análise do Desempenho da Rede Neural – 4

INTERPRETAÇÃO DE CLASSES DISTINTAS PELA RNA			
RAÇA	Negr.	Cauc.	Mong.
Negr.	19	0	0
Cauc.	1	4	0
Mong.	0	1	1
TOTAL	20	5	1

Quadro 26

Análise do Desempenho da Rede Neural – 5

INTERPRETAÇÃO DE CLASSES DISTINTAS PELA RNA				
IDADE	20<	30<	40<	50<
20<	9	1	0	0
30<	0	3	1	0
40<	0	0	1	3
50<	0	0	0	8
TOTAL	9	4	2	11

Quadro 27

Análise do Desempenho da Rede Neural – 6




Figura 40

Análise do Desempenho da Rede Neural (QwickNet)

Idade aproximada

5 Conclusões e Recomendações

5.1 Conclusões

Um novo método para abordar um problema objetivando solução total, parcial ou melhor que o anterior é o propósito de todo pesquisador. No entanto a cada novo método toma-se por base os conhecimentos anteriores.

O Método de Classificação Cefalométrica Utilizando Redes Neurais descrito neste trabalho, confronta os métodos estatísticos tradicionais com o método utilizando redes neurais. Mesmo que o modelo de Redes Neurais Artificiais assemelhe-se a modelos de inferência estatística (modelos de regressão, análise discriminante e generalização linear), as RNAs estão altamente relacionadas ao conceito de aprender por generalização.

Os processos de treinamento apesar de ser na maior parte empírico, requisita do pesquisador um conhecimento aprofundado de Inteligência Artificial e da ferramenta utilizada. Provavelmente a aplicação de algoritmos genéticos na escolha dos processos de aprendizagem facilite as configurações da rede neural.

Os métodos de classificação cefalométrica atualmente empregados tem sido de grande ajuda à identificação dos restos mortais de um indivíduo, mas não superam a maleabilidade com que as Redes Neurais aprendem, sem que seja necessária a identificação do propósito da base de dados estudada.

5.2 Limitações da pesquisa

Apesar de o método alcançar 96,15% de acerto, essa porcentagem possivelmente se manterá estável quando se estuda isoladamente algumas características como o sexo e idade craniana. No entanto, essa taxa de acerto poderá diminuir em virtude das características raciais dependentes do grau de miscigenação.

As Redes Neurais são capazes de se adaptar a uma nova base de dados, mas seria necessário estudar exemplos de crânios, inclusive fósseis, de todo o planeta. O universo estudado ainda é pequeno diante da variabilidade antropométrica encontrada nos povos.

5.3 Trabalhos Futuros

A aplicação do método de classificação cefalométrica utilizando redes neurais traz uma contribuição aos estudos e pesquisas antropológicas de caráter genealógico. Por essa razão o refinamento da técnica é desejado, podendo-se introduzir métodos de computação evolucionária e lógica fuzzy para o aprimoramento dos resultados.

Há também a oportunidade de estudos de anomalias de crescimento craniano e desenvolvimento de programas de computador para as áreas de Ortodontia, Anatomia e Odontologia Legal.

6 Referências Bibliográficas

(INTERNET) Artificial Intelligence FAQ. <http://www.cis.ohio-state.edu/hypertext/faq/usenet/ai-faq/general/top.html>

(INTERNET) CARDON, A.; MÜLLER, D. N.; NAVAUX, P. O. A. Introdução às Redes Neurais Artificiais. Nov. 2000. <http://www.ulbra.tche.br/danielnm/ia/rna/rna.html>.

(INTERNET) FAHLMAN, S. E. An Empirical Study of Learning Speed in Back-Propagation Networks. Carnegie Mellon University: Computer Science Technical Report CMU-CS-88-162. Set. 1988. <http://www.cs.cmu.edu/Reports/index.html> . www.boltz.cs.cmu.edu/tech-report.html.

(INTERNET) FIESLER, E. Comparative Bibliography of Ontogenic Neural Networks. Procedente da International Conference on Artificial Neural Nets - ICANN'94. Sorrento – Italy: Maio1994. <http://www.idiap.ch/idiap-networks.html>.

