



MINISTÉRIO DA CIÊNCIA E TECNOLOGIA

**INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS**

**RECUPERAÇÃO DE PERFIS DE TEMPERATURA E  
UMIDADE DA ATMOSFERA A PARTIR DE DADOS DE  
SATÉLITE - ABORDAGENS POR REDES NEURAIAS  
ARTIFICIAIS E IMPLEMENTAÇÃO EM HARDWARE**

Elcio Hideiti Shiguemori

Tese de Doutorado em Computação Aplicada, orientada pelo Prof. Dr. Haroldo  
Fraga de Campos Velho e pelo Prof. Dr. José Demisio Simões da Silva.

INPE  
São José dos Campos  
2007

00.000.00(000.0)

Shiguemori. E. H..  
Tese de Doutorado/ Shiguemori. E. H.. – São José dos  
Campos: INPE, 2007.  
179p.;

1. Problemas Inversos. 2. Redes Neurais. 3. Perfis Verticais. 4. FPGA. 5. Implementação em Hardware. I.Título

*A minha mãe Yurico...  
à minha namorada Ana Paula e ...  
à minha irmã Erica.*



## AGRADECIMENTOS

Primeiramente a Deus, que, através de sua infinita bondade, nos concede incontáveis oportunidades para o crescimento.

Aos meus orientadores Dr. Haroldo Fraga de Campos Velho e Dr. José Demísio Simões da Silva, por quem tenho profunda admiração. Agradeço pela confiança e por terem me orientado de forma segura e amiga.

À minha querida namorada Ana Paula por estar sempre ao meu lado me ajudando e incentivando nas horas em que mais precisei.

À minha querida mãe Yurico e a minha irmã Erica que, com muito amor e carinho me incentivaram toda a minha vida, me apoiando e estando ao meu lado em todos os momentos.

Agradeço ao meu avô Noboru Gondo que com muito carinho sempre me deu forças, e acompanhou em espírito a fase final da tese.

À minha tia Dica, que muito me apoiou, confiou e torceu por mim.

Ao amigo Silvio de Souza Goes pelo incentivo.

Em memória ao meu pai Mário e aos meus tios Bruno e Hirofumi, pois sei que acompanharam em espírito meu esforço.

Aos meus sogros Agostinho e Aparecida Castro, pelo incentivo

Aos pesquisadores Dr. João Carlos Carvalho e Dr. Rodrigo Augusto Ferreira de Souza (CPTEC/INPE) pela disponibilização dos dados do CPTEC/INPE, discussões e colaboração na conduta dos experimentos.

Ao Professor Dr. João Pedro Braga da Universidade Federal de Minas Gerais pelo trabalho conjunto, na colaboração na tese e pela recepção. Também aos alunos do Laboratório de Química da UFMG, em especial à Vanessa Viterbo e Rita de Cassia Oliveira Sebastião pela cooperação no desenvolvimento da rede de Hopfield.

Ao meu amigo Dr. Francisco Tavares pelas sugestões e incentivo durante minha formação acadêmica.

À Cristina do LAC ajudou durante todos os anos que estive no INPE.

Ao pessoal da SPG, em especial à Carol e ao Lafaiete.

Ao pessoal da biblioteca e da segurança que deram o apoio durante todos os anos no INPE.

À Ana Paula e Isabela que me ajudaram nas correções do texto.

Aos amigos do INPE, que acompanharam e apoiaram este trabalho, em especial aos amigos Fabrício Pereira Härter, Felipe Leonardo Lobo Medeiros, Isabela Neves Drummond, Leonardo Dagnino Chiwiakowsky e Roberto Pinto Souto.

Aos amigos do IEAv em especial ao Major Maurício Pozzobom Martins e Major Eduardo Viegas Dalle Lucca pelo incentivo.

Ao CNPq pelo apoio financeiro e pela compra dos equipamentos.

## RESUMO

Esta tese aborda o uso de redes neurais na solução do problema inverso para recuperar perfis verticais de temperatura e umidade da atmosfera a partir de dados de satélites. As redes neurais artificiais são apresentadas como métodos alternativos na recuperação de dados atmosféricos, problemas estes considerados mal-postos que requerem técnicas numéricas avançadas, como regularização, quando resolvidos por métodos clássicos. São estudadas diferentes redes neurais, a rede Perceptron de Camadas Múltiplas com aprendizagem por retropropagação do erro, a rede Funções de Base Radial, a rede de Hopfield, além de uma variação da rede Funções de Base Radial, com dados de diferentes sensores e regiões do planeta. A análise de desempenho dos modelos de redes é feita apresentando-se dados não usados no treinamento, adicionando-se ruído gaussiano e dados reais medidos por satélites. Os perfis verticais de temperatura obtidos pela técnica são próximos aos obtidos por medidas de radiossondagem e comparados com resultados obtidos pelo método clássico de solução de problemas inversos, a regularização. É realizada uma implementação num dispositivo lógico programável possibilitando que a estimação dos dados atmosféricos seja realizada em tempo-real e embarcada em satélites.



