UNIVERSIDADE DE SÃO PAULO
FACULDADE DE FILOSOFIA, CIÊNCIAS E LETRAS DE RIBEIRÃO PRETO
DEPARTAMENTO DE FÍSICA E MATEMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM FÍSICA APLICADA À MEDICINA E BIOLOGIA

**Redes neurais artificiais no apoio ao diagnóstico diferencial de
lesões intersticiais pulmonares**

PAULO EDUARDO AMBRÓSIO

Dissertação apresentada à Faculdade de Filosofia, Ciências e Letras de Ribeirão Preto, Universidade de São Paulo, como parte das exigências para a obtenção do título de Mestre em Ciências.
Área: Física Aplicada à Medicina e Biologia.

RIBEIRÃO PRETO – SP

2002

UNIVERSIDADE DE SÃO PAULO
FACULDADE DE FILOSOFIA, CIÊNCIAS E LETRAS DE RIBEIRÃO PRETO
DEPARTAMENTO DE FÍSICA E MATEMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM FÍSICA APLICADA À MEDICINA E BIOLOGIA

**Redes neurais artificiais no apoio ao diagnóstico diferencial de
lesões intersticiais pulmonares**

PAULO EDUARDO AMBRÓSIO

Orientador:

PROF. DR. PAULO MAZZONCINI DE AZEVEDO MARQUES

RIBEIRÃO PRETO – SP

2002

AMBRÓSIO, Paulo E.

Redes neurais artificiais no apoio ao diagnóstico diferencial de lesões intersticiais pulmonares. / Paulo Eduardo Ambrósio – Ribeirão Preto, 2002.
85 p.

Dissertação (Mestrado) – Faculdade de Filosofia Ciências e Letras de Ribeirão Preto, Universidade de São Paulo, 2002.

Orientador: Prof. Dr. Paulo Mazzoncini de Azevedo Marques.

1. Redes neurais artificiais. 2. Lesões intersticiais pulmonares.

Redes neurais artificiais no apoio ao diagnóstico diferencial de lesões intersticiais pulmonares

Paulo Eduardo Ambrósio

ORIENTADOR: Prof. Dr. Paulo Mazzoncini de Azevedo Marques

EXAMINADOR: _____

EXAMINADOR: _____

RIBEIRÃO PRETO – SP, _____ de _____ de 2002

Aos meus pais

Vanderlei e Maria Aparecida

Agradeço...

Ao Prof. Paulo, por sua orientação e incentivo no andamento da pesquisa.

Ao Fernando, pela valiosa contribuição na coleta de casos para a realização dos experimentos.

Ao Dr. Baddini, professor do Departamento de Clínica Médica da Faculdade de Medicina de Ribeirão Preto, pela ajuda nas definições iniciais do trabalho.

Ao Dr. José Antônio H. Rodrigues, médico assistente do Serviço de Radiodiagnóstico do Hospital das Clínicas da Faculdade de Medicina de Ribeirão Preto, pela análise das radiografias para a elaboração do banco de dados.

À minha esposa, Bernadete, pelo apoio e ajuda com os conceitos médicos.

A todas as outras pessoas que direta ou indiretamente contribuíram na realização desse trabalho.

***Experiência não é o que acontece
com um homem; é o que um homem
faz com o que lhe acontece.***

Aldous Huxley

SUMÁRIO

LISTA DE FIGURAS	9
LISTA DE TABELAS	10
RESUMO	11
ABSTRACT	12
INTRODUÇÃO	13
1 DOENÇAS PULMONARES	16
1.1 DOENÇAS PULMONARES INTERSTICIAIS	17
1.1.1 Diagnóstico das doenças intersticiais	18
1.2 DESCRIÇÃO DAS PATOLOGIAS INVESTIGADAS	18
1.2.1 Blastomicose sul-americana	19
1.2.2 Fibrose pulmonar idiopática (IPF)	20
1.2.3 Tuberculose miliar	22
1.2.4 Histoplasmoses	24
1.2.5 Sarcoidose	25
1.2.6 Silicose	26
1.2.7 Esclerose sistêmica (escleroderma)	28
1.2.8 Histiocitose X (granuloma eosinofílico)	30
1.2.9 Linfangite carcinomatosa	31
2 REDES NEURAIS ARTIFICIAIS	33
2.1 INTRODUÇÃO	33
2.2 UM POUCO DE HISTÓRIA	35
2.3 ALGUMAS VANTAGENS E DESVANTAGENS NA UTILIZAÇÃO DE REDES NEURAIS ARTIFICIAIS	37
2.4 ESTRUTURA DAS REDES NEURAIS ARTIFICIAIS	39
2.5 APRENDIZAGEM	42
2.5.1 Aprendizagem por correção de erro	43
2.5.2 Paradigmas de aprendizagem	45

2.6	PERCEPTRONS	45
2.6.1	<i>Perceptron</i> de camada oculta	46
2.6.2	<i>Perceptron</i> multicamadas	46
2.7	TREINAMENTO	48
2.7.1	Algoritmo de <i>backpropagation</i>	49
3	SISTEMAS DE APOIO AO DIAGNÓSTICO	52
3.1	SISTEMAS DE DIAGNÓSTICO EM RADIOLOGIA	54
3.2	SISTEMAS DE DIAGNÓSTICO MÉDICO BASEADOS EM REDES NEURAIS ARTIFICIAIS	56
3.3	REVISÃO DE TRABALHOS CORRELATOS	57
4	DESENVOLVIMENTO PRÁTICO	60
4.1	LEVANTAMENTO DE DADOS	60
4.1.1	Dados coletados	64
4.2	SISTEMA COMPUTACIONAL	64
4.2.1	Construção e configuração da rede neural	65
4.2.2	Base de dados para treinamento e testes	66
4.2.3	Treinamento do sistema e testes de performance	67
4.3	RESULTADOS E DISCUSSÕES	67
4.3.1	Dados obtidos	67
4.3.2	Aplicação de redes neurais artificiais	68
4.3.3	Configuração da rede neural	69
4.3.4	Treinamento da rede neural	70
4.3.5	Resultados alcançados	72
	CONCLUSÃO	73
	REFERÊNCIAS BIBLIOGRÁFICAS	75
	APÊNDICE A – NOTAÇÃO UTILIZADA	80
	APÊNDICE B – RELAÇÃO DE EQUAÇÕES MATEMÁTICAS	81
	APÊNDICE C – BASE DE DADOS	84

LISTA DE FIGURAS

Figura 1	Radiografia torácica de paciente do sexo masculino, 45 anos, diagnosticado com blastomicose sul-americana	20
Figura 2	Radiografia torácica de paciente do sexo masculino, 70 anos, diagnosticado com fibrose pulmonar idiopática	21
Figura 3	Radiografia torácica de paciente do sexo masculino, 18 anos, diagnosticado com tuberculose miliar	23
Figura 4	Radiografia torácica de paciente do sexo masculino, 20 anos, diagnosticado com histoplasmoze	25
Figura 5	Radiografia torácica de paciente do sexo masculino, 31 anos, diagnosticado com sarcoidose ..	26
Figura 6	Radiografia torácica de paciente do sexo masculino, 55 anos, diagnosticado com silicose	28
Figura 7	Radiografia torácica de paciente do sexo feminino, 46 anos, diagnosticada com esclerose sistêmica	29
Figura 8	Radiografia torácica de paciente do sexo feminino, 32 anos, diagnosticada com histiocitose X	31
Figura 9	Um neurônio artificial básico	39
Figura 10	(a) Função de limiar. (b) Função linear por partes. (c) Função sigmóide com parâmetro de inclinação a variável	41
Figura 11	Estrutura de um <i>perceptron</i> com uma camada oculta	48
Figura 12	Protocolo de entrada de dados do sistema	62
Figura 13	Gráfico do erro médio obtido no treinamento da rede neural, após 2000 épocas	70
Figura 14	Gráfico do erro médio obtido no treinamento da rede neural, após 5000 épocas	71
Figura 15	Exemplos de gráficos de erro médio obtidos no treinamento da rede neural, em diferentes configurações	71

LISTA DE TABELAS

Tabela 1	Codificação numérica das patologias investigadas, para a implementação computacional	66
Tabela 2	Exemplo de registros da base de dados	66
Quadro 1	Percentuais de acerto obtidos pelo sistema	72
Tabela 3	Base de dados completa	84

RESUMO

Nos últimos tempos, observa-se um grande crescimento na utilização de computadores como ferramenta de auxílio nas mais diversas áreas, sendo a Medicina uma das principais áreas dessa utilização. Inúmeras aplicações da Informática podem ser encontradas na área médica, citando-se os sistemas de apoio ao diagnóstico como uma das mais marcantes. Esses sistemas têm como principal objetivo auxiliar o profissional da área no processo de tomada de decisões, o qual pode ocorrer em diferentes etapas de sua atividade. Esse processo normalmente envolve uma grande quantidade de dados e informações, que podem ser armazenadas e processadas muito mais rapidamente por computador. O objetivo principal desse trabalho é o desenvolvimento de um sistema computacional baseado na técnica de redes neurais artificiais, para auxílio ao médico radiologista na confirmação de diagnóstico das chamadas lesões intersticiais pulmonares. O exame radiológico para esse grupo é de difícil interpretação mesmo para profissionais bem treinados, visto o grande número de patologias assim classificadas e a semelhança entre elas. Os dados para treinamento da rede neural são obtidos por protocolo gerado por especialistas, através da revisão de casos com diagnóstico confirmado para determinadas patologias. O sistema desenvolvido é baseado em uma rede neural do tipo *perceptron* multicamadas, que funciona como um classificador de padrões – dado um conjunto de dados de entrada, a saída é classificada entre determinadas patologias. Nessa pesquisa, são levantados elementos para justificar a utilização de redes neurais artificiais em sistemas de apoio ao diagnóstico, objetivando uma ferramenta confiável para o auxílio ao profissional no seu dia-a-dia, e também uma ferramenta educacional de auxílio ao treinamento e qualificação para os estudantes da área médica.

ABSTRACT

It is observed that a big growing in the use of computers as a tool to help in several areas, specially in medicine, happened in the past years. A big number of applications of these computers can be found in Medicine, such as the Diagnosis Support System, which is one of the most remarkable. These systems have as its main objective to help in the phases its activity. This process usually involves a lot of data and information, which can be stored by a computer very quickly. The most important objective of this project is the development of a computer system based in artificial neural network to help the Radiologist in the confirmation of the diagnosis of the so-called Interstitial Lung Disease. The radiological examination for this group has a difficult interpretation even to well-trained professionals, due to the big number of classified as well as similar pathologies in this area. The data for the neural net are obtained through a protocol generated by specialists, through the review of cases with confirmed diagnosis for certain pathologies. The developed system is based in a kind of multilayer perceptron neural net, which run as a classifier of patterns. A number of data is given as entry data, afterwards the exit is classified among certain pathologies. In this research, elements to justify the use of the artificial neural net in diagnosis support systems are raised, objectifying a reliable tool to help professionals who use it day by day and also as an educational tool to help in the training and qualification of medical school students.

INTRODUÇÃO

Nos últimos anos, observa-se uma grande mudança no modo de vida das pessoas, sendo uma das principais causas dessa mudança a crescente massificação da Informática no cotidiano. O computador vem cada vez mais aumentando sua influência nas mais diversas áreas de atuação devido a constantes melhorias em qualidade e desempenho, e sua rápida evolução nos tem apresentado equipamentos cada vez menores e mais acessíveis ao grande público. Esta evolução acelerada da Informática tem motivado cada vez mais a comunidade científica a intensificar seus estudos na área, o que, conseqüentemente, ajuda na evolução da própria Informática e de seu papel como ferramenta de auxílio para todas as demais ciências. Pode-se perceber, atualmente, a Informática contribuindo para o desenvolvimento científico em praticamente todas as áreas do conhecimento.

Um interessante fenômeno notado é que de cada área em que a Informática entra como ferramenta de auxílio, ela se apropria de parte do conhecimento daquela área para si mesma, gerando novas idéias e propostas. Um exemplo desta interação é a técnica de redes neurais artificiais, que se fundamenta nas teorias que se conhecem a respeito dos neurônios do cérebro humano, objetivando a reprodução de comportamentos computacionalmente inteligentes, como por exemplo, o reconhecimento de padrões.

A utilização de computadores como ferramenta de auxílio à tomada de decisões encontra na Medicina uma de suas principais áreas de aplicação. Inúmeras atividades relacionadas à Informática podem ser encontradas na área médica, citando-se os sistemas de apoio ao diagnóstico como uma das mais marcantes. Esses sistemas têm como principal objetivo auxiliar o profissional da área no processo de tomada de decisões, o qual pode ocorrer em diferentes etapas de sua atividade.

O objetivo deste trabalho foi o desenvolvimento de um sistema computacional de apoio ao diagnóstico de um grupo de patologias classificadas

como lesões intersticiais pulmonares, com o intuito principal de se verificar a validade da utilização da técnica de redes neurais artificiais para esse fim.

Este desenvolvimento foi iniciado com a definição de quais patologias, dentre um universo com mais de 180 tipos, seriam levantadas para o estudo, contando-se com o auxílio de um médico especializado na área, chegando-se às seguintes: blastomicose sul-americana, fibrose pulmonar idiopática, tuberculose miliar, histoplasmose, sarcoidose, silicose, esclerodermia, histiocitose X e linfangite carcinomatosa. Em seguida, levantou-se os principais parâmetros a serem observados no exame clínico e radiológico que podem auxiliar no diagnóstico diferencial.

O desenvolvimento prático do trabalho consistiu em duas etapas principais: a) levantamento de casos clínicos, utilizados para o treinamento do sistema; b) implementação computacional do sistema.

O sistema computacional desenvolvido neste trabalho é baseado na técnica de redes neurais artificiais do tipo *perceptron* multicamadas (MLP – *Multi-Layer Perceptron*), que consiste em uma série de elementos de processamento, denominados neurônios artificiais, ou nós, interligados entre si, com um determinado peso associado a cada conexão. A opção por esse tipo de rede se deu pelo fato de o problema tratado ser basicamente uma classificação de amostras em determinados padrões, sendo essa a principal aplicação dos *perceptrons*.

O algoritmo de treinamento utilizado foi do tipo *backpropagation*, que é baseado em uma análise dos erros de resposta do sistema para os ajustes necessários na rede. O algoritmo de *backpropagation* consiste na apresentação, a cada época de treinamento, de um conjunto de dados de entrada com seus respectivos resultados esperados; a cada erro obtido na saída é associado um valor que retorna pela rede para ser utilizado na correção dos pesos de conexão entre os neurônios.

Para o levantamento dos casos clínicos, todos coletados no Hospital das Clínicas da Faculdade de Medicina de Ribeirão Preto (HCFMRP), primeiramente fora realizada uma pesquisa nos arquivos do hospital para levantamento dos casos registrados com diagnóstico para uma das patologias investigadas. Após esse levantamento, eliminou-se todos os registros em que não houvesse uma comprovação concreta do diagnóstico. Esses registros foram levados para a análise de um médico especializado, o qual excluiu os que apresentavam a patologia como

causa secundária. Desse conjunto de elementos já bastante reduzido, realizou-se então, com a ajuda de um médico radiologista, a análise das radiografias encontradas, e o preenchimento do protocolo utilizado como entrada de dados para o sistema.

Esta dissertação vem apresentar os resultados obtidos neste trabalho, bem como algumas definições das doenças estudadas e das redes neurais artificiais.

No primeiro capítulo são feitas algumas definições de doenças intersticiais pulmonares, técnicas de diagnóstico e uma descrição detalhada de cada uma das nove doenças envolvidas neste trabalho, com seus aspectos radiológicos mais característicos.

O Capítulo 2 é dedicado às redes neurais artificiais, dando ênfase às redes do tipo *perceptron* multicamadas e ao algoritmo de aprendizado *backpropagation*.