(INTERNET) KRÖSE, B. J. ; SMAGT, P. V. D. An Introduction to Neural Networks. University of Amsterdam: 1993. <http://www.fwi.uva.nl/research/ias/>. <ftp://ftp.wins.uva.nl/pub/computer-systems/aut-sys/reports/neuro-intro/>

(INTERNET) KUHN, M.L.S.; REIS, J.E.S. Da perícia medico legal na identificação humana. www.geocities.com/hotsprings/villa/1696/indintifi-ml.html. Jun. 1999.

(INTERNET) McCOLL, P. When to use (or not!) a BP Neural Network Solution. An Introduction to Back-Propagation Neural Networks. <http://www.seattlerobotics.org/encoder/nov98/neural.html>.

(INTERNET) Neural-Nets FAQ. <http://www.cis.ohio-state.edu/hypertext/faq/usenet/ai-faq/neural-nets/top.html>

(INTERNET) SABATTINI, R.M.E. The Evolution of Human Intelligence. 1ª publ. Fev. 2001. Brain and Mind Magazine. http://www.epub.org.br/cm/n12/mente/evolution/evolution_i.html

(INTERNET) SCHIFMANN, W. ; JOOST, M. ; WERNER, R. Optimization of the Backpropagation Algorithm for Training Multilayer Perceptrons. Technical Report, Universidade de Koblenz - Alemanha. Set. 1995. Web: <http://www.uni-koblenz.de/~schiff/publications.html>

ALCÂNTARA, H. R. Perícia Médica Judicial. Rio de Janeiro: Guanabara Dois. 1982. Pág. 367.

ALMEIDA JÚNIOR, A. ; COSTA JÚNIOR, J. B. O. Lições de medicina legal. 12ª ed. São Paulo: Companhia Editorial Nacional, 1974. Pág. 59-65.

ALVES. E. S. Medicina Legal e Deontologia. Curitiba: Imprensa da Universidade

Federal do Paraná, 1965. p. 82-97. Apud: GALVÃO, L.C.C. Estudos Médico-Legais.

ARBIBI, M.A. The Handbook of Brain Theory and Neural Networks. Massachusetts: MIT Press, 1995.

ÁVILA, J. B. Introdução à Antropologia Física. Rio de Janeiro: Editora Agir. 1958. Pág 324.

AZEVEDO, F. M. Algoritmos Genéticos em Redes Neurais Artificiais. São José dos Campos: ITA. V Escola de Redes Neurais. 1999.

BARRETO, J. M. Conexionismo e a Resolução de Problemas. Florianópolis: Dissertação do Departamento de Informática e Estatística da UFSC.1996.

BARRETO, J. M. Redes Neurais - Aspectos matemáticos e computacionais. Universidade Federal do Maranhão: Escola de Matemática Computacional. Sociedade Brasileira de Matemática Aplicada e Computacional.1996.

BAUMGART, S. R.; HERRMANN, W. M.; EILERS, R.; BES, F. Application of Evolutionary and Genetic Algorithms to Reduce the Feature Space and to Develop Classification Rules. Neuropsychobiology. MIT Press. 1998.

BONNET, E. F. P. Lecciones de Medicina legal. 5a ed. Buenos Aires: Lopez Libreiros Editores. 1978. Pág 116.

BORGES, S. R. Determinação do sexo de indivíduos adultos radiografias cefalométricas em norma lateral. Ribeirão Preto: USP. (Doutorado em ciências, área de Odontologia legal), Faculdade de Farmácia e Odontologia de Ribeirão Preto , 1967.

BRACE, C.L.; NELSON, H.; KORN, N.; BRACE M.L.: Atlas of human evolution. 2ª ed. Holt, Rinehart and Winston Publ. 1979

BRAGA, A. P.; CARVALHO, A.; LUDEMIR, T. B. Fundamentos de Redes Neurais Artificiais. Rio de Janeiro: 11ª Escola de Computação. UFRJ, 1998.

BRAGA, A. P.; CARVALHO, A.; LUDERMIR, T. B. Redes Neurais Artificiais - Teoria e Aplicações. Rio de Janeiro: Livro Técnico e Científico. UFRJ. 2000.

CAUDILL M.; BUTLER C. Understanding Neural Networks. Vol. 1: Basic Networks. Massachusetts: MIT Press.1994.