# **ATMOSPHERIC TEMPERATURE AND HUMIDITY RETRIEVAL FROM SATELLITE DATA - ARTIFICIAL NEURAL NETWORKS AND HARDWARE IMPLEMENTATION APPROACHES**

## **ABSTRACT**

This thesis presents Artificial Neural Networks for inverse problem solution to recover atmospheric temperature and moisture profiles from satellite data. The Artificial Neural Networks are presented as alternative methods in the solution of inverse problems in the atmospheric data retrieval, considered ill-posed problems and requiring advanced numerical techniques to solve them, e. g. regularization methods, when solving by classic methods. Different neural networks are studied, the MultiLayer Perceptron, Radial Basis Function, Hopfield neural networks, and also a variation of the Radial Basis Function. Different kinds of atmospheric sensors of different satellites, and also tested with Global and Brazil data. The analysis of neural networks models is done presenting the data not used in training phase, adding gaussian noise and satellite data. The temperature and moisture profiles obtained by the neural networks are near of radiosonde measurements and are compared with the ones obtained by classic method of inverse problem solution, the regularization method. A hardware implementation in programmable logic device is done and the real-time and on-board atmospheric temperature and moisture retrieval are enable.



## SUMÁRIO

Pág.

LISTA DE FIGURAS

LISTA DE TABELAS

LISTA DE SIGLAS E ABREVIATURAS

LISTA DE SÍMBOLOS

**CAPÍTULO 1 - INTRODUÇÃO** **27**

**CAPÍTULO 2 - TRANSFERÊNCIA RADIATIVA NA ATMOSFERA** **35**

2.1 - Radiação Eletromagnética . . . . . 36

2.2 - A Equação Integral da Transferência Radiativa (EITR) . . . . . 39

2.3 - Funções Peso . . . . . 43

2.4 - Satélites e Sondagem Remota . . . . . 44

2.4.1 - Instrumentos de Sondagem . . . . . 45

**CAPÍTULO 3 - PROBLEMAS INVERSOS** **49**

3.1 - Problema Mal-posto . . . . . 50

3.2 - Métodos de Solução de Problemas Inversos . . . . . 51

3.2.1 - Inversão Direta . . . . . 52

3.2.2 - Mínimos Quadrados . . . . . 52

3.2.3 - Métodos de Regularização . . . . . 53

3.3 - Determinação do Parâmetro de Regularização . . . . . 55

3.4 - Métodos de Otimização . . . . . 56

3.5 - Solução de Problemas Inversos por Redes Neurais Artificiais . . . . . 57

**CAPÍTULO 4 - REDES NEURAIS ARTIFICIAIS** **59**

4.1 - Neurônios Biológicos . . . . . 61

4.2 - Neurônios Artificiais . . . . . 62

4.3 - Funções de Ativação . . . . . 63

4.4 - Arquitetura das Redes Neurais Artificiais . . . . . 64

4.5 - Funcionamento das Redes Neurais . . . . .	65
4.6 - Perceptron . . . . .	66
4.7 - Rede Perceptrons de Múltiplas Camadas . . . . .	67
4.7.1 - Determinação dos pesos sinápticos - $w_{ji}(n)$ . . . . .	68
4.8 - Rede de Funções de Base Radial . . . . .	73
4.8.1 - Centros Fixos Selecionados Aleatoriamente . . . . .	74
4.8.2 - Seleção Auto-organizada de Centros . . . . .	74
4.9 - Proposta de uma Rede de Funções de Base Radial Não-Extensiva . . . . .	75
4.10 - Rede de Hopfield . . . . .	79
4.11 - Utilização da Rede de Hopfield na estimação de perfis verticais de temperatura da atmosfera . . . . .	84
<b>CAPÍTULO 5 - DISPOSITIVOS LÓGICOS PROGRAMÁVEIS</b>	<b>87</b>
5.1 - Dispositivos FPGA . . . . .	88
5.2 - Implementação utilizando Dispositivos Lógicos Programáveis . . . . .	91
5.3 - VHDL . . . . .	94
<b>CAPÍTULO 6 - IMPLEMENTAÇÃO E RESULTADOS</b>	<b>97</b>
6.1 - Medidas de Radiossondas . . . . .	98
6.2 - Solução do Problema Direto . . . . .	101
6.3 - Pré-processamento dos dados . . . . .	102
6.4 - Treinamento . . . . .	103
6.5 - Generalização . . . . .	103
6.6 - Implementação em VHDL/FPGA . . . . .	104
6.7 - Diferentes testes para análise da metodologia . . . . .	104
6.8 - Cálculo dos Erros . . . . .	106
6.9 - Recuperação de dados atmosféricos utilizando a rede Perceptron de Múltiplas Camadas - RPMC . . . . .	108
6.9.1 - Recuperação dos perfis verticais de temperatura com uso da RPMC - sensor HIRS/NOAA-14 . . . . .	108
6.9.2 - Estimação de dados reais do HIRS/NOAA-14 . . . . .	114
6.9.3 - Recuperação de perfis de temperatura utilizando a RPMC com dados do HIRS/NOAA-16 . . . . .	117
6.9.4 - Recuperação dos perfis verticais de temperatura com uso da RPMC - AIRS/AQUA . . . . .	123