No terceiro capítulo são apresentadas definições de sistemas de apoio ao diagnóstico, sistemas de diagnóstico em radiologia e sistemas baseados em redes neurais artificiais. Nesse capítulo também é apresentada uma revisão bibliográfica da área.

No Capítulo 4 é feita uma revisão dos objetivos básicos do trabalho e da metodologia utilizada, e relatado o desenvolvimento prático do trabalho. O levantamento de dados é apresentado na seção 4.1. O sistema computacional é tratado na seção 4.2. A seção 4.3 apresenta os resultados obtidos e as discussões.

1 DOENÇAS PULMONARES

Os pulmões são os órgãos responsáveis por isolar o oxigênio do ar e difundi-lo no sangue. Localizam-se na caixa torácica, um à direita e outro à esquerda, e a preenchem quase totalmente. O espaço central entre os pulmões direito e esquerdo, o mediastino, é ocupado pelo coração, vasos sanguíneos, traquéia, timo, esôfago e troncos nervosos. Cada um dos pulmões apresenta a forma de um cone irregular, com cerca de 25 cm de altura, mas não são perfeitamente iguais – o direito é maior e é dividido por duas fissuras em três partes (ou lobos) e o esquerdo apresenta apenas uma fissura e portanto apenas dois lobos.

Muitos fatores diferentes podem afetar o aparelho respiratório e provocar dificuldades respiratórias. Os mais comuns são as infecções provocadas por vírus e bactérias, tais como as gripes, que afetam o nariz e a garganta, a laringite e a bronquite. Outros vírus e bactérias são responsáveis pela tuberculose e pela pneumonia, que afetam os pulmões e os tecidos que os rodeiam. Existem ainda as infecções recorrentes, por exposição ao pó e ao fumo, que podem afetar o funcionamento dos pulmões, levando a aumento da acumulação de ar nos alvéolos pulmonares.

Uma das principais ferramentas para a detecção de doenças dos pulmões é o exame radiológico do tórax.

O exame radiológico do tórax é extremamente importante no diagnóstico das doenças pulmonares. A radiografia de tórax serve como registro da existência ou não de doença na época em que foi realizada, e os exames de acompanhamento podem revelar o seu progresso ou desenvolvimento.

É importante salientar que o exame radiológico não deve suplantiar o exame físico de rotina e a anamnese. Tudo deve ser trabalhado e analisado em conjunto para um correto diagnóstico.

Embora existam técnicas de diagnóstico mais modernas e completas que a radiografia simples do tórax, esta é talvez a técnica mais utilizada, principalmente por ser relativamente de baixo custo, apresentando resultados satisfatórios na maioria dos casos.

Um importante grupo de doenças que atinge o aparelho respiratório é o denominado doença intersticial, que recebe este nome pelo fato de “os primeiros casos de moléstias desse grupo terem sido reconhecidos apenas em fases avançadas de sua evolução, quando mostravam acentuada deposição de tecido fibroso no interstício periférico.” [Martinez, 1998, p.247].

1.1 DOENÇAS PULMONARES INTERSTICIAIS

Para uma breve descrição conceitual das chamadas doenças intersticiais pulmonares, recorremos a [Martinez, 1998]:

“A denominação, doença intersticial pulmonar (DIP), é normalmente empregada para designar um grupo numeroso e heterogêneo de patologias, caracterizadas pelo desenvolvimento de infiltrados celulares, e/ou pela deposição de matriz extracelular, nos espaços aéreos distais aos bronquíolos terminais. Como esses processos acometem as mesmas regiões dos pulmões, eles adquirem características clínicas, radiológicas e funcionais muito semelhantes, o que não só justifica a sua inclusão num único grupo, como também explica as dificuldades envolvidas com os seus diagnósticos específicos” [p.247].

O grupo das doenças intersticiais pulmonares é composto por mais de cento e oitenta diferentes patologias [Martinez, 1998]. Embora consideradas moléstias graves, os casos registrados dessas patologias vêm aumentando significativamente, devido ao surgimento de novos agentes agressores pulmonares.

1.1.1 Diagnóstico das doenças intersticiais

Como comentado anteriormente, uma das principais técnicas para diagnóstico de doenças pulmonares e provavelmente a mais utilizada é a investigação radiológica, sempre acompanhada pelo exame físico e anamnese.

No contexto do histórico clínico, normalmente os pacientes se queixam da presença freqüente de dispnéia há meses ou anos. Parâmetros importantes que devem ser questionados e levados em conta incluem a presença ou não de febre, se o paciente é fumante, se é constantemente exposto à poeira, uso de medicamentos ou outras substâncias tóxicas tanto no presente como no passado, entre outros.

Com relação ao diagnóstico através da radiografia simples de tórax, Martinez [1998, p.249] coloca que “Embora permita o diagnóstico sintômico da doença, é de pouca utilidade no diagnóstico diferencial entre os diferentes processos”, porém, como já citado, é uma técnica de exame muito utilizada principalmente por questões financeiras.

Pode-se citar como principais parâmetros a serem analisados na avaliação radiológica, entre outros, a localização das lesões no pulmão, a homogeneidade dessas lesões, a perda do volume pulmonar e a constatação do “pulmão em favo de mel”.

1.2 DESCRIÇÃO DAS PATOLOGIAS INVESTIGADAS

Apesar da grande quantidade de doenças classificadas no grupo das doenças intersticiais, como fonte de dados para o desenvolvimento desta pesquisa foram escolhidas nove, devido a seu grau de incidência, relevância clínica e dificuldade no diagnóstico diferencial. São elas: blastomicose sul-americana, fibrose pulmonar idiopática (IPF), tuberculose miliar, histoplasmose, sarcoidose, silicose, esclerose sistêmica (escleroderma), histiocitose X (granuloma eosinofílico), e linfangite carcinomatosa.

A seguir são feitas pequenas descrições¹ individuais das patologias investigadas neste estudo, com alguns detalhes dos aspectos radiológicos, que constituem o material foco deste trabalho.

1.2.1 Blastomicose sul-americana

A blastomicose sul-americana, doença descrita pela primeira vez por Adolfo Lutz, em 1908, ocorre com grande freqüência no Brasil, Argentina, Paraguai e Venezuela, e têm sido descritos casos no México e na América Central. Atinge mais freqüentemente homens entre 20 e 50 anos, sobretudo os trabalhadores em zona rural e/ou na lavoura.

O agente etiológico da blastomicose sul-americana é o *Paracoccidioides brasiliensis*, fungo de forma arredondada, com parede dupla, nítida e espessa, apresentando-se isolado ou em gemulação. O parasito encontra-se na lesão, que é constituída por um granuloma de células gigantes semelhante ao da tuberculose e ao do corpo estranho. As lesões costumam evoluir para fibrose, após passarem pelas fases exsudativa e produtiva. Às vezes, na fase exsudativa, os focos, ao se fundirem, dão origem a cavernas.

Em cerca de 80 por cento dos casos de blastomicose sul-americana o pulmão se encontra comprometido. A sintomatologia respiratória é variável, dependendo do grau de comprometimento do pulmão. Raramente a doença se manifesta com sinais ou sintomas de infecção respiratória aguda, e quando isso ocorre, a hipótese diagnóstica de micose não costuma ser averiguada. Em geral, confunde-se com a tuberculose, e esta é a primeira hipótese a ser afastada.

Aspectos radiológicos

O aspecto radiológico da blastomicose sul-americana depende do estado evolutivo da doença e das condições do pulmão antes de ser atingido pelo

¹ Frisa-se que todas as descrições aqui apresentadas foram transcritas e/ou adaptadas dos textos encontrados em [Tarantino, 1982]; [Cukier *et al.*, 1997]; [Robbins *et al.*, 1986].

parasito. Os aspectos radiológicos nas formas mais avançadas se apresentam como lesões bilaterais extensas, rudimentarmente comparáveis a flocos de algodão. Quando as lesões se cronificam, determinam enfisema localizado com formação de vesículas de tamanho variável e cavernas. As principais características das lesões pulmonares da blastomicose são: bilateralidade; simetria; preferência pelos terços médios e bases, poupando os ápices; ausência de adenomegalias; cavernas pouco freqüentes, relativamente pequenas e de paredes irregulares.

Figura 1 Radiografia torácica de paciente do sexo masculino, 45 anos de idade, diagnosticado com blastomicose sul-americana.

1.2.2 Fibrose pulmonar idiopática (IPF)

Descrita originalmente por Hamman e Rich, em 1944, como “fibrose intersticial difusa aguda dos pulmões”. Atualmente, o termo fibrose é de uso habitual na literatura de doença intersticial para descrever as alterações do colágeno que são características dessas doenças. As fibroses intersticiais se caracterizam pelo envolvimento difuso pulmonar, com evolução aguda, subaguda ou crônica.

A doença é encontrada igualmente em indivíduos de ambos os sexos, e em todas as idades, desde a infância até a velhice. É tida como uma doença mais ou menos rara, com alta taxa de mortalidade.

A gravidade dos sintomas que surgem na doença está relacionada com a extensão e a distribuição das lesões pulmonares. O principal sintoma é a dispnéia acompanhada de taquipnéia. O exame clínico revela que há febre em muitos casos.

Aspectos radiológicos

Nas formas agudas e subagudas, o quadro radiológico poderá ser caracterizado apenas por um velamento difuso e homogêneo, conferindo ao pulmão um aspecto a que se chama de vidro fosco. Esse velamento difuso pode apresentar sombras mais densas isoladas ou confluentes, sobretudo nas bases.

Na forma crônica, o aspecto mais comum é o aparecimento de sombras lineares finas ou nodulares de pequeno tamanho, difusas por todo o pulmão, mas com localização predominante nas bases. Com o correr do tempo tais sombras tornam-se mais grosseiras, podendo ocasionar o surgimento de translucências de diâmetro de 2 a 3 mm, ocupando uma posição central e rodeadas pelas imagens nodulares ou lineares que se comportam como finas paredes das mesmas. Esse aspecto é semelhante ao pulmão em favo de mel.

Figura 2 Radiografia torácica de paciente do sexo masculino, 70 anos de idade, diagnosticado com fibrose pulmonar idiopática.

1.2.3 Tuberculose miliar

A tuberculose é uma doença contagiosa granulomatosa aguda ou crônica que envolve o pulmão, podendo porém, afetar qualquer tecido ou órgão do organismo. Embora na América do Norte e Europa tenha ocorrido nítido declínio na incidência e mortalidade pela doença desde o início do século vinte, a tuberculose permanece como uma das principais causas mundiais de morte.

O agente etiológico da tuberculose é o *Mycobacterium tuberculosis*, identificado por Robert Koch em 1882. O bacilo de Koch, como é chamado, é um bastonete fino e longo, medindo 2 a 4 micrômetros de extensão por apenas 0,2 a 0,5 micrômetros de espessura. Não tem flagelos nem esporos e não possui toxinas. É transmitido principalmente pelo ar.

A tuberculose primária é a forma de doença que se desenvolve em indivíduo previamente não exposto, e portanto não sensibilizado, infectado com o bacilo. Na sua via inicial habitual de entrada, o bacilo inalado implanta-se nas superfícies alveolares do parênquima pulmonar, mais freqüentemente nas porções baixas do lobo superior ou porções superiores do lobo inferior, geralmente mais para a periferia do pulmão. Na grande maioria dos indivíduos, a única seqüela dessa tuberculose primária é uma densidade radiológica focal das lesões calcificadas no parênquima pulmonar e nos gânglios linfáticos, porém, em 5 a 15% dos casos, especialmente entre crianças pré-escolares, a infecção primária não segue esse curso, e várias possíveis complicações podem desenvolver-se. No hospedeiro particularmente vulnerável pode ocorrer uma disseminação mais ampla da infecção, quando os bacilos ganham acesso à corrente sanguínea através do duto torácico. Às vezes, ocorre a contaminação direta do sangue, quando um tubérculo erode num vaso vizinho. Quando a invasão da corrente sanguínea é maciça, surge a **tuberculose miliar aguda**.

A tuberculose miliar aguda pode apresentar um início súbito, violento ou pode desenvolver-se durante o curso de algumas semanas. Em qualquer das situações ocorre uma profunda prostração e febre elevada; quando o comprometimento dos pulmões é amplo, pode ocorrer tosse e dispnéia.

Aspectos radiológicos

Em função da multiplicidade de manifestações radiológicas da tuberculose e conseqüentemente do grande número de diagnósticos diferenciais possíveis, a especificidade da radiologia deixa a desejar, sobretudo quando avaliada por profissionais pouco habituados a sua interpretação.

As características radiológicas clássicas da tuberculose são os infiltrados heterogêneos, localizados nos segmentos superiores e posteriores dos pulmões; a presença de cavitação; a característica retrátil das lesões; a existência de lesões satélites à lesão principal; e a possibilidade de acompanhamento de derrame pleural. Entretanto, quando a tuberculose está associada a imunodeficiências, sua manifestação radiológica pode não ser típica.

Figura 3 Radiografia torácica de paciente do sexo masculino, 18 anos de idade, diagnosticado com tuberculose miliar.

1.2.4 Histoplasmose

A histoplasmose é uma infecção micótica causada pelo *Histoplasma capsulatum* (fungo descoberto por Samuel Darling, em 1905), que penetra no organismo por inalação ou por ingestão e atinge especialmente o sistema reticuloendotelial, produzindo ora uma simples histoplasmose-infecção, ora uma histoplasmose-doença.

É uma infecção que imita a tuberculose de vários modos. Inicia-se geralmente como uma infecção pulmonar primária localizada e freqüentemente assintomática, podendo então progredir para um comprometimento pulmonar mais disseminado, às vezes cavitário e, nos indivíduos predispostos, pode disseminar-se num padrão miliar.

A histoplasmose pode determinar quadros clínicos agudos, subagudos ou crônicos, ou apenas uma infecção latente, sem outras manifestações. O quadro clínico da histoplasmose-doença é comum a muitas infecções, caracterizando-se por febre irregular, anemia, leucopenia e hepatoesplenomegalia.

Aspectos radiológicos

Na fase aguda da doença observam-se imagens infiltrativas densas, verdadeiras áreas de condensação que em nada diferem do aspecto das pneumonias bacterianas e da tuberculose.

As lesões radiológicas podem assumir os seguintes aspectos: nódulo único de contornos bem definidos; condensação pneumônica mal-definida, sem localização preferencial e indistinguível da pneumonia bacteriana aguda ou da tuberculose; nódulos múltiplos e lesão tipo pneumônica, que costumam ser as manifestações mais freqüentes da doença, onde os infiltrados contêm áreas de densidade diferente, são irregulares e bilaterais; miliar.

Figura 4 Radiografia torácica de paciente do sexo masculino, 20 anos de idade, diagnosticado com histoplasmose.

1.2.5 Sarcoidose

Sarcoidose é a alteração granulomatosa de etiologia desconhecida que atinge mais comumente os jovens adultos e se manifesta por linfadenopatia hilar bilateral, infiltração pulmonar e lesões cutâneas ou oculares.

As causas da sarcoidose ainda são desconhecidas. A tuberculose sempre foi considerada, quando não a responsável pela sarcoidose, sua companheira inseparável.

A maneira mais comum de se diagnosticar a sarcoidose é pela radiografia do tórax, constituindo em um grande número de casos achado radiológico ocasional. Um fato que desde o início chama a atenção, sobretudo nas formas torácicas da doença, é a pobreza de sintomas e sinais em contraste com o aspecto radiológico. A fadiga, o emagrecimento e a febre mais ou menos elevada são sintomas usuais.

A sarcoidose se inicia com manifestações extrapulmonares em cerca de 40 por cento dos casos, sendo os órgãos mais comprometidos os olhos, a pele, os gânglios periféricos, o sistema nervoso e o coração.

Aspectos radiológicos

É no tórax que as lesões da sarcoidose adquirem a sua maior importância, fazendo com que a maioria das suspeitas diagnósticas parta de uma radiografia simples do tórax. Em um grande número de casos de sarcoidose, o primeiro diagnóstico costuma ser de tuberculose.