CUOZZO J.W. Buried alive - the startling truth about Neanderthal man. Green Forest - Arkansas: Master Books. 1998

DEAN, C.; LEAKEY, M.G.; REID, D.; SCHRENK, F.; SCHWARTZ, G.T.; STRINGER, C.B. Growth processes in teeth distinguish modern humans from Homo erectus and earlier hominins. Cape Town: Nature. 2001

DRUMMOND, R.A. A determination of cephalometric norms for the Negro race. 54ª ed. American Journal of Orthodontics.. 1968. Pág. 670-682

DUDA, R., HART, P.E. Pattern Classification and Scene Analysis. New York: John Wiley Publ. 1973.

FÁVERO, F. Medicina Legal - Introdução ao Estudo da Medicina Legal - Identidade, Traumatologia. 12ª ed. Belo Horizonte: 1991. Pág. 73-150.

FINLAY, L M. Craniometry and cephalometry - A history prior to the advent of radiography. 4a ed. Edinburgh: Edinburgh Encyclopedia.1980. Pág. 312-321

FRANCELIN, R.A. Uma Introdução a Redes Neurais. Anais do Workshop sobre Redes Neurais. São Carlos – SP: UFSCar. 1992.

FRIEDMAN, M.; KANDEL, A. Introduction to Pattern Recognition. Singapore: World Scientific. 1999

FUNDAÇÃO NACIONAL DO INDIO. Populações e culturas pré-históricas do Brasil. Brasília: Editora Gráfica Alvorada Ltda. 1993.

GALVÃO, L. C. C. Determinação do sexo através de medidas cranianas (Tese de Mestrado em ciências, Área de Odontologia legal e Deontologia) FOP-UNICAMP, 1994.

GALVÃO, L. C. C. Estudos Médico-Legais. Porto Alegre: Sagra - Luzzato Editores. 1996.

GAMBLE C. Timewalkers - The prehistory of global colonization. Cambridge-Massachussets: Harvard University Press. 1993.

GARCIA, C.J. Cephalometric evaluation of Mexican Americans using the Downs and Steiner analysis. 68ª ed. American Journal of Orthodontics. 1975. Pág. 67-74.

GILES, E.; ELLIOT, O. Sex determination by discriminant function analysis of crania. Massachusetts: Cambridge University. 1963.

GOMES, H. Medicina Legal. 20a ed. Rio de Janeiro: Livraria Freitas Bastos. 1969. Pág 54-55.

GORE, R.: Neandertals. 189ª ed. National Geographic. Jan. 1996. Pág. 2-35

GROVES C. Buried alive - The startling truth about Neanderthal man. 19ª ed. Reports of the National Center for Science Education. Fev. 1999. Pág. 27-9

HAYKIN, S. Redes Neurais: Princípios e prática. Porto Alegre: Ed. Bookman. 2001

HEEB, D. Organization of Behavior. New York: John Wiley & Sons Publ. 1949.

HERTZ, J.; KROGH, A.; PALMER, R.G. Introduction to the Theory of Neural Computation. California: Addison Wesley Publishing Company. 1991.

HRDLICKA, A. Normal micro- and macrocephaly in America - A study of extreme brain sizes in American skulls. 25ª ed. American Journal of Physical Anthropology. 1939 Pág. 1-91