6.9.5 - Estimaco de perfis verticais de umidade da atmosfera utilizando-se redes neurais artificiais . . . . .	125
6.10 -Recuperao de perfis verticais de temperatura da atmosfera utilizando-se a rede Funoes de Base Radial . . . . .	128
6.10.1 -Recuperao dos perfis verticais de temperatura com uso da RFBR - sensor HIRS/NOAA-14 . . . . .	128
6.10.2 -Estimaco de dados reais do HIRS/NOAA-14 com uso da RFBR . . . . .	133
6.11 -Recuperao de dados atmosfricos utilizando a rede Funoes de Base Radial No-Extensiva . . . . .	135
6.11.1 -Resultados utilizando-se o banco de dados sintticos . . . . .	135
6.11.2 -Resultados utilizando-se o banco TIGR-P . . . . .	138
6.12 -Resultados utilizando-se a RFBR-NE: conjuntos de dados Sinttico e TIGR-P . . . . .	139
6.13 -Estimaco de dados reais do HIRS/NOAA-14 com uso da RFBR-NE . . . . .	141
6.14 -Emprego da Rede de Hopfield . . . . .	146
6.14.1 -Estimaco de dados reais do HIRS/NOAA-14 com uso da rede de Hopfield	146
6.14.2 -Estimaco de perfis verticais de temperatura atravs da rede de Hopfield para o HIRS/NOAA-16 . . . . .	148
6.14.3 -Resultados utilizando-se o banco TIGR-C . . . . .	148
6.14.4 -Resultados utilizando o banco NESDISPR . . . . .	150
6.15 -Estimaco de perfis verticais de temperatura utilizando-se FPGA . . . . .	151
6.16 -Estimaco de dados reais do HIRS/NOAA-14 utilizando-se FPGA . . . . .	158
<b>CAPTULO 7 - CONCLUSOES</b>	<b>161</b>
<b>REFERNCIAS BIBLIOGRFICAS</b>	<b>167</b>



## LISTA DE FIGURAS

	<u>Pág.</u>
1.1 Processo de inversão utilizando RNAs . . . . .	34
2.1 Perfil de temperatura vertical. <i>Adaptado de (FERREIRA, 2004)</i> . . . . .	36
2.2 Esquema geométrico para atmosfera plano-paralela . . . . .	40
2.3 Esquema de um feixe de radiação atravessando um meio absorvente. . . . .	42
2.4 Instrumentos a bordo dos satélites NOAA. . . . .	46
3.1 Problema inverso versus problema direto. . . . .	50
3.2 Método de Regularização . . . . .	53
3.3 Exemplos de inversões usando redes neurais . . . . .	58
4.1 Esquema da célula neural . . . . .	61
4.2 Representação de um neurônio artificial. FONTE:Haykin (2000, p. 36) . . . . .	62
4.3 Funções de Ativação . . . . .	63
4.4 Rede com uma única camada. . . . .	64
4.5 Rede de três camadas. . . . .	65
4.6 Distribuição de Tsallis para vários valores de $q$ . Fonte: (TSALLIS, 1999) . . . . .	78
5.1 Elementos formando um único bloco lógico programável. Fonte: Maxfield, 2004. . . . .	91
5.2 Visão de cima para baixo de uma arquitetura FPGA genérica. Fonte: Maxfield, 2004. . . . .	91

5.3	Concorrência de uma descrição. Fonte: Adaptado de d'Amore, 2005. . . . .	95
6.1	Metodologia . . . . .	97
6.2	Média das temperaturas dos bancos e seus desvios padrão . . . . .	100
6.3	Exemplo da solução da ETR (a) temperatura e (b) radiância . . . . .	102
6.4	Exemplo de uma par de treinamento. . . . .	103
6.5	Camadas para análise dos erros . . . . .	107
6.6	Testes . . . . .	107
6.7	Exemplo 1 (a) Perfil de temperatura obtido com a RPMC e o banco sintético, (b) erro da recuperação em relação à radiossondagem. . . . .	109
6.8	Exemplo 2: (a) Perfil de temperatura obtido com a RPMC e o banco sintético, (b) erro da recuperação em relação à radiossondagem. . . . .	110
6.9	Exemplo 1: (a) Perfil de temperatura obtido com a RPMC e o banco TIGR-P, (b) erro da recuperação em relação à radiossondagem. . . . .	111
6.10	Exemplo 2: (a) Perfil de temperatura obtido com a RPMC e o banco TIGR-P, (b) erro da recuperação em relação à radiossondagem. . . . .	112
6.11	Exemplo 1: (a) Perfil de temperatura obtido com a RPMC e o banco Sintético+TIGR-P, (b) erro da recuperação em relação à radiossondagem. . . . .	113
6.12	Exemplo 2: (a) Perfil de temperatura obtido com a RPMC e o banco Sintético+TIGR-P, (b) erro da recuperação em relação à radiossondagem. . . . .	114
6.13	(a) Perfil de temperatura obtido com a RPMC treinada com o banco Sintético, (b) erro da recuperação em relação à radiossondagem. . . . .	115
6.14	(a) Perfil de temperatura obtido com a RPMC treinada com o banco TIGR-P, (b) erro da recuperação em relação à radiossondagem. . . . .	116
6.15	(a) Perfil de temperatura obtido com a RPMC treinada com o banco Sintético+TIGR-P, (b) erro da recuperação em relação à radiossondagem. . . . .	116