As lesões pulmonares são em geral bilaterais, mais ou menos simétricas, comprometem os terços médios de ambos os pulmões, predominando mais junto aos hilos do que na periferia, poupando os ápices e as bases adquirindo a forma de leque.

Basicamente, a sarcoidose se apresenta sob quatro aspectos radiológicos: adenomegalia hilar; lesões micronodulares; adenomegalia hilar e lesões parenquimatosas; fibrose.

Figura 5 Radiografia torácica de paciente do sexo masculino, 31 anos de idade, diagnosticado com sarcoidose.

1.2.6 Silicose

Silicose é a condição patológica crônica dos pulmões devido à inalação de partículas contendo sílica-livre ou não-combinada, dióxido de silício, SiO_2 . A sílica constitui cerca de 60% da crosta terrestre, apresentando-se na forma livre em rochas

(quartzo, areia), e na forma combinada com óxidos metálicos, formando os silicatos (feldspatos, argilas, caulins, etc.).

A silicose é a mais antiga, a mais comum, a mais grave e a mais importante das pneumoconioses, ou seja, o acúmulo de poeira nos pulmões e as reações teciduais provocadas pela sua presença. É reconhecida como “doença profissional ou do trabalho”, abrangida, portanto, no conceito legal de “acidente do trabalho”.

Normalmente, o organismo dispõe de uma série de mecanismos de proteção contra a inalação de qualquer tipo de poeira. As vias aéreas superiores dispõem de secreção mucosa abundante que retém as partículas, sendo posteriormente eliminadas. Fatores que predispõem a inalação de poeiras são: respiração pela boca; doenças broncopulmonares; tabagismo; idade. O tempo de exposição do trabalhador às poeiras silicosas tem papel fundamental no aparecimento das lesões pulmonares.

Na grande maioria dos casos de silicose o quadro clínico é pouco expressivo durante muitos anos após o início da exposição às poeiras nocivas. Os pacientes são praticamente assintomáticos ou referem tosse, dores torácicas não localizadas, episódios de bronquite ou queixas de ordem geral, tais como tonturas, fraqueza, sudorese, etc. A associação da tuberculose à silicose é relativamente grave pelo fato de ser diagnosticada muitas vezes tardiamente.

Aspectos radiológicos

É a radiologia, ao lado da anamnese profissional, que basicamente define o diagnóstico das pneumoconioses, e da silicose, em especial.

Chama a atenção, em muitos casos, a falta de correlação entre o quadro clínico, com a sintomatologia ausente ou escassa, e o quadro radiológico bastante sugestivo, com nodulação disseminada.

Para uma padronização nas leituras radiográficas das pneumoconioses, é feita uma classificação das opacidades pulmonares em **pequenas opacidades** (diâmetro máximo de 10mm) e **grandes opacidades**. As pequenas opacidades são subdivididas em **arredondadas** e em **irregulares**, e as grandes opacidades em **bem-definidas** e **mal-definidas**.

No diagnóstico diferencial radiológico é importante destacar a possível confusão com a tuberculose miliar, a sarcoidose, a carcinomatose e outras pneumoconioses.

Figura 6 Radiografia torácica de paciente do sexo masculino, 55 anos de idade, diagnosticado com silicose.

1.2.7 Esclerose sistêmica (escleroderma)

A esclerose sistêmica é uma enfermidade de caráter progressivo ou não, caracterizada por alterações inflamatórias e fibróticas por todo o interstício de vários órgãos do organismo. Anteriormente denominada escleroderma devido ao endurecimento predominante ocasionado no tegumento, atualmente o nome preferido é esclerose sistêmica, pois pode acometer vários órgãos e poupar a pele. A doença pode iniciar-se em qualquer idade, desde a infância até uma idade avançada, porém incide em maior proporção entre as idades de 30 a 50 anos. As mulheres são três vezes mais afetadas que os homens.

As manifestações clínicas podem ser localizadas ou generalizadas. Praticamente qualquer órgão pode estar afetado, porém as alterações mais proeminentes são encontradas na pele, sistema músculo-esquelético, trato intestinal, pulmões, rins e coração. O pulmão é acometido em cerca de 30 a 50% dos casos. Frequentemente desenvolve fibrose intersticial difusa dos septos alveolares, acompanhada de um progressivo espessamento das paredes dos pequenos vasos pulmonares.

Aspectos radiológicos

Os achados radiológicos na esclerose sistêmica são muito variáveis, indo do aspecto aparentemente normal à nodulação inicialmente fina, depois grosseira, de localização prevalente nos campos médios e bases. Nos casos avançados, o aspecto é de pulmão em favo de mel. A disposição das alterações pulmonares é do tipo intersticial.

Figura 7 Radiografia torácica de paciente do sexo feminino, 46 anos de idade, diagnosticada com esclerose sistêmica.

1.2.8 Histiocitose X (granuloma eosinofílico)

A histiocitose X é caracterizada morfológicamente por infiltração granulomatosa dos septos alveolares e paredes brônquicas por uma célula distinta, o histiócito. No estágio inicial do comprometimento pulmonar da doença podem ser observados grânulos ou nódulos disseminados medindo 1 a 10 mm de diâmetro, de cor pálida.

A etiologia é desconhecida, embora se suspeite de um agente infeccioso. Sob a denominação genérica de histiocitose X, incluem-se três variantes clínica e morfológicamente relativamente distintas: a doença de Letterer-Siwe, a doença de Hand-Schüller-Christian e o granuloma eosinofílico. Existem controvérsias quanto a estas entidades serem doenças distintas ou constituírem diferentes estágios ou expressões de um mesmo processo básico.

O granuloma eosinofílico é considerado a variante mais benigna. É encontrada principalmente em crianças mais velhas e adultos. Existe forte predominância no sexo masculino. Está geralmente confinado aos ossos ou raramente localizado na pele.

A doença pulmonar pode não ter repercussão clínica ou condicionar dispnéia, tosse, dores torácicas, hemoptises ou pneumotórax espontâneo. Os sintomas gerais são mais freqüentemente representados por perda de peso e febre.

Aspectos radiológicos

As alterações radiológicas são caracterizadas por comprometimento difuso, bilateral e simétrico. Diferenciam-se de outras doenças intersticiais por afetar preferencialmente as porções superiores dos campos pulmonares.

Os estágios avançados da doença caracterizam-se pela presença de um padrão reticulonodular que se une, particularmente nas zonas superiores, formando cistos que caracterizam o pulmão em favo de mel.

Figura 8 Radiografia torácica de paciente do sexo feminino, 32 anos de idade, diagnosticada com histiocitose X.

1.2.9 Linfangite carcinomatosa

A linfangite carcinomatosa é uma forma de metástase pulmonar que se caracteriza pela invasão e crescimento de células neoplásicas nos vasos linfáticos, e cuja via de disseminação atualmente mais aceita é a hematogênica, podendo ocorrer também por via linfática. Histologicamente, caracteriza-se pelo espessamento das estruturas de suporte do parênquima pulmonar e interstício, por tecido tumoral, fibrose e edema.

São causas comuns de linfangite carcinomatosa os tumores de pulmão, tubo digestivo (em geral o tumor do estômago), mama, colo do útero, pâncreas, próstata, tireóide e adenocarcinoma de origem indeterminada.

Desde o século XIX o câncer no pulmão tem aumentado em frequência ano a ano, adquirindo em alguns países caráter epidêmico.

É mais freqüente no homem do que na mulher, atualmente na proporção de 2,3 para 1. Incide mais na faixa etária dos 50 aos 70 anos, mais nos tabagistas e, finalmente, mais nos moradores de centros urbanos.

A história natural do câncer de pulmão caracteriza-se, de hábito, por evolução lenta, de modo que o tumor pode permanecer despercebido por muitos anos. Sabe-se que na fase sintomática o tumor já percorreu dois terços de sua vida, restando, portanto, apenas um terço para o diagnóstico e o tratamento. O fato de o diagnóstico ser tardio deixa a impressão de que o tumor é de desenvolvimento rápido e que os diversos tratamentos são ineficazes. Estudos estatísticos relacionados com o crescimento de neoplasias de pulmão mostram que um tumor de 2 cm pode ter de 2 a 15 anos de existência, dependendo do tipo histológico.

Em relação à etiopatogenia, há uma forte correlação entre o câncer de pulmão e o tabagismo. Há outras substâncias relacionadas com o câncer de pulmão, tais como: asbesto, níquel, arsênico, poeira radioativa, silicose, etc. Além disso, certos carcinomas podem se originar em cicatrizes fibróticas, embora alguns estudos baseados em análise da matriz colágena considerem a fibrose como consequência e não a causa do tumor.

Aspectos radiológicos

As manifestações radiográficas incluem infiltrado intersticial, linhas B de Kerley e edema subpleural, podendo-se identificar ainda linfonodomegalias hilares e mediastinais.

Na análise radiológica da linfangite carcinomatosa, pode-se observar:

- espessamento do septo interlobular;
- aspecto poligonal;
- espessamento liso ou nodular do interstício axial;
- nódulos subpleurais e nos septos;
- espessamento do interstício intralobular (aspecto em teia de aranha);
- espessamento da bainha axial centrolobular (sinal da lágrima).

Quando há espessamento do interstício axial e a presença de nódulos subpleurais, o diagnóstico diferencial principal é com a sarcoidose.

2 REDES NEURAIS ARTIFICIAIS

2.1 INTRODUÇÃO

Os sistemas baseados em redes neurais artificiais, também chamados de sistemas conexionistas, que podem ser classificados como uma sub-área da Inteligência Artificial², são sistemas computacionais construídos através de técnicas que procuram imitar o cérebro humano com suas conexões de elementos de processamento.

As pesquisas em redes neurais artificiais foram e são motivadas pela idéia de que o cérebro humano é um computador, ou seja, um sistema de processamento de informações, altamente complexo e paralelo. Ele tem a capacidade de organizar sua estrutura funcional para a execução das tarefas de processamento muito mais rapidamente que o mais rápido computador digital já construído.

Portanto, por quê não criar um sistema artificial com a capacidade de simular, ao menos em parte, a estrutura e a organização desse “computador biológico”? Essa, então, é a idéia inicial das redes neurais artificiais.

Uma rede neural artificial pretende simular o sistema nervoso humano, o qual contém uma coleção de neurônios (os elementos de processamento) que se comunicam através de axônios e dendritos. Dendritos são ramificações que recebem sinais elétricos de outros neurônios, que são transmitidos pelo axônio. À junção (conexão) de um dendrito com um axônio, denomina-se sinapse. Estima-se que existam cerca 10^{12} neurônios no cérebro humano, e que cada um destes possua

² Inteligência Artificial é uma disciplina que tem por objetivo estudar os mecanismos de funcionamento da inteligência humana e procurar maneiras de reproduzir essa capacidade artificialmente, através de programas de computador.

aproximadamente 10^3 sinapses [Thompson, 1986]. Com relação a tempos de resposta, para os neurônios naturais este tempo fica na ordem de frações de milissegundo, enquanto os computadores, em geral, são cerca de um milhão de vezes mais rápidos, porém, o grau de conectividade dos neurônios é da ordem de mil vezes maior do que o dos computadores.

A tecnologia das redes neurais artificiais tem origem e fundamentação em uma série de disciplinas, sendo as principais a neurociência, a matemática, a estatística, a física, a ciência da computação e a engenharia. E são também apropriadas para diversos usos, destacando-se as tarefas de percepção, como o reconhecimento, classificação e auto-associação de padrões. Apesar da inspiração inicial para a idéia das redes neurais artificiais ter origem na neurofisiologia, sua pesquisa atualmente engloba diversas áreas do conhecimento, envolvendo pesquisadores com propósitos e formações diferentes.

Em sua forma genérica, uma rede neural artificial é uma “máquina” projetada para modelar o processamento do cérebro humano em uma tarefa ou função específica. A implementação dessa “máquina” pode se dar na forma de *hardware*, utilizando-se de componentes eletrônicos, ou simplesmente simulada por programação.

Uma definição bastante clara para as redes neurais artificiais, é a encontrada em Haykin [2001, p.28]:

“Uma rede neural é um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torna-lo disponível para o uso. Ela se assemelha ao cérebro em dois aspectos:

1. O conhecimento é adquirido pela rede a partir de ambiente através de um processo de aprendizagem.
2. Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.”

resumindo, uma rede neural artificial é um sistema computacional que tem a capacidade de “aprender” com seu próprio uso, ou seja, produzir saídas adequadas para entradas que não estavam presentes durante o treinamento, de forma a alcançar um objetivo desejado. Essa capacidade de generalização torna possível às redes neurais artificiais resolver problemas computacionais complexos.

É importante nesse momento deixar claro que, na prática, toda essa idéia não acontece de maneira tão simples. Vários empecilhos podem ocorrer durante a implementação de uma rede neural artificial que provocam até uma impossibilidade de sua aplicação em dados problemas. Nota-se também que as

redes neurais artificiais normalmente não conseguem fornecer soluções precisas quando aplicadas isoladamente; precisam ser integradas a outros tipos e paradigmas de sistemas.

Devemos também reconhecer que existe ainda um longo e árduo caminho de pesquisas a ser percorrido para que se consiga chegar a uma arquitetura computacional que reproduza fielmente a capacidade do cérebro humano.

2.2 UM POUCO DE HISTÓRIA

As primeiras pesquisas na área de redes neurais artificiais surgiram com o trabalho de McCulloch & Pitts (1943). Nesse artigo – que é considerado o ponto de nascimento da área de redes neurais e da própria Inteligência Artificial –, o psiquiatra e neuroanatomista Warren McCulloch e o matemático William Pitts descrevem um cálculo lógico que unifica os estudos de neurofisiologia e da lógica matemática.

Outro importante trabalho para o surgimento da área é um estudo do psicólogo Donald Hebb, em seu livro *Organization of Behaviour*, publicado em 1949, onde descreveu pela primeira vez o funcionamento quantitativo da sinapse e do processo de treinamento humano. As teorias de Hebb, notadamente seu **postulado de aprendizagem**, são usadas ainda hoje no desenvolvimento de modelos computacionais de sistemas de aprendizagem.

Um desenvolvimento muito importante desta idéia, que impulsionou a maior parte das pesquisas na área, foi publicado por Rosenblatt, do M.I.T. (*Massachusetts Institute of Technology*), em seu livro *Perceptrons* de 1958, onde apresenta uma nova abordagem para o problema de reconhecimento de padrões, através de um método inovador de aprendizagem.

Durante a década de 1960, grandes pesquisas foram realizadas, principalmente relacionadas aos *perceptrons*. Nessa época, tudo levava a crer que as redes neurais artificiais poderiam realizar qualquer coisa. Porém, em 1969, a

publicação do trabalho de Minsky & Papert, também intitulado *Perceptrons*, levou a área a um grande estado de estagnação ao demonstrar matematicamente os limites para a aplicação dos *perceptrons* de camada única (os quais eram mais pesquisados na época), como por exemplo, a incapacidade de solucionar problemas simples como a função lógica OU-EXCLUSIVO para duas ou mais variáveis. Essa publicação veio a desencorajar os pesquisadores e principalmente as agências financiadoras a desenvolver novas pesquisas com os *perceptrons*.

Somente com o surgimento do algoritmo de *backpropagation* para treinamento de redes de múltiplas camadas, em 1986 (Rumelhart e cols.), a comunidade científica voltou a se interessar pelas redes neurais artificiais como ferramenta para reconhecimento de padrões.

Apesar de alguns modelos de redes neurais artificiais serem baseados em conceitos biológicos (O'Reilly & Johnson, 1994; Peres & Hochstein, 1994), várias abordagens não procuram ser muito realistas do ponto de vista biológico. Muitas redes neurais artificiais são modelos extremamente simplificados quando comparados às redes neurais biológicas.

Grande parte do trabalho realizado até hoje envolve a simulação através de *software* para computadores de uso geral, apesar de *hardware* de uso específico já ser disponível para alguns tipos de redes. O que se espera, neste sentido, é que futuramente, computadores dedicados e processadores paralelos implementem com mais eficiência as redes neurais artificiais.