- IMBELIONI, J. Fueguidos y Laguidos - Anales del Museo Argentino de Ciencias Naturales. Bueno Aires: Physis. 1937. Pág. 79-104.
- IMBELIONI, J. Tabela classificativa de los indios. Regiones biologicas y grupos raciales de America. Bueno Aires: Physis. 1938. Pág 229-249
- JACOBSON, A. The craniofacial pattern of the South African Negro. 73ª ed. American Journal of Orthodontics. 1978. Pág. 681-691
- KOVÁKS, Z. L. Redes Neurais Artificiais - Fundamentos E Aplicações. São Paulo: Ed.Collegium Cognitio. 1996
- LACERDA, J.B. O Homen dos Sambaquis. Arquivos do Museu Nacional. Brasil: 1885. Pág. 175-203
- LANGANEY, A. A natureza humanizada. Transcrito do Programa Oficial do IV encontro nacional de Ortodontistas da Sociedade Paulista de Ortodontia. Paris: Museu do Homem. Citado por Jean Robert Pitte. 1994
- LAWRENCE, J. Introduction to Neural Networks and Expert Systems. Nevada City - CA: California Scientific Software. 1992.
- LEE, A. & PEARSON, K. Data for the problem of evolution in man. - A first study of the correlation of the human skull. 1961. Pág. 225-264
- LOESCH, C e SARI, S. T. Redes Neurais Artificiais - Fundamentos e Modelos. Blumenau : FURB, 1996.
- MACHADO FILHO, J. Perfis dos tipos brasileiros, brancos, masculinos. Ortodontia. Brasil: 1969. Pág. 113-132.
- McCULLOCH, W. S. Embodiments of Mind. Cambridge - Massachusetts: MIT Press. 1965.
- MINSKY, M. L.; PAPERT, S. A. Perceptrons - An Introduction to Computational Geometry. Cambridge: MIT Press. 1988.
- NIELSEN, R.H. Neurocomputing. California: Addison Wesley Publ. 1990.
- OSÓRIO, F. S. Simulação de Redes Artificiais de Neurônios com Aprendizado Supervisionado. São Leopoldo: Scientia (Unisinos). 1992
- PEIXOTO, A. Medicina Legal. 3a ed. Rio de Janeiro: Livraria Francisco Alves. 1931. Pág. 362-363.
- PEREIRA, C. B.; ALVIM, M. M. Manual para estudos craniométricos e cranioscópicos. Santa Maria – RS: Imprensa Universitária (UFSM). 1979. Pág. 112-114
- PEREIRA. C.B. - Nosso estudo em crânios de Sambaquis Estudos no Material do Burlington Growth Center. (Universidade de Toronto – Canadá). São Paulo: Revista Paulista de Cirurgiões Dentistas. Vol. 40. 3ª ed. Maio. 1986.

RICH, E. ; KNIGHT, K. Inteligência Artificial. Rio de Janeiro: Ed. Makron Books. UFRJ. 1991

ROHR, A. Pesquisas páleo-etnográficas na Ilha de Santa Catarina. 3ª pesq. Florianópolis: UFSC. 1959. Pág. 199-264.

RUMELHART, D. E. ; HINTON, G. E. ; WILLIAMS, R. J. Learning Internal Representations by Error Propagation in Parallel Distributed Processing - Explorations in the Microstructure of Cognition Cambridge: MIT Press. 1986.

SADOWSKY, P. L.; JACOBSON, A. A comparative cephalometric analysis of South Africa adult caucasoids. 28ª ed. Journal of the Dental Association of South Africa. 1973. Pág. 274-276.

SHREEVE J. The neandertal enigma: solving the mystery of human origins - Covers current debates about Neandertals and the appearance of modern humans. New York: William Morrow Publ. 1995

SMITH, M. Neural Networks For Statistical Modeling. Ed. Boston, International Thomson Computer Press. 1996

SOUZA LIMA, J. A vida e obra de Luiz Lustosa Silva (considerado o "criador" da Odontologia legal). Rio de Janeiro: Conselho Federal de Odontologia. 1996.

TAFNER, M. A., XEREZ, M. ; RODRIGUES, I. W. Redes Neurais Artificiais - Introdução e Princípios de Neurocomputação. Blumenau: Editora EKO. 1995.

TOBIAS P.V. The brain of Homo habilis - A new level of organization in cerebral evolution. New York: Journal of Human Evolution. 1987.

TU, J.V. Advantages And Disadvantages Of Using Artificial Neural Networks Versus Logistic Regression For Predicting Medical Outcomes. Massachusetts: MIT Press. 1996.

UESATO, G.; KINOSHITA, K., KAWAMOTO, T.; KOYAMA, I; NAKANISCHI, Y. Steiner cephalometric norms for Japanese and Japanese Americans. American Journal of Orthodontics. 1978.

VASCONCELS, G. Lições de medicina legal. Rio de Janeiro: Editora Forense, 1970. Pág. 40

VESENTINI, J.W.; THOMAS, D. J.M.; PADILHA A. Sociedade e Espaço - Atlas das Raças Humanas. São Paulo: Editora Ática - 1.996

WASSERMAN, P.D. Advanced Methods In Neural Computing. New York: Ed. Van Nostrand Reinhold. 1993

WIDROW B. Generation and Information Storage in Networks of Adaline Neurons. Washington D. C.: Spartan Books. 1962.