6.16	Exemplo 1: (a) Perfil de temperatura obtido com a RPMC com os dados TIGR-C, (b) erro da recuperação em relação à radiossondagem. . . . .	118
6.17	Exemplo 2: (a) Perfil de temperatura obtido com a RPMC com os dados TIGR-C, (b) erro da recuperação em relação à radiossondagem. . . . .	119
6.18	Exemplo 1: (a) Perfil de temperatura obtido com a RPMC com os dados NESDISPR, (b) erro da recuperação em relação à radiossondagem. . . .	120
6.19	Exemplo 2: (a) Perfil de temperatura obtido com a RPMC com os dados NESDISPR, (b) erro da recuperação em relação à radiossondagem. . . .	121
6.20	Exemplo 1: (a) Perfil de temperatura obtido com a RPMC com os dados CLASS1, (b) erro da recuperação em relação à radiossondagem. . . . .	122
6.21	Exemplo 2: (a) Perfil de temperatura obtido com a RPMC com os dados CLASS1, (b) erro da recuperação em relação à radiossondagem. . . . .	123
6.22	Exemplo 1: (a) Perfil de temperatura obtido com a RPMC com os dados BD4+BD5+BD6, (b) erro da recuperação em relação à radiossondagem.	124
6.23	Exemplo 2: (a) Perfil de temperatura obtido com a RPMC com os dados BD4+BD5+BD6, (b) erro da recuperação em relação à radiossondagem.	125
6.24	Exemplos de perfis de umidade obtidos com a RPMC do banco TIGR-C.	127
6.25	Exemplo 1: (a) Perfil de temperatura obtido com a RFBR com os dados sintéticos, (b) erro da recuperação em relação à radiossondagem. . . . .	129
6.26	Exemplo 2: (a) Perfil de temperatura obtido com a RFBR com os dados sintéticos, (b) erro da recuperação em relação à radiossondagem. . . . .	130
6.27	Exemplo 1: (a) Perfil de temperatura obtido com a RFBR e o banco TIGR-P, (b) erro da recuperação em relação à radiossondagem. . . . .	131
6.28	Exemplo 2: (a) Perfil de temperatura obtido com a RFBR e o banco TIGR-P, (b) erro da recuperação em relação à radiossondagem. . . . .	131
6.29	Exemplo 1: (a) Perfil de temperatura obtido com a RFBR e o banco Sintético+TIGR-P, (b) erro da recuperação em relação à radiossondagem.	132

6.30	Exemplo 2: (a) Perfil de temperatura obtido com a RFBR e o banco Sintético+TIGR-P, (b) erro da recuperação em relação à radiossondagem.	133
6.31	(a) Perfil de temperatura obtido com a RFBR treinada com banco Sintético, (b) erro da recuperação em relação à radiossondagem.	134
6.32	(a) Perfil de temperatura obtido com a RFBR treinada com o banco TIGR-P, (b) erro da recuperação em relação à radiossondagem.	134
6.33	(a) Perfil de temperatura obtido com a RFBR treinada com o banco Sintético+TIGR-P, (b) erro da recuperação em relação à radiossondagem.	135
6.34	Distribuições para diferentes valores de $q$	136
6.35	Exemplo 1: (a) Perfil de temperatura obtido com a RFBR-NE e o banco TIGR-P, (b) erro da recuperação em relação à radiossondagem.	137
6.36	Exemplo 2: (a) Perfil de temperatura obtido com a RFBR-NE e o banco TIGR-P, (b) erro da recuperação em relação à radiossondagem.	137
6.37	Exemplo 1: (a) Perfil de temperatura obtido com a RFBR-NE e o banco TIGR-P, (b) erro da recuperação em relação à radiossondagem.	138
6.38	Exemplo 2: (a) Perfil de temperatura obtido com a RFBR-NE e o banco TIGR-P, (b) erro da recuperação em relação à radiossondagem.	139
6.39	Exemplo 1: (a) Perfil de temperatura obtido com a RFBR-NE, (b) erro da recuperação em relação à radiossondagem.	140
6.40	Exemplo 2: (a) Perfil de temperatura obtido com a RFBR e o banco TIGR-P, (b) erro da recuperação em relação à radiossondagem.	140
6.41	(a) Perfil de temperatura obtido com a RFBR-NE com $q = 1,0$ , treinada com o banco sintético, (b) erro da recuperação em relação à radiossondagem.	141
6.42	(a) Perfil de temperatura obtido com a RFBR-NE com $q = 0,5$ , treinada com o banco sintético, (b) erro da recuperação em relação à radiossondagem.	142

6.43	(a) Perfil de temperatura obtido com a RFBR-NE com $q = 1, 0$ , treinada com o banco TIGR-P, (b) erro da recuperação em relação à radiossondagem.	143
6.44	(a) Perfil de temperatura obtido com a RFBR-NE com $q = 1, 5$ , treinada com o banco TIGR-P, (b) erro da recuperação em relação à radiossondagem.	143
6.45	(a) Perfil de temperatura obtido com a RFBR-NE com $q = 0, 5$ , treinada com o banco sintético+TIGR-P, (b) erro da recuperação em relação à radiossondagem. . . . .	144
6.46	(a) Perfil de temperatura obtido com a RFBR-NE com $q = 1, 0$ , treinada com o banco sintético+TIGR-P, (b) erro da recuperação em relação à radiossondagem. . . . .	145
6.47	(a) Perfil de temperatura obtido com a RFBR-NE com $q = 1, 5$ , treinada com o banco TIGR-P, (b) erro da recuperação em relação à radiossondagem.	145
6.48	(a) Perfil de temperatura obtido com a rede de Hopfield, (b) erro das recuperações em relação à radiossondagem. . . . .	147
6.49	Estados dos neurônios no tempo. . . . .	148
6.50	Exemplo 1: (a) Perfil de temperatura obtido com a rede de Hopfield, (b) erro da recuperação em relação à radiossondagem. . . . .	149
6.51	Exemplo 2: (a) Perfil de temperatura obtido com a rede de Hopfield, (b) erro da recuperação em relação à radiossondagem. . . . .	149
6.52	Exemplo 1: (a) Perfil de temperatura obtido com a rede de Hopfield, (b) erro da recuperação em relação à radiossondagem. . . . .	150
6.53	Exemplo 2: (a) Perfil de temperatura obtido com a rede de Hopfield, (b) erro da recuperação em relação à radiossondagem. . . . .	151
6.54	Passos para implementação . . . . .	152
6.55	Função de ativação . . . . .	153
6.56	Esquema de ativação . . . . .	154