Atualmente, as áreas de aplicação das redes neurais artificiais são várias. Na teoria, as redes neurais artificiais podem ser utilizadas em qualquer tipo de problema computacional, porém, na prática, o que se tem visto é sua aplicação em problemas mais específicos que requerem mapeamentos complexos, onde se tem um grande volume de dados disponíveis mas não se consegue descrever regras para o comportamento do sistema. Outro ponto importante das redes neurais artificiais é a capacidade de serem tolerantes a ruídos ou erros nos dados. Podem ser citadas como as principais aplicações onde se faz o uso de redes neurais artificiais, o processamento de linguagem natural, processamento de voz, análise de imagens, reconhecimento de escrita, compressão de imagens, processamento de sinais, previsão mercadológica, modelos econômicos e financeiros, sistemas de memória associativa e apoio ao diagnóstico médico.

2.3 ALGUMAS VANTAGENS E DESVANTAGENS NA UTILIZAÇÃO DE REDES NEURAIS ARTIFICIAIS

Como em qualquer tipo de modelagem matemática de sistemas naturais, para as redes neurais artificiais deve-se relacionar algumas vantagens e desvantagens em sua utilização³.

Como vantagens da aplicação das redes neurais artificiais, pode-se citar:

- a) Qualidade superior: as redes permitem análises superiores às conseguidas com técnicas estatísticas.
- b) Competitividade: empresas que tenham conseguido redes bem elaboradas possuem maior poder de fôlego frente aos seus concorrentes, dado que essa é uma tecnologia ainda nova e pouco conhecida.
- c) Auto-aprendizado: não necessitam de conhecimentos de especialistas para tomar decisões; elas se baseiam unicamente nos exemplos históricos que lhes são fornecidos.
- d) Implementação mais rápida: o tempo necessário para se implementar uma rede é menor que o utilizado para a construção de um sistema especialista equivalente, além do menor custo envolvido.
- e) Imunidade a falhas: como as unidades da rede operam em paralelo, a destruição ou defeito em um dos seus nós não torna a rede inoperante, podendo até mesmo não causar grandes problemas em seu funcionamento (a exemplo do que ocorre com o cérebro humano).
- f) Capacidade de generalização: mesmo com dados incompletos ou imprecisos as redes podem preencher as lacunas sem sofrer degradação; é algo parecido com a interpolação e extrapolação da estatística, porém operacionalmente muito diferente.
- g) Imunidade a ruídos: os dados reais sempre contêm ruído; as redes conseguem separar o ruído da informação relevante, tendo sido utilizadas até como filtros de dados.

³ Ressalta-se que esses itens foram compilados e adaptados de texto encontrado na Internet, em 23/04/2000, na URL: <http://www.univ.com.br/acmm/Redes/~RN-INDEX.htm>.

- h) Adaptabilidade: uma vez construída uma rede eficiente em dada aplicação, ela pode ser utilizada em aplicações de tempo real, sem necessidade de ter sua arquitetura alterada a cada atualização; basta que seja re-treinada com base nos novos dados históricos que forem surgindo.
- i) Democratização: através de arquiteturas e algoritmos gerais que podem ser encapsulados em *softwares* e *hardwares* de rede, os executivos poderão se utilizar dessa ferramenta, à medida que as redes se tornarem mais conhecidas, sem necessidade de construir outros tipos de redes ou de desenvolver novos algoritmos.

Deve-se também colocar algumas desvantagens no uso das redes neurais artificiais:

- a) Treinamento demorado: o treinamento de uma rede, dependendo da aplicação, pode ser demorado (horas ou mesmo dias).
- b) Resultados desconcertantes: as redes podem chegar a conclusões que contrariem as regras e teorias estabelecidas, bem como considerar dados irrelevantes como básicos; somente o bom senso do profissional experiente saberá tratar tais casos.
- c) Caixa-preta: é impossível saber o motivo que levou a rede a uma conclusão; seus critérios decisórios são encriptados, não se sabendo que valores são relevantes à tomada de uma decisão.
- d) Volume grande de dados: para uma rede poder aprender corretamente, necessita-se de um grande volume de dados históricos; a carência de dados relevantes em quantidade suficiente torna a rede inaplicável.
- e) Preparação dos dados: os dados de entrada necessitam de tratamento prévio: devem ser normalizados e cuidadosamente selecionados para que a rede seja corretamente ensinada a agir: dados de má qualidade produzem resultados falhos.

2.4 ESTRUTURA DAS REDES NEURAIS ARTIFICIAIS

As redes neurais artificiais tiveram sua inspiração em modelos biológicos de neurônios e suas redes altamente interconectadas de processamento de informações, porém a comparação com os neurônios biológicos para por aí. Os modelos de implementação e estruturação das redes artificiais têm muito pouco do que se conhece realmente do campo da neurologia e outras ciências correlatas.

As especificações das redes neurais artificiais são dadas pela arquitetura da rede, características dos elementos processadores (neurônios), dinâmica, e regras de treinamento.

A arquitetura da rede, ou sua organização física, geralmente está relacionada com a função que esta rede terá. As redes podem ser compostas por diversos elementos processadores, os quais podem estar dispostos em uma, duas ou várias camadas. A organização dessas camadas também pode seguir os mais variados padrões de conexão e fluxo de sinais: algumas redes permitem apenas o fluxo para frente (*feed-forward*); outras podem possuir conexões retroativas (*feedback*), laterais, competitividade entre camadas, etc.

Elementos processadores (daqui para frente referenciados apenas por “**neurônios**”), funcionam basicamente como integradores de sinais. A função de um neurônio é coletar sinais advindos de outros neurônios, ou mesmo sinais de entrada da rede, ponderar os dados através de pesos específicos e repassar esses dados para outros neurônios ou para a saída da rede. A figura 9 mostra a estrutura típica de um neurônio artificial.

Figura 9 Um neurônio artificial básico.

O processamento efetuado por um neurônio desse tipo, para o cálculo de seu sinal de saída (Y), pode ser descrito através da seguinte equação matemática:

$$Y_j = f\left(\sum_{i=1}^n w_i \cdot x_i + b_j\right) \quad (1)$$

onde n é o número total de sinais de entrada que chegam até o neurônio que está sendo calculado; x_i é um valor de entrada para esse neurônio (que pode tanto ser originário de outro neurônio ou da própria entrada da rede); e w_i é um peso associado a essa conexão (que pode caracterizar maior ou menor significância para a conexão). Matematicamente, o resultado da somatória das componentes do produto interno entre o vetor de entrada ($\mathbf{x}$) e o vetor de pesos ($\mathbf{w}$) do neurônio é mapeado através de uma função de ativação (f), produzindo o valor de saída ($\mathbf{Y}$) do neurônio j . Essa função de ativação tem como objetivo restringir a amplitude da saída do neurônio, isto é, limitar sua saída a um intervalo de valor finito. O modelo acima descrito ainda inclui um *bias* (representado por b_j) cuja função é aumentar ou diminuir a entrada líquida da função de ativação.

São três os tipos de funções de ativação mais usados para mapear uma rede neural artificial [Haykin, 2001, p.38-40], cujos gráficos básicos são mostrados na figura 10:

1. **Função de limiar:** A saída do neurônio assume valor 0 quando seu resultado for negativo, e 1 caso contrário (fig.10a).

$$f(u) = \begin{cases} 1 & \text{se } u \geq 0 \\ 0 & \text{se } u < 0 \end{cases} \quad (2)$$

2. **Função linear por partes:** Esse tipo de função pode ser visto como uma aproximação de um amplificador não-linear (fig.10b).

$$f(u) = \begin{cases} 1 & \text{se } u \geq +\frac{1}{2} \\ u & \text{se } +\frac{1}{2} > u > -\frac{1}{2} \\ 0 & \text{se } u \leq -\frac{1}{2} \end{cases} \quad (3)$$

3. **Função sigmóide:** É o tipo de função de ativação mais largamente utilizada na construção das redes neurais artificiais. É uma função estritamente crescente. Pode ser de várias formas, sendo as mais comuns a função logística (fig.10c)

$$f(u) = \frac{1}{1 + e^{-a \cdot u}} \quad (4)$$

onde a é o parâmetro de inclinação da função (quanto maior o valor de a , mais inclinada se torna a curva), e a função tangente hiperbólica.

$$f(u) = \tanh(u) \quad (5)$$

É importante salientar que as funções descritas anteriormente (excetuando-se a função tangente hiperbólica (eq.5)), estão definidas no intervalo de 0 a +1, porém, é comum verificarmos implementações onde a função se estende de -1 a +1, trazendo, inclusive, alguns benefícios analíticos.

Figura 10 (a) Função de limiar. (b) Função linear por partes. (c) Função sigmóide com parâmetro de inclinação a variável.

2.5 APRENDIZAGEM

Como já mencionado anteriormente, uma das principais vantagens e importâncias das redes neurais artificiais é sua capacidade de “aprender sozinha” através de seu próprio uso, e de melhorar sempre seu desempenho baseada nessa aprendizagem.

Uma das habilidades dos seres humanos que tem sido alvo de indagações e de pesquisas ao longo dos séculos é a capacidade de aprender. Esta capacidade recebe o nome técnico de protopeiria. Os homens e alguns animais superiores possuem a protopeiria muito desenvolvida. Eles aprendem com a experiência, aprendem ouvindo o que lhes é dito, e aprendem ampliando o alcance do conhecimento que já possuem, através de reordenações sucessivas.

Considerando o fato de aprendizado ser um processo altamente complexo, não só por reunir habilidades e conceitos advindos de várias áreas de conhecimento, mas também por envolver diferentes níveis de abstração, não há em relação a ele uma definição única. Podem ser encontradas diversas definições que se diferenciam pela ênfase dada a diferentes aspectos do processo de aprendizado.

Em Simon [1983] aprendizado é definido como “o processo através do qual um sistema melhora o seu desempenho”. Esta definição parte do pressuposto que o sistema está tentando realizar uma tarefa. A melhoria no desempenho pode se dar através da aplicação de novos métodos e conhecimentos, ou então através do melhoramento dos métodos e conhecimentos existentes, de maneira a torná-los mais rápidos e precisos.

Aprendizado pode também ser abordado como um processo de aquisição de habilidades – pesquisas que relacionam a Inteligência Artificial e a Psicologia Cognitiva têm se preocupado em descobrir qual é o conhecimento necessário que promove o desenvolvimento de habilidades, na realização de determinadas tarefas.

Com uma visão mais voltada para a teoria conexionista das redes neurais, encontra-se a definição segundo a qual:

“Aprendizagem é um processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira pela qual a modificação dos parâmetros ocorre.” [Haykin, 2000, p.75]

A forma básica de aprendizagem de uma rede neural artificial se dá através de um processo iterativo de correções e ajustes dos pesos associados a suas conexões e ao *bias*, ou seja, a rede aprende um pouco mais a cada iteração realizada durante a fase de treinamento.

Existem várias maneiras e tipos de ferramentas para a implementação matemática e computacional de aprendizagem em uma rede neural artificial, cada qual mais adequada a determinadas aplicações e projetos.

De acordo com Haykin [2001, p.76], as cinco principais regras básicas de aprendizagem são: **aprendizagem por correção de erro**, fundamentada na filtragem ótima; **aprendizagem baseada em memória**, que trabalha através da memorização direta dos dados de treinamento; **aprendizagem hebbiana**, baseada na teoria original de Hebb (comentada anteriormente); **aprendizagem competitiva**, também inspirada na neurobiologia; e **aprendizagem de Boltzmann**, baseada em idéias da mecânica estatística. Como já comentado acima, dependendo da aplicação e estrutura da rede neural artificial, uma regra se adapta melhor que outra.

Como neste trabalho utilizou-se a regra de aprendizagem por correção de erro, apenas esta será descrita a seguir em maiores detalhes.

2.5.1 Aprendizagem por correção de erro

Essa regra de aprendizagem consiste basicamente em ajustes realizados nos pesos das conexões entre os neurônios da rede, baseados nos erros encontrados nos sinais de saída, com o intuito de minimizar esse erro.

O erro da saída de um neurônio é obtido comparando-se o resultado por ele calculado com seu resultado desejado. Nota-se que para a implementação dessa regra de aprendizagem é necessário fornecer diretamente à rede, através de uma fonte externa, as respostas desejadas para cada padrão de entrada apresentado durante a fase de treinamento. Matematicamente, esse sinal de erro pode ser definido por:

$$e_j(n) = d_j(n) - y_j(n) \quad (6)$$

ou seja, o sinal de erro e do neurônio j no instante n (passo de tempo do processo de iteração envolvido na aprendizagem) é igual à saída desejada (d) para esse neurônio menos a sua saída efetivamente obtida (y).

Após a determinação do erro, deve-se realizar ajustes corretivos nos pesos das conexões entre os neurônios para uma devida aproximação da saída obtida à resposta desejada, ou seja, minimizar o índice de desempenho da rede, sendo que estes ajustes devem ocorrer passo a passo até o sistema atingir uma situação estável (quando os pesos não mais se alteram).

Esse processo de minimização do índice de desempenho (ou função de custo, como também é denominada) resulta na comumente referida como **regra delta**, ou regra de *Widrow-Hoff* (assim denominada por ter sido criada pelos pesquisadores Widrow e Hoff, em 1960).

De acordo com a regra delta, o ajuste do peso da conexão de um neurônio da camada j a um neurônio da camada k (w_{jk}), no instante n , é definido pela equação

$$\Delta w_{jk}(n) = \lambda \cdot e_k(n) \cdot x_j(n) \quad (7)$$

onde λ é uma constante positiva que determina a taxa ou tamanho do passo avançado a cada iteração do processo de aprendizagem, denominada **parâmetro de aprendizado**, lembrando também que x_j representa o valor do neurônio j .

Após ser calculado esse ajuste, a atualização do peso da conexão se dá por

$$w_{jk}(n+1) = w_{jk}(n) + \Delta w_{jk}(n) \quad (8)$$

ou seja, o novo valor do peso da conexão é o valor antigo mais o ajuste.

2.5.2 Paradigmas de aprendizagem

Além dos tipos de regras de aprendizagem, acima comentadas, deve-se levar em conta no projeto da rede também o paradigma de aprendizagem, que pode ser de dois tipos: aprendizagem supervisionada e aprendizagem não-supervisionada.

Na **aprendizagem supervisionada**, também denominada de aprendizagem com um professor, deve ser apresentada à rede uma resposta esperada para cada padrão de entrada, para que esta possa comparar com sua resposta calculada e saber quanto errou, e assim, “aprender” com esse erro. Como se pode notar, esse paradigma de aprendizagem está intimamente relacionado com a regra de correção de erro, descrita no item anterior, e utilizado na elaboração deste trabalho.

No oposto, a **aprendizagem não-supervisionada**, como o próprio nome já diz, não depende de nenhum elemento externo (professor) para supervisionar o processo de aprendizagem.

2.6 PERCEPTRONS

O *perceptron*, introduzido por Rosenblatt, em 1958, é uma forma simples de rede neural artificial cuja principal aplicação se dá nos problemas de classificação de padrões, ou seja, “o processo pelo qual um padrão/sinal recebido é atribuído a uma classe dentre um número predeterminado de classes (categorias)” [Haykin, 2001, p.92].

Para que uma rede neural artificial realize uma tarefa de reconhecimento de padrões, é necessário que passe por uma fase de treinamento, onde são apresentados diversos padrões de entrada e a classe ao qual cada um desses padrões pertence. Após esse treinamento, espera-se que, ao ser apresentado à rede um padrão por ela desconhecido, mas pertencente ao mesmo

tipo dos padrões que foram usados no treinamento, esta seja capaz de identificar a classe correta a qual pertence.

2.6.1 Perceptron de camada única

As redes do tipo *perceptron* de uma única camada são úteis na solução de problemas que admitem separação de classes por hiperplanos, ou seja, padrões linearmente separáveis. Rosenblatt demonstrou que sempre que um *perceptron* for treinado com padrões retirados de duas classes linearmente separáveis, será capaz de convergir para uma superfície de decisão formada por um hiperplano entre essas duas classes.

Quando o *perceptron* é construído com um único neurônio, esse somente será capaz de classificar padrões entre duas classes apenas. Porém, com o aumento do número de neurônios, o número de classes separáveis aumentará proporcionalmente.

2.6.2 Perceptron multicamadas

Como comentado anteriormente, o *perceptron* de camada única só é capaz de classificar padrões linearmente separáveis. Quando o problema a ser trabalhado não admite uma separação linear exata, como acontece normalmente na prática, torna-se necessário o uso de um *perceptron* multicamadas.

A falta de uma regra de treinamento para esse tipo de rede foi o principal fator que levou as pesquisas em redes neurais artificiais a um estágio de paralisação no final dos anos 60, somente voltando a surgir interesse na década de 1986, quando do desenvolvimento do algoritmo de *backpropagation*, por Rumelhart e cols. Atualmente, os *perceptrons* multicamadas treinados por *backpropagation*

constituem, provavelmente, a mais difundida e mais utilizada entre as arquiteturas e dinâmicas de redes neurais artificiais conhecidas.

Arquiteturalmente, os *perceptrons* multicamadas consistem em uma série de neurônios com interconexões entre as diferentes camadas. Podem ser verificados três tipos de camadas de neurônios: uma camada de entrada, uma camada de saída, e uma ou mais camadas intermediárias, normalmente denominadas de camadas ocultas. Cada neurônio de uma camada recebe os sinais de todos os neurônios da camada anterior e propaga sua saída a todos os neurônios da camada posterior.

A camada de entrada é utilizada para receber os dados de entrada da rede. Essa camada, portanto, não efetua qualquer tipo de processamento, servindo apenas para receber e armazenar o vetor de entrada, ou seja, o padrão a ser classificado. O número de neurônios dessa camada pode ser facilmente obtido pelo número de componentes do vetor de entrada do sistema.

A camada de saída tem a função de coletar e armazenar as respostas da rede ao padrão inserido na entrada. Também possui uma estruturação relativamente simples, sendo composta de tantos neurônios quantas forem as classes do problema.

Entre a camada de entrada e a de saída, podemos ter uma ou mais camadas ocultas, assim denominadas por não possuírem qualquer comunicação direta com os dados trabalhados. A principal função dessas camadas é a de proporcionar complexidade e não-linearidade para a rede. Aqui não se conhece um método que determine, *a priori*, um número ótimo de camadas ou de neurônios em cada camada, porém, a escolha desses parâmetros é muito importante e influencia diretamente a performance do sistema, pois o tempo envolvido com o cálculo da resposta e com o treinamento da rede aumenta significativamente com o aumento da quantidade de conexões e de neurônios das camadas ocultas. Redes sem camadas ocultas não conseguem resolver problemas não-lineares, por outro lado, com muitas camadas ocultas ou com muitos neurônios nessas camadas, a rede passa a funcionar como uma memória, perdendo a capacidade de generalização.

A figura 11 representa uma estrutura de rede neural artificial do tipo *perceptron* com uma camada oculta.

Figura 11 Estrutura de uma rede *perceptron* com uma camada oculta.

Outra característica importante a se destacar é a não-linearidade das saídas dos neurônios quando se trata de uma rede desse tipo. Essa não-linearidade é obtida utilizando-se como função de ativação uma função do tipo sigmóide, normalmente a função logística, apresentada na Equação 4.

2.7 TREINAMENTO

Aprender significa adaptar-se ao ambiente de acordo com regras pré-existent, alterando o seu desempenho ao longo do tempo. Para que uma rede neural artificial aprenda, é necessário que passe por uma etapa de treinamento, onde os pesos associados às conexões são alterados – adaptando-se ao ambiente – seguindo algumas regras.

Essas regras de treinamento especificam como os pesos podem ser adaptados durante o aprendizado para melhorar a performance da rede. A alteração dos parâmetros de uma rede só é permitida durante a fase de treinamento, permanecendo estáticos durante as fases de teste e execução.

Centenas de algoritmos de treinamento para as redes multicamadas foram e continuam sendo propostos. Entre eles, o mais difundido e utilizado atualmente é o *backpropagation*, por ser um método de implementação relativamente fácil e que tem obtido bastante sucesso em aplicações práticas.

2.7.1 Algoritmo de *backpropagation*

O algoritmo de treinamento conhecido como *backpropagation* envolve três estágios, a propagação “para frente” (*feed forward*) do sinal de entrada, uma propagação “para trás” (*backpropagation*) do erro da saída obtida em relação à saída desejada, e um ajuste dos pesos associados às conexões da rede.

Como já visto anteriormente, o erro da saída de cada neurônio é obtido matematicamente através de

$$e_j(n) = d_j(n) - y_j(n) \quad (9)$$

onde d_j representa a saída desejada para o neurônio j e y_j representa a saída obtida para esse neurônio.

O valor instantâneo da energia total do erro da rede a cada padrão de entrada apresentado é obtido pela somatória das energias do erro de todos os neurônios da camada de saída, escrito como

$$\mathcal{E}(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (10)$$

considerando o conjunto C como o conjunto de todos os neurônios da camada de saída. E para se calcular a energia média do erro, que representa a função de custo, usada para se determinar o desempenho da aprendizagem, usa-se

$$\mathcal{E}_{med} = \frac{1}{N} \sum_{n=1}^N \mathcal{E}(n) \quad (11)$$

onde N representa o número total de padrões de entrada apresentados à rede em uma época de treinamento. A energia do erro é justamente a medida que se busca minimizar para caracterizar o aprendizado da rede.

Para a minimização do erro é utilizada regra delta, já descrita anteriormente, baseada no método do gradiente descendente, que significa buscar, no espaço de pesos, uma direção para a mudança do peso com o intuito de reduzir o valor da energia do erro. A regra delta pode aqui ser reescrita como

$$\Delta w_{jk}(n) = \lambda \cdot \delta_k(n) \cdot x_j(n) \quad (12)$$

onde o gradiente local $\delta_k(n)$ é definido por

$$\delta_k(n) = e_k(n) \cdot y_k(n) \cdot (1 - y_k(n)) \quad (13)$$

ou seja, o gradiente local de cada neurônio é calculado através do produto do sinal de erro desse neurônio pela derivada de sua saída obtida.

Nota-se que todos os cálculos envolvidos nas correções dos pesos das conexões neurais são baseados no sinal de erro, e esse sinal de erro é obtido através da informação externa de uma saída desejada. Quando o neurônio a ser calculado pertence à camada de saída da rede, todo o cálculo é facilmente e diretamente realizado utilizando-se das Equações 9 e 13.

Quando, porém, o neurônio está localizado em uma camada oculta, não se tem previamente determinada uma resposta desejada para ele. O cálculo do sinal de erro para esse tipo de neurônio deve, então, ser realizado recursivamente, baseado nos sinais de erro de todos os neurônios da camada imediatamente posterior aos quais o neurônio oculto está diretamente conectado, para tanto o gradiente local deve ser reescrito, obtendo-se a *fórmula de retropropagação*

$$\delta_j(n) = \left(\sum_k \delta_k(n) \cdot w_{jk}(n) \right) \cdot h_j(n) \cdot (1 - h_j(n)) \quad (14)$$

onde j representa um neurônio de camada oculta, k os neurônios da camada imediatamente posterior a ele conectados, e h_j a saída encontrada para esse neurônio da camada oculta.

Agora é possível reescrever a Equação 12, a regra delta, tanto para os neurônios da camada de saída como para os neurônios de camadas ocultas, bastando modificar os índices para melhor visualização, ou seja

$$\Delta w_{jk}(n) = \lambda \cdot \delta_k(n) \cdot h_j(n) \quad (15)$$

para os neurônios da camada de saída, onde h_j representa os valores de entrada desses neurônios, oriundos dos neurônios da camada oculta imediatamente à esquerda, e

$$\Delta w_{ij}(n) = \lambda \cdot \delta_j(n) \cdot x_i(n) \quad (16)$$

para os neurônios da camada oculta, com x_i representando os valores de entrada da rede, no caso desta ter apenas uma camada oculta.

Após as definições, é possível descrever o algoritmo de *backpropagation* de uma forma geral:

1. Inicializar

Definir os pesos das conexões (através de uma distribuição uniforme aleatória com média zero).

2. Apresentar os padrões de entrada

Reordenar aleatoriamente o conjunto de treinamento.

Alimentar a rede com um exemplo do conjunto de treinamento.

Para todos os exemplos do conjunto de treinamento, individualmente, executar os passos 3 e 4.

3. Propagar os sinais

Calcular os sinais de todos os neurônios pelas Eq. 1 e 4.

Calcular os sinais de erro pela Eq. 9.

Calcular o valor instantâneo da energia total do erro pela Eq. 10.

4. Retropropagar

Calcular os gradientes locais pelas Eq. 13 e 14.

Calcular os deltas pelas Eq. 15 e 16

Ajustar os pesos das conexões pela Eq. 8.

5. Iterar

Após apresentação de todo o conjunto de treinamento, calcular a energia média do erro pela Eq. 11.

Voltar ao passo 2 até que a energia média do erro se encontre estabilizada no valor mínimo.

3 SISTEMAS DE APOIO AO DIAGNÓSTICO

Dentre as tarefas desempenhadas pelo profissional da área médica diariamente, uma das principais é a tomada de decisões. Esse processo pode ocorrer em diversos pontos de sua atividade e é baseado em uma série de informações colhidas também em diferentes momentos e etapas. Uma tarefa em que a tomada de decisão é claramente verificada é a de diagnóstico.

Como a Informática, ou tecnologia da informação, é justamente a ciência que tem por objetivo tratar a informação e toda a tecnologia envolvida nesse tratamento, como por exemplo a coleta, o armazenamento, o processamento, a transmissão e todas as outras formas de manipulação da informação, fica claro que a utilização de sua principal ferramenta, o computador, se dê de forma ampla em todo processo que envolva a tomada de decisão.

Atualmente ouve-se muito sobre a Informática Médica. Simplificadamente, pode-se dizer que o objetivo mais básico da área de atuação dessa disciplina é disponibilizar ao médico a informação de que ele necessita, de forma rápida, no momento e local onde ela é necessária. Diante o exposto, a utilização do computador na Medicina vem se tornando constantemente mais corriqueira, e até mesmo indispensável sob certos aspectos.

Uma grande ajuda que a Informática tem dado na área médica diz respeito ao diagnóstico. O diagnóstico médico se baseia na análise de uma série de dados e informações coletadas pelo profissional em diversas fontes de diferentes tipos, inclusive toda a experiência já vivenciada pelo médico em outros diagnósticos do mesmo tipo. A quantidade desses dados, informações e conhecimentos vem crescendo progressivamente, e para um médico desempenhar bem suas funções, deve estar sempre atualizado frente às novidades que surgem a cada dia.

Qualquer programa de computador que tenha como objetivo auxiliar o médico na resolução de algum tipo de problema e na elaboração de um diagnóstico pode ser classificado como Sistema de Apoio ao Diagnóstico (SAD) [Shortliffe,

1990]. Os sistemas computadorizados de apoio ao diagnóstico médico têm, portanto, como função básica auxiliar o profissional principalmente no aspecto de armazenamento e processamento da grande quantidade de dados e informações tratados na etapa de diagnóstico. Esses sistemas, normalmente construídos através de técnicas de Inteligência Artificial, tentam imitar o raciocínio do médico através de princípios de análises de decisões, com a capacidade de elaborar um raciocínio automático e realizar inferências lógicas, como induções e deduções. Sobre o assunto, encontra-se uma excelente descrição onde o autor apresenta um histórico do desenvolvimento das pesquisas relacionadas à Inteligência Artificial na Medicina [Coeira, 1996].

A primeira experiência bem-sucedida de se construir um sistema de diagnóstico médico foi o programa MYCIN [Shortliffe, 1976], desenvolvido nos Estados Unidos no início da década de 1970 pelo Dr. Edward Shortliffe, da Universidade de Stanford. Esse sistema tem a função de apoio ao diagnóstico e terapia de infecções provocadas por microorganismos.

Atualmente podem ser verificados vários estudos que analisam a utilização de sistemas computacionais de apoio ao diagnóstico. Alguns trabalhos procuram inclusive apresentar dicas e recomendações tanto para a construção de um sistema com esse fim como também na sua utilização prática. Como exemplo disso, cita-se um interessante estudo [Bates *et al.*, 2001] onde os autores, além de apresentarem uma revisão bastante completa sobre o uso da Informática na redução da frequência de erros médicos, ainda recomendam:

“- Implementar sistemas de apoio à decisão médica; - Ao projetar sistemas de TI (Tecnologia da Informação), levar em consideração e medir suas consequências, testar se eles garantem achar e prevenir erros potenciais; - Adotar padrões para dados e sistemas, e assegurar que os sistemas se intercomunique eficientemente; - Implementar sistemas e estruturas de controle; - Melhorar regulamentação e incentivar vendedores de sistemas a implementar sistemas de apoio à decisão; - Implementar sistemas de prescrição médica, codificação de barras para medicamentos, sangue, dispositivos e pacientes; - Comunicar valores anormais.”⁴

Outro estudo de revisão sobre o tema que merece destaque é o realizado por Dereck Hunt e cols. [Hunt *et al.*, 1998], no qual os autores analisaram, em vários trabalhos realizados com sistemas de apoio à decisão médica, sua

⁴ Tradução e adaptação do resumo do artigo apresentada como material de estudo do curso “Atualização Científica em Informática em Saúde” realizado pelo Instituto Edumed, Campinas, Brasil, outubro de 2001.

influência na performance clínica do médico e os resultados diretos para o paciente. Neste estudo, os autores apresentam uma série de resultados, como por exemplo, que de um total de 68 trabalhos selecionados, 40 foram publicados após 1992, o que mostra que as pesquisas na área ainda são recentes. Outros resultados relevantes são: de 65 estudos onde os efeitos na performance do médico puderam ser analisados, 43 apresentam benefícios no uso de sistemas computacionais (66%); a influência dos sistemas no resultado final para o paciente pôde ser analisada em 14 estudos, e destes, 6 mostraram grandes benefícios. Como conclusões mais importantes, os autores colocam o rápido aumento de publicações sobre o assunto e a melhoria constante na qualidade dessas publicações. Também concluem que os sistemas para controle de dosagens de drogas, prevenção de doenças e outros aspectos da atenção médica trazem enormes benefícios na performance clínica, mas os sistemas de diagnóstico, segundo eles, nesse estudo não apresentaram resultados convincentes.

3.1 SISTEMAS DE DIAGNÓSTICO EM RADIOLOGIA

A utilização do computador na área de diagnóstico radiológico pode ser dada de diversas maneiras, entre as quais estão também os sistemas de apoio ao diagnóstico. Várias pesquisas sobre o tema têm surgido ultimamente, sendo inclusive matéria do editorial de janeiro de 2002 de um importante periódico da área – *Academic Radiology* –, onde a autora conclui que:

“A revolução da tecnologia da informação está mudando os métodos para interpretação de imagens médicas. Cada nova edição de periódico de imagens médicas traz novas técnicas de imagem, novas aplicações ou novos resultados de estudos de observação e de testes clínicos e pré-clínicos de tais métodos. No futuro, é provável que todas as imagens médicas tenham alguma forma de diagnóstico apoiado por computador executado para beneficiar os cuidados com pacientes e os resultados.”⁵ [Giger, 2002, p.3].

A principal contribuição desse tipo de sistema para área vem do aspecto do ser humano possuir uma habilidade um tanto quanto limitada na

⁵ A tradução é nossa.

detecção de padrões nas imagens médicas que possam determinar ou classificar alguma patologia. A margem de erros cometidos pelo médico nesse procedimento, básico no diagnóstico por imagem, é bastante reduzida com a ajuda de um bom sistema computacional.