6.57 Ativação do neurônio 1 da camada escondida da RPMC . . . . .	155
6.58 Máquina de estados 1 . . . . .	156
6.59 Máquina de Estados 2 . . . . .	156
6.60 Máquina de estados 3 . . . . .	157
6.61 Máquina de estados 4 . . . . .	157
6.62 Kit Spartan III . . . . .	158
6.63 Simulação com ModelSim . . . . .	158
6.64 (a) Comparação das estimações em Fortran e VHDL com a radios- sondagem, (b) erros das estimações. . . . .	159

## LISTA DE TABELAS

	<u>Pág.</u>
6.1 Bancos de dados atmosféricos . . . . .	99
6.2 Experimentos com o HIRS/2 - NOAA-14 . . . . .	105
6.3 Erros de Medidas . . . . .	105
6.4 Experimentos com o HIRS/NOAA-16 . . . . .	105
6.5 Experimentos com o AIRS/AQUA . . . . .	106
6.6 Média dos erros da generalização dos Dados Sintéticos . . . . .	108
6.7 Desvios padrão dos erros da generalização dos Dados Sintéticos . . . . .	109
6.8 Média dos erros da generalização do banco TIGR-P . . . . .	111
6.9 Desvios padrão da generalização do banco TIGR-P . . . . .	111
6.10 Média dos erros da generalização do banco sintético + TIGR-P . . . . .	113
6.11 Desvios padrão da generalização do banco sintético + TIGR-P . . . . .	113
6.12 Resultados da generalização do banco TIGR-C . . . . .	118
6.13 Desvios padrão dos erros empregando o banco TIGR-C . . . . .	118
6.14 Média dos erros dos resultados da generalização do banco NESDISPR . . . . .	119
6.15 Desvios padrão dos erros . . . . .	120
6.16 Erros do conjunto de generalização do banco CLASS1 . . . . .	121
6.17 Desvios padrão dos erros do conjunto de generalização do banco CLASS1 . . . . .	122
6.18 REMQ dos resultados da generalização do banco BD4+BD5+BD6 . . . . .	123
6.19 Desvios padrão das REMQ da generalização do banco BD4+BD5+BD6 . . . . .	124

6.20 Erros obtidos nos testes de validação . . . . .	126
6.21 Erros obtidos nos testes de generalização . . . . .	127
6.22 Resultados da generalização do banco Sintético . . . . .	129
6.23 Resultados da generalização do banco TIGR-P . . . . .	130
6.24 Resultados da generalização do banco Sintético + TIGR-P . . . . .	132
6.25 Generalização da RFBR-NE - banco Sintético - Camada 1 . . . . .	136
6.26 Generalização da RFBR-NE - banco TIGR-P - Camada 1 . . . . .	138
6.27 Generalização da RFBR-NE - banco Sintético + TIGR-P - Camada 1 . . . . .	139
6.28 Generalização da Rede de Hopfield - banco TIGR-C . . . . .	148
6.29 Generalização da Rede de Hopfield - banco NESDISPR . . . . .	150

## LISTA DE SIGLAS E ABREVIATURAS

AIRS	–	”Atmospheric Infrared Sounder”
ASIC	–	Circuitos Integrados de Aplicação-Específica
ASSP	–	Partes Padrão de Aplicação-Específicas
AVHRR	–	”Advanced Very High Resolution Radiometer”
BST	–	”Boundary-Scan Test”
CAD	–	Projeto Auxiliado por Computador
CBERS	–	China-Brasil Earth Resource Satellite
CPTEC	–	Centro de Previsão de Tempo e Estudos Climáticos
CPU	–	Unidade Central de Processamento
DSA	–	Divisão de Satélites e Sistemas Ambientais
DSP	–	Processador de Sinais Digitais
EDA	–	Automação de Projeto Eletrônico
EEPROM	–	Memória Somente de Leitura Apagada e Programada Eletricamente
EITR	–	Equação Integral da Transferência Radiativa
EMAS	–	Experimento de Mesoescala da Atmosfera do Sertão
ETR	–	Equação da Transferência Radiativa
FPGA	–	”Field-programmable gate array”
GOES	–	”Geostationary Operational Environmental Satellite”
HDL	–	Linguagem de Descrição de Hardware
HIRS	–	High-resolution Infrared Radiation Sounder
HOP	–	Hopfield
INPE	–	Instituto Nacional de Pesquisas Espaciais
ICI	–	”Inversion Coupled with Imager”
IEEE	–	”Institute of Electrical and Electronics Engineers”
ITPP	–	”International TOVS Processing Package”
JTAG	–	”Joint Test Action Group”
LAC	–	Laboratório de Computação e Matemática Aplicada
LUT	–	”Look-up Table”
MSU	–	”Microwave Sounding Unit”
NESDIS	–	”National Environmental Satellite, Data, and Information Service”
NOAA	–	”National Oceanic and Atmospheric Administration”
PI	–	Problema Inverso
PLD	–	Dispositivos Lógicos Programáveis
RAM	–	Random Access Memory
REMQ	–	Raiz do Erro Médio Quadrático
RFBR	–	Rede Funções de Base Radial
RFBR-NE	–	Rede Funções de Base Radial Não-Extensiva
RNA	–	Rede Neural Artificial
RPMC	–	Rede Perceptron de Múltiplas Camadas

TIGR – "TOVS Initial Guess Retrieval"  
TIROS – "Television and Infrared Observational Satellite"  
TOVS – "TIROS Operational Vertical Sounder"  
SB – Blocos de Conexão  
SCD1 – Satélite de Coleta de Dados  
SMS – "Synchronous Meteorological Satellite"  
SSU – "Stratospheric Sounding Unit"  
VHDL – "VHSIC Hardware Description Language"  
VHSIC – "Very-High-Speed Integrated Circuit "

## LISTA DE SÍMBOLOS

$E$	– energia
$\tilde{\nu}$	– frequência do oscilador
$h$	– constante de Planck
$k_B$	– constante de Boltzmann
$c$	– velocidade da luz
$T$	– temperatura
$I_\lambda$	– radiância monocromática
$\lambda$	– comprimento de onda
$\rho$	– densidade
$k_\lambda$	– absorção
$\sigma_\lambda$	– espalhamento
$j_\lambda$	– função fonte
$B_\lambda$	– função de Planck
$\mathfrak{S}$	– transmitância
$\partial\mathfrak{S}/\partial p$	– função peso
$\Omega$	– operador de regularização
$\alpha$	– parâmetro de regularização
$\varphi$	– função de ativação
$w$	– pesos da rede neural
$b$	– limiar da rede neural
$\eta$	– taxa de aprendizagem
$G$	– função de base radial
$\Gamma$	– função Gamma



## CAPÍTULO 1

### INTRODUÇÃO

O sensoriamento remoto permite a obtenção de informações sobre um objeto, área ou fenômeno através de dados adquiridos por um ou mais dispositivos sem contato direto com estes. Para isto podem ser utilizados vários sensores para coletar remotamente dados que fornecem essas informações.

Os modelos numéricos de previsão de tempo e clima, em meteorologia, necessitam de dados observados que sirvam como condição inicial para sua execução. Tais dados, preferencialmente, devem ser fornecidos por estações terrestres de observação de condições meteorológicas que formam a rede de observações distribuídas pelo planeta para coleta de dados.

Uma importante linha de pesquisa em meteorologia, denominada assimilação de dados, consiste em utilizar dados meteorológicos observados, com o intuito de melhorar as condições iniciais dos modelos numéricos de previsão do tempo e, possivelmente, a previsão fornecida por estes modelos.

Entretanto, os modelos geralmente são executados para previsões em sub-regiões do planeta, continentes, países, estados, cidades, que não são contidas exclusivamente na área de interesse. Isto implica no uso de dados observados provenientes de regiões restritas do planeta, de onde se faz necessário obter os dados observados. Países com grandes extensões territoriais, com diferenças na cadeia produtiva e na economia e/ou com acesso difícil a áreas remotas (oceanos e florestas tropicais), podem não dispor de uma rede de observação completa ou mesmo um número de estações terrestres suficientes para suprir a necessidade de dados. Necessitam, portanto, do uso de sensores remotos que consigam abranger toda a extensão territorial de interesse para a qual se faz necessário executar os modelos de previsão. Isto é obtido através do uso de satélites meteorológicos que proporcionam informação da atmosfera em forma de radiâncias que, por meio de um processo de inversão, são convertidas em variáveis meteorológicas.

O uso dessas sondagens remotas para inicialização de modelos de previsão numérica de tempo resulta num impacto maior no Hemisfério Sul que no Hemisfério Norte (KIDDER; HAAR, 1995). Isto, em parte, ocorre em função da grande cobertura oceânica do Hemisfério Sul, com um baixo número de radiossondas, e da existência de

áreas remotas, como é o caso da Amazônia, onde é difícil manter redes de observações convencionais.

Uma das variáveis ambientais importantes para os processos meteorológicos é o perfil vertical de temperatura na atmosfera, que pode ser estimado a partir das radiâncias medidas pelos sensores a bordo dos satélites, calibrados nas frequências de interesse. Outras variáveis de interesse são os perfis de umidade e de concentração de constituintes atmosféricos. Isto é feito através do processo de inversão matemática da Equação da Transferência Radiativa (ETR), pertencente à classe das equações de Fredholm de primeira espécie. A inversão deste tipo de problema apresenta dificuldades por ser um problema mal-posto, tendo soluções múltiplas e instáveis.