As principais pesquisas nessa área procuram encontrar e/ou desenvolver técnicas de computação que aumentem a confiabilidade desse tipo de sistema, para que possam realmente ser utilizados na rotina da clínica médica como uma espécie de segunda opinião no diagnóstico. Uma outra aplicação importante que se propõe para um sistema de apoio ao diagnóstico radiológico se refere ao ensino e treinamento de futuros profissionais.

Dentre as técnicas computacionais mais utilizadas nos sistemas de apoio ao diagnóstico, encontram-se as relacionadas à Inteligência Artificial, que comprovadamente são de grande auxílio para a tomada de decisão do médico. Sobre isso pode ser visto um importante estudo [Kahn-Junior, 1994] onde o autor descreve as principais técnicas de Inteligência Artificial utilizadas em sistemas de apoio à decisão em radiologia, como por exemplo, decisão baseada em regras, redes neurais artificiais, hipertextos e redes bayesianas. Além de fazer uma revisão teórica dessas técnicas, o autor também descreve suas aplicações na radiologia e discute sobre o futuro da radiologia com o uso de sistemas de apoio à decisão baseados nessas técnicas.

Outro artigo sobre o assunto que merece destaque, que apresenta o interessante título “Pode uma máquina aprender a interpretar radiografias?”, traz uma visão crítica sobre o uso de sistemas computacionais “inteligentes” no apoio ao diagnóstico radiológico. Muito bem embasado, o artigo apresenta uma boa revisão sobre o tema. O autor conclui que, embora as pesquisas em Inteligência Artificial e mais especificamente na técnica de redes neurais artificiais ainda terem muito a avançar, certamente pode ser considerada uma “poderosa ferramenta em todas as formas de esforço científico, incluindo medicina e radiologia.” [Reinus, 1997, p.21].

3.2 SISTEMAS DE DIAGNÓSTICO MÉDICO BASEADOS EM REDES NEURAIS ARTIFICIAIS

O desenvolvimento de sistemas de apoio ao diagnóstico médico baseados em redes neurais artificiais vem sendo amplamente pesquisado nos últimos anos. Pode-se facilmente encontrar referências de sua utilização em diversas aplicações relacionadas a problemas da área médica, com resultados satisfatórios em diferentes especialidades, tendo inclusive obtido destaque de divulgação na mídia não especializada⁶, onde foi apresentado um sistema baseado em redes neurais artificiais para diagnóstico e prevenção de ataques cardíacos que obteve resultados melhores que os próprios médicos especialistas.

No processamento de informações médicas, o uso de sistemas baseados em redes neurais artificiais apresenta como principais benefícios [Keller, 1998]:

- é treinada por exemplos obtidos de regras genéricas;
- é automática;
- elimina processos de fadiga humana (por exemplo, na análise excessiva de dados);
- apresenta rápida identificação;
- apresenta análises de condições e diagnósticos em tempo real.

Dentre as aplicações mais pesquisadas, destacam-se o apoio ao diagnóstico, a análise química, a análise de imagens e o desenvolvimento e aprimoramento de novas drogas.

Uma linha de pesquisa que vem se apresentando como uma grande força no futuro da área biomédica é a aplicação das redes neurais artificiais no campo da Biologia Molecular (como por exemplo, a determinação de padrões de estruturas de DNA), devido a alta complexidade e não-linearidade observada nas análises exigidas [Burke, 1996].

Nas aplicações de apoio ao diagnóstico, alvo desta pesquisa, a grande maioria dos trabalhos publicados se relaciona à determinação e classificação de padrões.

⁶ The Wall Street Journal, dec 2, 1991; O Estado de São Paulo, 29 set, 1997.

A seguir é apresentada uma revisão de trabalhos nesta linha.

3.3 REVISÃO DE TRABALHOS CORRELATOS

Grande parte dos trabalhos envolvendo a análise e desenvolvimento de sistemas de apoio ao diagnóstico na área de imagens, baseados em redes neurais artificiais refere-se a sistemas que têm como objetivo a classificação de padrões em imagens de mamografias. Dentre várias publicações nesta linha, encontram-se trabalhos que utilizam a técnica de redes neurais artificiais para análise automática das imagens com o objetivo de detectar microcalcificações [Wu *et al.*, 1992]; sistemas de apoio à tomada de decisão clínica no diagnóstico do câncer de mama [Wu *et al.*, 1993]; automatização na análise e classificação de microcalcificações em malignas e benignas utilizando como entrada do sistema valores coletados manualmente [Jiang *et al.*, 1996] ou automaticamente através de análises de textura na imagem [Chan *et al.*, 1997]; e ainda sistemas que interagem com equipamentos específicos (por exemplo, captam sinais de vídeo de aparelhos de ultrasonografia) para proceder a análises de detecção de nódulos sólidos de mama [Chen *et al.*, 1999].

Encontram-se ainda diversos trabalhos relatando sistemas de apoio ao diagnóstico de patologias mais diversas, como Alzheimer [Garcia-Perez *et al.*, 1998], tumores de cérebro [Poptani *et al.*, 1999], e anemias [Rodrigues & Oliveira, 2001].

Fato importante que se nota é que todos os trabalhos citados apresentam como resultados porcentagens de acerto significativamente elevadas dos sistemas analisados.

Relacionadas ao diagnóstico de doenças pulmonares, também são comuns as publicações, como por exemplo, diagnóstico de embolismo pulmonar [Patil *et al.*, 1993], determinação e classificação de nódulos pulmonares entre malignos e benignos [Gurney & Swensen, 1995; Nakamura *et al.*, 2000], descrição do desenvolvimento de sistemas para detecção automática de nódulos pulmonares

em radiografias digitais [Xu *et al.*, 1997; Penedo *et al.*, 1998] e prevenção da tuberculose pulmonar [El-Solh *et al.*, 1999].

Em outro importante estudo, os autores promovem uma comparação entre os resultados obtidos por um sistema computacional com os resultados obtidos por três especialistas na análise de imagens radiográficas para a determinação de embolismo pulmonar. Como resultados da comparação, os autores apresentam que a performance foi muito similar [Scott *et al.*, 2000].

Como a inspiração e o embasamento inicial para a realização deste trabalho se deu através dos estudos realizados no *Kurt Rossmann Laboratories for Radiologic Image Research*, da Universidade de Chicago, a seguir é apresentada uma revisão de parte das publicações do grupo, relacionadas diretamente ao diagnóstico de doenças intersticiais do pulmão.

No primeiro trabalho [Katsuragawa *et al.*, 1989] os autores apresentam o desenvolvimento de um método automático para a determinação de texturas do pulmão em radiografias digitais do tórax, com o intuito de promover uma classificação entre imagens normais e anormais. Para a determinação da performance do sistema, foi realizada uma comparação com resultados apresentados por especialistas. Os autores concluem que o método computadorizado pode ser de valiosa ajuda para os radiologistas na detecção de infiltrados intersticiais.

Em uma publicação seguinte [Katsuragawa *et al.*, 1990] os autores apresentam uma série de parâmetros para a melhoria do método desenvolvido pelo grupo e colocam que os resultados obtidos e apresentados podem perfeitamente servir como um guia para o desenvolvimento de esquemas computadorizados de análise de radiografias digitais de tórax.

No terceiro trabalho aqui citado do grupo [Asada *et al.*, 1990], já utilizando técnicas de redes neurais artificiais em um estudo piloto, como colocado pelos próprios autores, é descrito um sistema para a classificação de nove tipos de doenças intersticiais através da análise de vinte itens de informações clínicas e radiológicas. Como resultados, colocam que a performance de decisão da rede foi bastante alta, comparando-se com o apresentado por radiologistas especializados e até superior quando comparada com médicos residentes em radiologia. Apresenta ainda que, como resultados preliminares, o desenvolvimento das pesquisas com

redes neurais artificiais pode ser de grande valia como apoio ao diagnóstico diferencial das doenças intersticiais.

No trabalho do grupo que serviu de fonte inicial para esta pesquisa [Ashizawa *et al.*, 1999a], é apresentado um sistema baseado na técnica das redes neurais artificiais para o diagnóstico diferencial de 11 doenças intersticiais pela análise de dez parâmetros clínicos e 16 parâmetros radiológicos. A rede neural foi estruturada com três camadas (os 26 nós de entrada, 11 de saída, e a camada oculta com 18 nós), treinada pelo algoritmo de *backpropagation*. Como base de treinamento e teste os pesquisadores utilizaram 370 casos, sendo divididos em 150 casos clínicos, 110 casos de bibliografia e 110 casos hipotéticos. Como resultado, apresentam um índice de aproximadamente 90% de diagnósticos corretos entre as duas saídas de maior valor.

Com o avanço das pesquisas do grupo, apresentam conclusões de que a performance de um sistema computacional no diagnóstico diferencial de doenças intersticiais pode tranquilamente ser colocada como uma “segunda opinião” para auxiliar os radiologistas no diagnóstico final [Ashizawa *et al.*, 1999a; 1999b].

Na publicação mais recente do grupo [Abe *et al.*, 2002] os autores apresentam um estudo sobre o uso de uma rede neural artificial para determinar quais os mais importantes parâmetros clínicos e radiológicos que devem ser levados em conta em cada tipo de doença intersticial pulmonar.

4 DESENVOLVIMENTO PRÁTICO

Como já citado, o objetivo deste trabalho foi o desenvolvimento de um sistema computacional de apoio ao diagnóstico de um grupo de patologias classificadas como lesões intersticiais pulmonares, com o intuito principal de se verificar a validade da utilização da técnica de redes neurais artificiais para esse fim.

4.1 LEVANTAMENTO DE DADOS

O primeiro passo para o desenvolvimento da pesquisa foi definir quais as patologias que seriam levantadas para o estudo. Como já comentado anteriormente, o número de doenças que podem ser classificadas no grupo das lesões intersticiais pulmonares é muito grande, englobando mais de 180 diferentes doenças. Para realizar a escolha de quais seriam utilizadas como exemplo para o desenvolvimento do sistema, contou-se com a ajuda de um médico⁷ especializado na área, através do qual, com base principalmente na relevância clínica e dificuldade do diagnóstico diferencial, foram selecionadas as patologias já descritas, sendo elas: blastomicose sul-americana, fibrose pulmonar idiopática, tuberculose miliar, histoplasmose, sarcoidose, silicose, esclerodermia, histiocitose X e linfangite carcinomatosa.

Em seguida, também contando com a ajuda do especialista, levantou-se os principais parâmetros a serem observados no exame clínico e radiológico que podem auxiliar no diagnóstico diferencial, chegando-se aos seguintes:

⁷ Prof. Dr. José Antônio Baddini Martinez, professor do Departamento de Clínica Médica da Faculdade de Medicina de Ribeirão Preto, Universidade de São Paulo, Brasil.

a) parâmetros clínicos:

- idade do paciente;
- sexo;
- tempo de duração dos sintomas;
- constatação de estado febril;
- nível de imunidade;
- relato de doença maligna;
- paciente fumante;
- relato de tratamentos com drogas;
- relato de exposição constante à poeira;
- relato de exposição constante a antígenos orgânicos.

b) Parâmetros radiológicos:

- grau de lesões apresentadas na área superior, nas metades esquerda e direita;
- grau de lesões apresentadas na área média, nas metades esquerda e direita;
- grau de lesões apresentadas na área inferior, nas metades esquerda e direita;
- apresentação de padrão proximal ou periférico;
- homogeneidade das lesões apresentadas;
- apresentação de padrão fino ou grosseiro;
- apresentação de nodularidade;
- apresentação de linhas septais;
- apresentação de pulmão em “favo de mel”;
- verificação de perda de volume pulmonar;
- apresentação de linfadenopatia;
- apresentação de efusão pleural;
- tamanho cardíaco alterado.

Para o levantamento dos casos clínicos, todos coletados no Hospital das Clínicas da Faculdade de Medicina de Ribeirão Preto (HCFMRP), primeiramente fora realizada uma pesquisa nos arquivos do hospital para levantamento dos casos registrados com diagnóstico para uma das patologias investigadas. Após esse levantamento, eliminou-se todo registro em que não houvesse uma comprovação

concreta do diagnóstico, mantendo-se apenas os registros em que essa comprovação fosse possível de verificação. Esses registros foram então levados novamente ao médico especializado, o qual excluiu os que apresentavam a patologia como causa secundária.

Finalmente, esse conjunto de elementos, já bastante reduzido, foi levado para a análise, por um médico radiologista⁸, o qual realizou a quantificação dos parâmetros radiológicos e o preenchimento do protocolo (figura 12) utilizado como entrada de dados para o sistema.

<u>Parâmetros Clínicos</u>
<u>Idade</u>
<u>Sexo</u> (0=Masc.; 1=Fem.)
<u>Duração dos Sintomas</u> (0 – 12 meses)
<u>Temperatura</u> (0=Normal; 1=Febre)
<u>Imunidade</u> (0=Normal; 1=Suprimido)
<u>Doença Maligna</u> (0=Não; 1=Sim)
<u>Fumante</u> (0=Não; 1=Sim)
<u>Tratamento com Drogas</u> (0=Não; 1-Não tóxico; 2=Pouco tóxico; 3=Tóxico)
<u>Exposição à Poeira</u> (0=Não; 1=Sim)
<u>Exposição a Antígenos Orgânicos</u> (0=Não; 1=Sim)
<u>Parâmetros Radiológicos</u>
<u>Campo Superior Esquerdo</u> (0-5)
<u>Campo Superior Direito</u> (0-5)
<u>Campo Médio Esquerdo</u> (0-5)
<u>Campo Médio Direito</u> (0-5)
<u>Campo Inferior Esquerdo</u> (0-5)
<u>Campo Inferior Direito</u> (0-5)
<u>Proximal/Periférico</u> (0-5; 0=Proximal; 5=Periférico)
<u>Homogeneidade</u> (0-5)
<u>Fino/Grosseiro</u> (0-5; 0=Fino; 5=Grosseiro)
<u>Nodularidade</u> (0-5)
<u>Linhas Septais</u> (0-5)
<u>Favo de Mel</u> (0-5)
<u>Perda de Volume Pulmonar</u> (0-5)
<u>Linfadenopatia</u> (0-5)
<u>Efusão Pleural</u> (0-5)
<u>Tamanho Cardíaco</u> (1-5)

Figura 12 Protocolo de entrada de dados do sistema.

Os dados caracterizados como parâmetros clínicos foram obtidos através do prontuário do paciente, e quantificados da seguinte maneira:

⁸ Dr. José Antônio H. Rodrigues, médico assistente do Serviço de Radiodiagnóstico do Hospital das Clínicas da Faculdade de Medicina de Ribeirão Preto, Universidade de São Paulo, Brasil.

- a) Idade: idade do paciente, em anos;
- b) Sexo: sexo do paciente, sendo o valor 0 para sexo masculino e valor 1 para sexo feminino;
- c) Duração dos sintomas: relatado pelo paciente, de 0 a 12 meses (relatos de mais de doze meses foram fixados no valor 12);
- d) Temperatura: observação de estado febril no momento do exame, sendo classificado com o valor 0 para temperatura normal, e valor 1 para a constatação de febre;
- e) Imunidade: valor 0 para pacientes com imunidade normal e 1 para os portadores de doenças do sistema imune;
- f) Doença maligna: relatado pelo paciente, sendo o valor 1 para os pacientes portadores de doença maligna e 0 caso contrário;
- g) Fumante: relatado pelo paciente, sendo 0 para não fumantes e 1 para fumantes;
- h) Tratamento com drogas: pacientes com tratamento por drogas tóxicas foram classificados com o valor 3, pacientes tratados por drogas pouco tóxicas receberam o valor 2, tratados com drogas não tóxicas valor 1, e pacientes que não receberam nenhum tratamento por drogas classificados com o valor 0;
- i) Exposição à poeira: pacientes que relataram exposição constante à poeira receberam valor 1, caso contrário 0;
- j) Exposição a antígenos orgânicos: também relatada pelo paciente, a exposição a qualquer tipo de antígeno orgânico recebeu o valor 1, e valor 0 caso contrário.