Os principais enfoques da inversão matemática para a solução da ETR são os métodos explícitos, implícitos e híbridos. Nos métodos explícitos busca-se determinar o operador inverso exato ou aproximado, que relaciona os dados e os parâmetros desconhecidos do problema. Nos métodos implícitos a solução é obtida através de um processo iterativo de busca, minimizando-se a distância entre os dados disponíveis e os resultados do modelo direto. Nos híbridos utiliza-se uma combinação dos dois métodos.

O primeiro estudo na utilização de sensores de radiação a bordo de satélites com a finalidade de estimar perfis verticais de temperatura foi apresentado em [King \(1956\)](#). A proposta era que os perfis verticais de temperatura pudessem ser inferidos a partir das intensidades de radiação monocromática em um único canal espectral, proveniente de várias direções.

??) avançou os conceitos sobre as técnicas de sondagem remota sugerindo a utilização de diversos comprimentos de ondas associados à banda de absorção do CO<sub>2</sub> com a radiação emergente de apenas uma direção fixa. Como a transmissividade atmosférica é função do comprimento de onda da radiação, as medidas referentes ao centro da banda (maior absorção) trazem informações provenientes das camadas superiores da atmosfera e as medidas referentes às suas bordas contêm informações oriundas das camadas próximas à superfície.

A partir de 1960, com o desenvolvimento tecnológico dos projetos espaciais, houve um interesse na implantação de novas técnicas de sondagem remota. Paralelamente a estes fatores, houve um avanço nos recursos computacionais e métodos numéricos de

solução de equações diferenciais, em particular das equações de Fredholm de primeira espécie, surgindo vários estudos no sentido de implementar o uso de sondagem remota nos modelos de previsão de tempo.

Com o lançamento do primeiro satélite ambiental em 1960, surgiram várias técnicas para obtenção de perfis verticais de temperatura e umidade. Atualmente a mais utilizada é a International TOVS Processing Package (ITPP-5.0) (NIEMAN; ACHTOR, 1995), que usa medidas de instrumentos que operam a bordo dos satélites de órbita polar da série "Television and Infrared Observations Satellite"(TIROS-N) da "National Oceanic and Atmospheric Administration"(NOAA).

Fleming e McMillin (1977) apresentaram um esquema de tratamento estatístico com dados de radiossondagem para aproximar os perfis obtidos por satélite. Chahine (1968) propôs um método iterativo para inversão da ETR, para estimar os perfis verticais de temperatura utilizando a banda de absorção em 15 m do CO<sub>2</sub>.

Smith *et al.* (1970) derivaram um método implícito para resolução do problema. Os resultados obtidos através desta técnica foram bastante expressivos quando aplicados a situações de céu claro.

McMillin *et al.* (1979) realizaram várias comparações entre resultados obtidos por sondagens TOVS e radiossondagem. Foram analisadas situações de céu limpo, parcialmente coberto e totalmente coberto por nuvens com uso de canais de microondas.

Em Smith *et al.* (1979) foi utilizada uma técnica estatística de inversão e também foram realizadas comparações entre sondagens remotas e radiossondas, utilizando os sensores High-resolution Infrared Radiation Sounder (HIRS) e Microwave Sounding Unit (MSU) que integram o sistema TOVS. Em 1993, Smith *et al.* (1993) propuseram a utilização do sistema Advanced Very High Resolution Radiometer (AVHRR), cuja alta resolução espacial ajuda na melhor distinção e análise multiespectral da atmosfera, principalmente sobre a cobertura de nuvens e temperatura de superfície.

Alguns trabalhos foram propostos no Brasil, utilizando o ITPP. Sakuragi (1992) fez um estudo sobre o impacto dos perfis verticais de temperatura e umidade em modelos de previsão numérica de tempo sobre a região sul e sudeste do Brasil. Teixeira (1996a), Teixeira (1996b) fez comparações entre perfis de temperatura e umidade obtidas pelo TOVS e observações de radiossondagem feitas durante o Experimento

de Mesoescala da Atmosfera do Sertão (EMAS-I), sobre a região nordeste do Brasil. Os resultados apontam uma sensível melhora da versão do ITTP 5.0 em relação à versão anterior (ITTP-4.0). Entretanto, de uma maneira geral foi constatada uma deficiência dos modelos nas estimativas de umidade.

Nogueira (1998) fez um estudo sobre a incorporar informações de imagens do radiômetro avançado de alta resolução “Advanced Very High Resolution Radiometer” - (AVHRR) no pacote internacional de processamento TOVS “International TOVS Processing Package” - (ITPP5.0) para avaliar o desempenho em relação à classificação do padrão de cobertura de nuvens no local da sondagem, além de uma análise dos perfis verticais de temperatura da atmosfera inferidos através do sondador vertical operacional “TIROS Operational Vertical Sounder” - (TOVS). É mostrado que o padrão de nebulosidade é melhor classificado com a introdução dos dados AVHRR e que os perfis verticais de temperatura são influenciados em média até a altura de 700 hPa.

Carvalho (1998) e Ramos *et al.* (1999) propuseram um método iterativo implícito de inversão na obtenção de perfis verticais de temperatura. O método procede a minimização de um funcional composto por uma norma quadrática mais um termo de regularização de alta ordem, utilizando uma rotina numérica de minimização. Além das funções clássicas de regularização de Tikhonov, utilizou-se regularização baseada no princípio da máxima entropia. É apresentada uma comparação com perfis obtidos por radiossondagem. Os resultados das simulações atestam um bom desempenho do método, sobretudo nos níveis de pressão que vão da superfície até a inversão da tropopausa, que é a região de maior interesse meteorológico.