Os parâmetros radiológicos foram quantificados pelo profissional especializado com base na observação das imagens radiológicas catalogadas também no prontuário do paciente. Essa quantificação foi realizada com valores inteiros no intervalo de 0 a 5 para todos os campos, exceto o tamanho cardíaco (intervalo de 1 a 5), sendo dado o valor 0 para a ausência de lesão, e valores maiores para o nível (ou tamanho) da presença de lesão (por exemplo, na análise do campo superior esquerdo da imagem, verificando-se ausência de lesões nessa área, quantificou-se com o valor 0; por outro lado, verificando-se lesões abrangendo toda a área, valor 5).

Nota-se claramente que essa quantificação dos parâmetros radiológicos foi realizada de maneira muito subjetiva, cujos valores poderiam ser diferentes quando realizada a análise por outro profissional. Mas isso é o que realmente ocorre na prática diária da profissão.

4.1.1 Dados coletados

Para o treinamento e testes do sistema, realizou-se o levantamento de dados no Hospital das Clínicas da Faculdade de Medicina de Ribeirão Preto, conforme descrito acima, no período de janeiro a dezembro de 2001, contando com o apoio de um estudante⁹ de iniciação científica do curso de Ciências Médicas dessa instituição, onde se obteve um total de 79 (setenta e nove) casos das patologias investigadas, assim distribuídos: 21 casos de blastomicose sul-americana; 14 casos de histoplasmose; 11 casos de fibrose pulmonar idiopática; 10 casos de tuberculose miliar; 9 casos de sarcoidose; 5 casos de esclerodermia; 4 casos de silicose; 3 casos de histiocitose X; e 2 casos de linfangite carcinomatosa.

4.2 SISTEMA COMPUTACIONAL

O sistema computacional desenvolvido é constituído de duas partes principais: módulo de aprendizagem e módulo de diagnóstico.

O módulo de aprendizagem é utilizado para o treinamento da rede neural, onde a base de dados é apresentada exaustivamente ao programa para que os pesos das conexões entre os nós sejam ajustados, até que a rede apresente uma taxa de erro aceitável.

⁹ Fernando Bortolatto Faria.

O módulo de diagnóstico é o programa efetivamente apresentado ao usuário final, com os pesos das conexões já fixados, onde o usuário entra com os dados de um determinado caso e o programa faz a classificação em uma das possíveis patologias.

4.2.1 Construção e configuração da rede neural

O sistema computacional desenvolvido nesse trabalho baseou-se na técnica de redes neurais artificiais do tipo *perceptron* multicamadas (MLP – *Multi-Layer Perceptron*), que consiste em uma série de elementos de processamento, denominados neurônios artificiais, ou nós, interligados entre si, com um determinado peso associado a cada conexão.

A opção por esse tipo de rede se deu pelo fato de o problema tratado ser basicamente uma classificação de amostras em determinados padrões, sendo essa a principal aplicação dos *perceptrons*.

Para o treinamento da rede, utilizou-se o paradigma da aprendizagem supervisionada, através do algoritmo de *backpropagation*, que é baseado em uma análise dos erros de resposta do sistema para os ajustes necessários na rede.

Vários testes para diferentes configurações da rede foram realizados. Mantendo-se sempre o mesmo número de elementos nas camadas de entrada e de saída, ou seja, 26 nós na camada de entrada (representando os 26 parâmetros do protocolo de entrada), e 9 nós na camada de saída (cada um representando um dos padrões de classificação), testou-se uma série de variações quanto ao número de elementos ocultos.

Partiu-se inicialmente com uma configuração de apenas uma camada oculta composta de 5 elementos, e aumentou-se gradativamente esse número até alcançar os 35 elementos. Foram também testadas configurações com 2 camadas ocultas com um número menor de elementos em cada uma.

De todas as configurações testadas, a que apresentou melhores resultados e, portanto a escolhida, contém apenas uma camada oculta com 19 nós, promovendo a conexão entre a camada de entrada e a de saída.

4.2.3 Treinamento do sistema e testes de performance

Como já citado anteriormente, o treinamento do sistema se deu através do algoritmo de *backpropagation*. Para os testes de performance, foram realizadas duas formas de treinamento distintas.

A primeira consistiu em treinar a rede neural com todos os 79 registros da base e efetuar os testes com 16 registros (aproximadamente 20% do total) escolhidos aleatoriamente dessa mesma base, ou seja, os testes eram realizados com amostras já conhecidas pela rede desde o treinamento.

Na segunda forma, antes de se realizar o treinamento, eram separados os 16 registros aleatórios, e a rede treinada apenas com os 63 registros restantes. Assim, os testes eram realizados com amostras totalmente desconhecidas da rede no treinamento.

4.3 RESULTADOS E DISCUSSÕES

São apresentados, a seguir, alguns resultados obtidos nas diversas fases da pesquisa, e discutidos alguns de seus aspectos mais relevantes.

4.3.1 Dados obtidos

Um dos maiores problemas encontrados durante a realização dessa pesquisa foi com relação à coleta de dados para se efetuar o treinamento do sistema.

No momento da realização das pesquisas nos arquivos, foi encontrado um grande número de casos registrados com o diagnóstico para uma das patologias

trabalhadas, porém, ao se efetuar uma primeira análise, verificou-se a falta de uma comprovação (ou não) desse diagnóstico.

Em outro grande número de casos, as radiografias arquivadas não apresentavam condições plenas para a avaliação pelo médico especialista, visto que, pela própria característica dessas patologias, quase sempre vêm acompanhadas de uma série de outras patologias.

Esses e outros motivos nos permitem inclusive sugerir e deixar como alerta, para que as instituições de saúde reestruturem e dêem uma maior atenção aos processos de elaboração e preenchimento dos protocolos de seus pacientes, principalmente visando a atual tendência de se estabelecer um protocolo único dos pacientes pelo Sistema Nacional de Saúde.

4.3.2 Aplicação de redes neurais artificiais

Uma rede neural artificial do tipo *perceptron* multicamadas tem como característica principal de aplicação a classificação de padrões não-linearmente separáveis, ou seja, padrões que não possuem uma característica específica que provê essa classificação e sim uma combinação de características. Por esse motivo, principalmente, não se pode esperar, inicialmente, que um sistema baseado nessa técnica alcance 100% de êxito na classificação. Por quê, então, a utilização dessa técnica em detrimento a outras? Uma série de motivos pode ser apresentada, sendo o principal, o fato de que um sistema baseado em redes neurais artificiais não precisa armazenar um enorme banco de dados para ser consultado a cada execução, como acontece com a maioria das outras técnicas. Uma vez a rede treinada e seus pesos fixados, não é preciso mais acessar o banco de dados, tornando o sistema bem mais rápido e computacionalmente mais leve.

4.3.3 Configuração da rede neural

Com relação ao número de camadas ocultas e de elementos nessas camadas, não foi encontrada na literatura nenhuma regra básica que defina os melhores valores. Em todos os trabalhos pesquisados, essas quantidades são bem variadas, não apresentando muita relação entre si.

Na maioria das publicações verificadas obteve-se, como sugestão, iniciar os trabalhos com uma configuração de uma camada oculta com um pequeno número de elementos e ir aumentando essa quantidade para se verificar as diferenças.

Nesse trabalho, partiu-se de uma configuração com 5 elementos na camada oculta, aumentando-se gradativamente essa quantidade até alcançar os 35 elementos.

Trabalhando-se com configurações de 5 até 13 elementos, obteve-se índices de acerto muito baixos (não ultrapassando a casa dos 40%). Acima dos 14 elementos, os índices começaram a atingir valores mais aceitáveis, voltando a diminuir significativamente em configurações com 25 elementos ou mais. Os melhores índices foram obtidos na rede com 19 elementos.

O número de camadas ocultas também é alvo de intensas pesquisas para se tentar alcançar os valores mais adequados. Optou-se, nesse trabalho, em efetuar também testes com duas camadas ocultas. Nesses testes, os índices encontrados ficaram, na maior parte das vezes, abaixo dos encontrados com apenas uma camada oculta, e, nas vezes em que foram obtidos índices maiores, a diferença foi muito pequena, não justificando o aumento da complexidade e do peso computacional da implementação.

Estabeleceu-se, portanto, a configuração ideal da rede neural, para esse trabalho, composta de 26 elementos na camada de entrada (os 26 elementos do protocolo de entrada), 9 elementos na camada de saída (as 9 patologias a serem classificadas) e uma camada oculta com 19 elementos, conectando a camada de entrada à de saída.

4.3.4 Treinamento da rede neural

Para ilustrar o treinamento da rede neural, foram obtidos, para cada teste efetuado, os gráficos do índice de erro médio calculado a cada época de treinamento.

Na figura 13 é mostrado o gráfico do teste em que foram obtidos os melhores índices de acerto.

Figura 13 Gráfico do erro médio obtido no treinamento da rede neural, após 2000 épocas.

Em todos os gráficos obtidos, como os exemplos mostrados, notou-se claramente que o erro médio da rede neural tende sempre a um valor mínimo, estabilizando-se depois de um certo número de épocas.

Com o intuito de verificar se o aumento do número de épocas de treinamento pudesse diminuir ainda mais esse índice de erro, procedeu-se também alguns testes com mais épocas. O exemplo apresentado na figura 14 mostra que a diminuição pode existir, porém com uma taxa muito pequena, o que não justifica o aumento considerável no tempo de processamento. Nesse exemplo a rede neural foi treinada por 5000 épocas, com as mesmas configurações.

Figura 14 Gráfico do erro médio obtido no treinamento da rede neural, após 5000 épocas.

Como exemplo da grande diversidade de situações encontradas, com pequenas variações de configuração da rede neural, são mostrados outros gráficos obtidos, na figura 15.

Figura 15 Exemplos de gráficos de erro médio obtidos no treinamento da rede neural, em diferentes configurações.

4.3.5 Resultados alcançados

Como já comentado anteriormente, os testes de performance do sistema foram realizados de duas formas: com dados utilizados no treinamento e com dados não utilizados no treinamento.

A saída do sistema apresenta todas as nove patologias possíveis, classificadas de acordo com a probabilidade de ser a correta. Foram analisadas as situações em que o sistema apresentou o resultado correto como primeira ou segunda opção da lista classificada.

Abaixo são apresentados os melhores índices de acerto obtidos pelo sistema (Quadro 1).

Quadro 1 Percentuais de acerto obtidos pelo sistema.

	Apresentação da patologia correta na primeira possibilidade	Apresentação da patologia correta entre as duas primeiras possibilidades
Teste realizado com amostras não usadas no treinamento.	68,75 %	81,25 %
Teste realizado com amostras usadas no treinamento.	81,25 %	93,75 %

Como todos esses índices ficaram abaixo do esperado, foi realizado um novo teste, desta vez com uma distribuição mais uniforme das amostras. Utilizou-se neste teste a seguinte distribuição: 16 amostras referentes a blastomicose sul-americana, 14 referentes a histoplasmoze, 11 amostras de fibrose pulmonar idiopática, 10 de tuberculose miliar, e 9 amostras referentes a sarcoidose, totalizando 60 amostras, tendo sido deixadas de fora as amostras de esclerodermia, histiocitose X, silicose e linfangite carcinomatosa, por terem sido obtidas em pequena quantidade.

Foi mantida a mesma configuração e estrutura da rede neural, exceto a quantidade de elementos de saída, que foram adequados às cinco possibilidades aqui trabalhadas.

O treinamento da rede também foi realizado da mesma maneira, e a performance do sistema foi testada com 12 amostras não usadas no treinamento, apresentando um índice de acerto de 91,67%, índice este já bastante mais confiável que os anteriores.

CONCLUSÃO

O diagnóstico diferencial das lesões intersticiais pulmonares através do exame radiológico simples apresenta grande dificuldade até mesmo para os especialistas bem treinados, devido à grande semelhança nas características dessas patologias. Porém esse exame ainda está entre os mais utilizados, principalmente pelo fator custo.

Um importante detalhe que se pôde observar durante o desenvolvimento do estudo foi a grande subjetividade apresentada pelos médicos especialistas na análise e quantificação dos parâmetros radiológicos para a elaboração do diagnóstico.

Objetivando o desenvolvimento de um sistema computacional que pudesse ser de auxílio a esse diagnóstico e, principalmente, servir como suporte ao treinamento e atualização dos profissionais envolvidos com essa tarefa, foi proposto esse estudo sobre a utilização da técnica computacional das redes neurais artificiais para esse fim.

Observando os resultados obtidos pela pesquisa, pode-se concluir que as redes neurais artificiais cumprem bem o seu papel de classificador de padrões, para esse tipo de dado trabalhado.

Credita-se os índices de acerto relativamente baixos desse experimento à pequena quantidade de amostras obtidas para o treinamento da rede e principalmente à sua distribuição bastante irregular entre os padrões de classificação (um padrão com 21 amostras frente a outro com apenas 2 amostras), o que pode ser comprovado através dos resultados obtidos no teste em que foram excluídas as patologias com pequenas quantidades de amostras, deixando a distribuição mais regular.

Apesar disso, pode-se já afirmar que um sistema como o construído pode ser de grande valor para o médico radiologista no auxílio ao diagnóstico desse grupo de patologias, principalmente se usado como uma “segunda opinião”, para

sanar dúvidas, e também como uma ferramenta para auxílio ao treinamento de futuros profissionais da área.

Como perspectivas para a continuidade dos trabalhos, espera-se conseguir um maior número de amostras com uma distribuição mais regular, através de intercâmbio com outras instituições de saúde, o que não foi possível obter em tempo hábil para a conclusão dessa pesquisa.

Também como prosseguimento dos trabalhos, pretende-se desenvolver um sistema mais completo, incorporando-se a extração automática das características de entrada do sistema classificador, através de técnicas de processamento digital de imagens.

REFERÊNCIAS BIBLIOGRÁFICAS

ABE, H.; ASHIZAWA, K.; KATSURAGAWA, S.; MACMAHON, H.; DOI, K. Use of an artificial neural network to determine the diagnostic value of specific clinical and radiologic parameters in the diagnosis of interstitial lung disease on chest radiographs. *Academic Radiology*. Vol.9, nr.1, p.13-17, jan, 2002.

ANDRÉ, T. C. S. S. *Diagnóstico computadorizado de câncer de mama através de redes neurais*. Dissertação (Mestrado). Ribeirão Preto: Faculdade de Filosofia Ciências e Letras de Ribeirão Preto, Universidade de São Paulo, 1999.

ASADA, N.; DOI, K.; MACMAHON, H.; MONTNER, S. M.; GIGER, M. L.; ABE, C.; WU, Y. Potential usefulness of an artificial neural network for differential diagnosis of interstitial lung disease: pilot study. *Radiology*. Vol.177, nr.3, p.857-860, dec, 1990.

ASHIZAWA, K.; ISHIDA, T.; MACMAHON, H.; VYBORNÝ, C. J.; KATSURAGAWA, S.; DOI, K. Artificial neural networks in chest radiography: application to the differential diagnosis of interstitial lung disease. *Academic Radiology*. Vol.6, nr.1, p.2-9, jan, 1999.

ASHIZAWA, K.; MACMAHON, H.; ISHIDA, T.; NAKAMURA, K.; VYBORNÝ, C. J.; KATSURAGAWA, S.; DOI, K. Effect of an artificial neural network on radiologists' performance in the differential diagnosis of interstitial lung disease using chest radiographs. *American Journal of Roentgenology*. Vol.172, p.1311-1315, may, 1999.

BATES, D. W.; COHEN, M.; LEAPE, L. L.; OVERHAGE, J. M.; SHABOT, M. M.; SHERIDAN, T. Reducing the frequency of errors in medicine using information technology. *Journal of the American Medical Informatics Association*. Vol.8, p.299-308, 2001.

BEALE, R.; JACKSON, T. *Neural computing: an introduction*. Bristol: IOP Publishing, 1990.

BLOCK, H. D. The perceptron: a model for brain functioning. I. *Reviews of Modern Physics*. Vol.34, p.123-135, 1962.

BURKE, H. B. The importance of artificial neural networks in biomedicine. In: KELLER, P. E.; HASHEM, S.; KANGAS, L. J.; KOUZES, R. T. (eds.) *Applications of neural networks in environment, energy and health*. Chp.17, p.145-153. Singapore: World Scientific Publishing, 1996.

CHAN, H-P.; SAHINER, B.; PETRICK, N.; HELVIE, M. A.; LAM, K. L.; ADLER, D. D.; GOODSITT, M. M. Computerized classification of malignant and benign microcalcifications on mammograms: texture analysis using an artificial neural network. *Physics in Medicine and Biology*. Vol.42, nr.3, p.549-567, mar, 1997.

CHEN, D-R.; CHANG, R-F.; HUANG, Y-L. Computer-aided diagnosis applied to US of solid breast nodules by using neural networks. *Radiology*. Vol.213, nr.2, p.407-412, nov, 1999.

COEIRA, E. W. Artificial intelligence in medicine: the challenges ahead. *Journal of the American Medical Informatics Association*. Vol.3, nr.6, p.363-366, 1996.

COSTA, J. A. F. *Classificação automática de objetos em linhas de produção industriais utilizando redes neurais artificiais*. Relatório Técnico (RT-DC 002/97). São Carlos: Universidade Federal de São Carlos, 1997.

CUKIER, A.; NAKATANI, J.; MORRONE, N. (eds.) *Pneumologia: atualização e reciclagem*. Vol. II. 2.ed. São Paulo: Atheneu, 1997.

EL-SOLH, A. A.; HSIAO, C-B.; GOODNOUGH, S.; SERGHANI, J.; GRANT, B. J. B. Predicting active pulmonary tuberculosis using an artificial neural network. *Chest*. Vol.116, nr.4, p.968-973, oct, 1999.

FRASER, R. S.; PARÉ, J. A. P.; FRASER, R. G.; PARÉ, P. D. *Synopsis of diseases of the chest*. 2.ed. Philadelphia: WB Saunders, 1994.

GARCIA-PEREZ, E.; VIOLANTE, A.; CERVANTES-PEREZ, F. Using neural networks for differential diagnosis of Alzheimer disease and vascular demetia. *Expert Systems with Applications*. Vol.14, nr.1-2, p.219-225, jan-feb, 1998.

GIGER, M. L. Computer-aided diagnosis in radiology. *Academic Radiology*. Vol.9, nr.1, p.1-3, jan, 2002.

GURNEY, J. W.; SWENSEN, S. J. Solitary pulmonary nodules: determining the likelihood of malignancy with neural network analysis. *Radiology*. Vol.196, nr.3, p.823-829, sep, 1995.

GUYTON, A. C. *Anatomia e fisiologia do sistema nervoso*. Rio de Janeiro: Interamericana, 1977.

HASSOUN, M. H. *Fundamentals of artificial neural networks*. Cambridge, Mass.: MIT Press, 1995.

HAYKIN, S. *Redes neurais: princípios e prática*. Trad. P. M. Engel. 2.ed. Porto Alegre: Bookman, 2001.

HINTON, G. E. How neural networks learn from experience. *Scientific American*. Vol.267, nr.3, p.105-110, 1992.

HOLST, H.; ASTROM, K.; JARUND, A.; PALMER, J.; HEYDEN, A.; KAHL, F.; TAGIL, K.; EVANDER, E.; SPARR, G.; EDENBRANDT, L. Automated interpretation of ventilation-perfusion lung scintigrams for the diagnosis of pulmonary embolism using artificial neural networks. *European Journal of Nuclear Medicine*. Vol.27, nr.4, p.300-306, apr, 2000.

HOPFIELD, J. J. Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the National Academy of Sciences*. Vol.79, p.2554-2558, 1982.

HUNT, D. L.; HAYNES, B.; HANNA, S. E.; SMITH, K. Effects of computer-based clinical decision support systems on physician performance and patient outcomes: a systematic review. *Journal of the American Medical Association*. Vol.280, nr.15, p.1339-1346, oct, 1998.

ISHIDA, T.; KATSURAGAWA, S.; ASHIZAWA, K.; MACMAHON, H.; DOI, K. Application of artificial neural networks for quantitative analysis of image data in chest radiographs for detection of interstitial lung disease. *Journal of Digital Imaging*. Vol.11, nr.4, p.182-192, nov, 1998.

JIANG, Y.; NISHIKAWA, R. M.; WOLVERTON, D. E.; METZ, C. E.; GIGER, M. L.; SCHMIDT, R. A.; VYBORNÝ, C. J.; DOI, K. Malignant and benign clustered microcalcifications: automated feature analysis and classification. *Radiology*. Vol.198, nr.3, p.671-678, mar, 1996.

KAHN-JUNIOR, C. E. Artificial intelligence in radiology: decision support systems. *RadioGraphics*. Vol.14, nr.4, p.849-861, 1994.

KATSURAGAWA, S.; DOI, K.; MACMAHON, H. Image feature analysis and computer-aided diagnosis in digital radiography: classification of normal and abnormal lungs with interstitial disease in chest images. *Medical Physics*. Vol.16, nr.1, p.38-44, jan/feb, 1989.

KATSURAGAWA, S.; DOI, K.; NAKAMORI, N.; MACMAHON, H. Image feature analysis and computer-aided diagnosis in digital radiography: effect of digital parameters on the accuracy of computerized analysis of interstitial disease in digital chest radiographs. *Medical Physics*. Vol.17, nr.1, p.72-78, jan/feb, 1990.

KELLER, P. E. *Artificial neural networks in medicine*. Technical Report (PNL-SA-24193). Richland: Pacific Northwest National Laboratory, 1998.

KRÖSE, B.; SMAGT, P. van der. *An introduction to neural network*. Amsterdam: University of Amsterdam, 1996.

MARTINEZ, J. A. B. Doenças intersticiais pulmonares. *Medicina, Ribeirão Preto*. Vol.31, p.247-256, abr/jun, 1998.

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

MINSKY, M.; PAPERT, S. *Perceptrons*. Cambridge, Mass.: MIT Press, 1969.

MONNIER-CHOLLEY, L.; MACMAHON, H.; KATSURAGAWA, S.; MORISHITA, J.; ISHIDA, T.; DOI, K. Computer-aided diagnosis for detection of interstitial opacities on chest radiographs. *American Journal of Roentgenology*. Vol.171, p.1651-1656, dec, 1998.

NAKAMURA, K.; YOSHIDA, H.; ENGELMANN, R.; MACMAHON, H.; KATSURAGAWA, S.; ISHIDA, T.; ASHIZAWA, K.; DOI, K. Computerized analysis of the likelihood of malignancy in solitary pulmonary nodules with use of artificial neural networks. *Radiology*. Vol.214, nr.3, p.823-830, mar, 2000.

PATIL, S.; HENRY, J. W.; RUBENFIRE, M.; STEIN, P. D. Neural network in the clinical diagnosis of acute pulmonary embolism. *Chest*. Vol.104, nr.6, p.1685-1689, 1993.

PAULA, G. L. S. *Aplicação de redes neurais artificiais em instrumentos de avaliação clínica*. Tese (Doutorado). Ribeirão Preto: Universidade de São Paulo, 1998.

PENEDO, M. G.; CARREIRA, M. J.; MOSQUERA, A.; CABELLO, D. Computer-aided diagnosis: a neural-network-based approach to lung nodule detection. *IEEE Transactions on Medical Imaging*. Vol.17, nr.6, p.872-880, dec, 1998.

POPTANI, H.; KAARTINEN, J.; GUPTA, R. K.; NIEMITZ, M.; HILTUNEN, Y.; KAUPPINEN, R. A. Diagnostic assessment of brain tumors and non-neoplastic brain disorders in vivo using proton nuclear magnetic resonance spectroscopy and artificial neural networks. *Journal of Cancer Research and Clinical Oncology*. Vol.125, nr.6, p.343-349, jun, 1999.

REINUS, W. R. Machines that learn: can they learn to interpret radiographs? *American Journal of Roentgenology*. Vol.169, nr.1, p.19-21, jul, 1997.

ROBBINS, S. L.; ANGELL, M.; KUMAR, V. *Patologia básica*. Trad. A. Gelman. São Paulo: Atheneu: Edusp, 1986.

RODRIGUES, F. N.; OLIVEIRA, R. D. *Sistema computacional de apoio ao diagnóstico médico de anemias baseado em redes neurais artificiais*. Monografia (Graduação). Franca: Universidade de Franca, 2001.

ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological Review*. Vol.65, p.386-408, 1958.

SABBATINI, R. M. E. Uso do computador no apoio ao diagnóstico médico. *Informédica*. Vol.1, nr.1, p.5-11, 1993.

SCOTT, J. A.; PALMER, E. L.; FISCHMAN, A. J. How well can radiologists using neural network diagnose pulmonary embolism? *American Journal of Roentgenology*. Vol.175, nr.2, p.399-405, jun, 2000.

SHORTLIFFE, E. H. *Computer-based medical consultation: Mycin*. Amsterdam; Elsevier Scientific, 1976.

SHORTLIFFE, E. H.; PERREAULT, L. E.; WIEDERHOLD, G.; FAGAN, L. M. (eds.) *Medical informatics: computer applications in health care*. Reading, Mass.: Addison-Wesley, 1990.

SIMON, H. A. Why should machines learn?. In: MICHALSKY, R. S.; CARBONELL, J. G.; MITCHELL, T. M. *Machine learning*. Vol.1, Cap.2. Palo Alto: Tioga Publishing, 1983.

TARANTINO, A. B. *Doenças pulmonares*. 2.ed. Rio de Janeiro: Guanabara Koogan, 1982.

THOMPSON, C. Redes neurais artificiais. *Revista Augustus*. Vol.4, nr.6, p.57-65, ago, 1986.

WU, Y.; DOI, K.; GIGER, M. L.; NISHIKAWA, R. M. Computerized detection of clustered microcalcifications in digital mammograms: application of artificial neural network. *Medical Physics*. Vol.19, nr.3, p.555-560, may/jun, 1992.

WU, Y.; GIGER, M. L.; DOI, K.; VYBORNÝ, C. J.; SCHMIDT, R. A.; METZ, C. E. Artificial neural networks in mammography: application to decision making in the diagnosis of breast cancer. *Radiology*. Vol.187, nr.1, p.81-87, apr, 1993.

XU, X. W.; DOI, K.; KOBAYASHI, T.; MACMAHON, H.; GIGER, M. L. Development of an improved CAD scheme for automated detection of lung nodules in digital chest images. *Medical Physics*. Vol.24, nr.9, p.1395-1403, sep, 1997.

APÊNDICE A

NOTAÇÃO UTILIZADA

x	Sinal de entrada de um determinado neurônio (camada de entrada).
y	Sinal de saída calculado para um determinado neurônio da camada de saída.
h	Sinal de saída calculado para um determinado neurônio da camada oculta.
d	Sinal de saída desejado para um determinado neurônio (camada de saída).
e	Sinal de erro calculado na saída de um determinado neurônio.
b	Valor de <i>bias</i> de um determinado neurônio.
v	Peso associado a uma conexão neuronal entre a camada de entrada e a camada oculta.
w	Peso associado a uma conexão neuronal entre a camada oculta e a camada de saída.
λ	Parâmetro de aprendizagem.
Δ	Ajuste de peso de uma conexão neuronal.
δ	Gradiente local para ajuste de peso.
$\mathcal{E}$	Valor instantâneo da energia total do erro a cada padrão de entrada.
$\mathcal{E}_{med}$	Valor da energia média do erro.
$f(u)$	Função de ativação.

APÊNDICE B

RELAÇÃO DE EQUAÇÕES MATEMÁTICAS UTILIZADAS

- (1) Cálculo do sinal de saída de um neurônio artificial simples (pág.40).

$$Y_j = f\left(\sum_{i=1}^n w_i \cdot x_i + b_j\right)$$

- (2) Função de limiar (pág.40).

$$f(u) = \begin{cases} 1 & \text{se } u \geq 0 \\ 0 & \text{se } u < 0 \end{cases}$$

- (3) Função linear por partes (pág.40).

$$f(u) = \begin{cases} 1 & \text{se } u \geq +\frac{1}{2} \\ u & \text{se } +\frac{1}{2} > u > -\frac{1}{2} \\ 0 & \text{se } u \leq -\frac{1}{2} \end{cases}$$

- (4) Função logística (pág.41).

$$f(u) = \frac{1}{1 + e^{-a \cdot u}}$$

- (5) Função tangente hiperbólica (pág.41).

$$f(u) = \tanh(u)$$

- (6) Cálculo do sinal de erro de resposta de um neurônio (pág.43).

$$e_j(n) = d_j(n) - y_j(n)$$

- (7) Regra delta para ajuste de pesos de conexões (pág.44).

$$\Delta w_{jk}(n) = \lambda \cdot e_k(n) \cdot x_j(n)$$

- (8) Atualização do peso de conexões (pág.44).

$$w_{jk}(n+1) = w_{jk}(n) + \Delta w_{jk}(n)$$

- (9) Cálculo do sinal de erro de resposta de um neurônio (pág.49).

$$e_j(n) = d_j(n) - y_j(n)$$

- (10) Valor instantâneo da energia total do erro (pág.49).

$$\mathcal{E}(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n)$$

- (11) Energia média do erro (pág.49).

$$\mathcal{E}_{med} = \frac{1}{N} \sum_{n=1}^N \mathcal{E}(n)$$

- (12) Regra delta generalizada (pág.49).

$$\Delta w_{jk}(n) = \lambda \cdot \delta_k(n) \cdot x_j(n)$$

- (13) Gradiente local para neurônios da camada de saída (pág.50).

$$\delta_k(n) = e_k(n) \cdot y_k(n) \cdot (1 - y_k(n))$$

- (14) Gradiente local para neurônios de camadas ocultas (pág.50).

$$\delta_j(n) = \left(\sum_k \delta_k(n) \cdot w_{jk}(n) \right) \cdot h_j(n) \cdot (1 - h_j(n))$$

- (15) Regra delta reescrita para neurônios da camada de saída (pág.50).

$$\Delta w_{jk}(n) = \lambda \cdot \delta_k(n) \cdot h_j(n)$$

- (16) Regra delta reescrita para neurônios de camadas ocultas (pág.50).

$$\Delta w_{ij}(n) = \lambda \cdot \delta_j(n) \cdot x_i(n)$$

- (17) Função logística. Utilizada na implementação do sistema (pág.66).

$$f(u) = \frac{1}{1 + e^{-a \cdot u}}$$

APÊNDICE C

BASE DE DADOS

Idade	Sexo	Duração dos sintomas			Temperatura	Imunidade	Doença maligna	Fumante	Tratamento com drogas		Exposição à poeira	Exposição a antígenos org.	Campo superior esquerdo	Campo superior direito	Campo médio esquerdo	Campo médio direito	Campo inferior esquerdo	Campo inferior direito	Proximal/Periférico	Homogeneidade	Fino/Grosso	Nodularidade	Linhas septais	Favo de mel	Perda de volume pulmonar	Linfadenopatia	Efusão pleural	Tamanho cardíaco	Saída esperada																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																							
28	0	1	1	1	0	0	1	0	0	0	0	0	3	1	4	3	3	4	2	4	3	3	3	0	0	1	3	3	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

idade	Sexo	Duração dos sintomas		Temperatura	Imunidade	Doença maligna	Fumante	Tratamento com drogas		Exposição à poeira	Exposição a antígenos org.	Campo superior esquerdo	Campo superior direito	Campo médio esquerdo	Campo médio direito	Campo inferior esquerdo	Campo inferior direito	Proximal/Periférico	Homogeneidade	Fino/Grosso	Nodularidade	Linhas septais	Favo de mel	Perda de volume pulmonar	Linfadenopatia	Efusão pleural	Tamanho cardíaco	Saída esperada																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																								
44	0	7	0	0	0	0	1	2	0	1	5	1	3	3	3	0	3	3	2	4	4	0	0	4	0	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0