Souza (2004) analisa o desempenho do sistema de sondagem AQUA e do modelo “Inversion Coupled with Imager” (ICI) para recuperar perfis de temperatura e umidade sobre a região Amazônica. Com a desativação do “Humidity Sounder for Brazil” (HSB), busca-se selecionar canais do “Atmospheric Infrared Sounder” (AIRS) sensíveis ao vapor d’água que fossem representativos do comportamento espectral dos canais HSB e simulassem as temperaturas de brilho desses canais a partir de informações dos canais AIRS. A inferência de perfis verticais de temperatura e umidade sobre a região Amazônica foram melhor representadas pelo modelo ICI e pelas análises do modelo de Previsão Numérica de Tempo (PNT) do Centro de Previsão de Tempo e Estudos Climáticos (CPTEC) do que pelo modelo de inversão da “National Aeronautics and Space Administration” (NASA).

Como observado, todas as técnicas propostas têm se mostrado adequadas para abordar o problema da resolução da ETR por técnicas de inversão matemática. No entanto, os avanços da tecnologia de sensores e a redução dos custos de desenvolvimento e lançamento de satélites, aliados às grandes preocupações ambientais têm levado a um aumento significativo de satélites de observação da Terra, do espaço e da atmosfera. Novos sensores são construídos com calibração em faixas e subfaixas específicas do espectro eletromagnético para captura de novos fenômenos, que geram um grande aumento no volume de dados envolvidos nos processos de inversão matemática e exigem, portanto, muito mais recursos computacionais e mais tempo para o processamento.

Em função das grandes transformações ambientais pelas quais passa o planeta, os modelos da dinâmica dos fenômenos ambientais, espaciais e atmosféricos, em particular os de previsão meteorológica de tempo e clima, precisarão gerar estimativas mais precisas e no menor tempo possível. Isso implica na necessidade de se ter acesso às observações ou medidas inferidas a partir de dados de satélites no menor tempo possível ou, idealmente, em tempo real. Assim, um grande desafio consiste na obtenção de sistemas de resolução da ETR, por inversão matemática, que sejam rápidos, de boa qualidade e que demandem o mínimo de recursos computacionais.

Neste sentido, vários trabalhos na literatura têm procurado utilizar as redes neurais artificiais (RNAs) para abordar este problema: [Aires \*et al.\* \(2002\)](#) utilizam uma rede neural regularizada simulando dados atmosféricos com o instrumento IASI. [Vasudevan \*et al.\* \(2004\)](#) utilizam a rede perceptron de múltiplas camadas na estimação de vapor d'água e nuvem. Em ([BLACKWELL, 2004](#); [BLACKWELL, 2005](#)), é utilizado um método híbrido para recuperar perfis de temperatura e umidade da atmosfera simulando céu-claro e parcialmente com nuvens a partir de dados da Sonda Atmosférica Infravermelha (AIRS - do inglês Atmospheric InfraRed Sounder) e AMSU. A metodologia é realizada em dois estágios: no primeiro é utilizada uma transformação de componentes principais e na segunda uma rede neural Perceptron de Múltiplas Camadas. [Diego e Loyola \(2006\)](#) aplicam redes neurais na recuperação de colunas de ozônio da atmosfera.

As RNAs são modelos matemáticos de funcionamento do cérebro constituídas de unidades de processamento (neurônios) interligadas em camadas, imitando a estrutura topológica básica do cérebro, na forma de conectar unidades sensoras

(entradas das RNAs) às unidades do córtex (camadas intermediárias das RNAs) e estas às unidades motoras ou atuadoras (saídas das RNAs).

Além da modelagem topológica, as RNAs também modelam a forma de aquisição do conhecimento do cérebro. Estas RNAs utilizam algoritmos que simulam os processos de aprendizagem realizados, através da adaptação das sinapses (conexões nas RNAs) entre os neurônios.

Portanto, as RNAs são utilizadas como sistemas de processamento da informação que possuem importantes características exibidas pelo cérebro, como paralelismo, distribuição da informação recebida e plasticidade (ou capacidade de adaptação) ao ambiente em que está inserida.

Apesar de seus processos de aprendizagem demandarem tempo, as RNAs, quando solicitadas, podem produzir respostas em frações de segundo dependendo de sua complexidade topológica. Isto se dá pela simplicidade do funcionamento das unidades de processamento que, basicamente, são combinadores lineares das entradas que convergem para si, e que produzem níveis de ativação como função do resultado desta combinação linear.

O uso de RNAs nas abordagens para resolver o problema de inversão descrito anteriormente, são, portanto, tentativas de se obter métodos rápidos, robustos e precisos para a estimação de variáveis ambientais de interesse para os processos meteorológicos.

Entretanto, existem diferentes modelos de RNA ([HAYKIN, 1994](#)), o que dificulta o estabelecimento de uma regra de utilização.

Neste trabalho, diferentes modelos de redes neurais são utilizados na busca por um modelo que seja simples, rápido, preciso e que consiga generalizar seu funcionamento de maneira abrangente, no que diz respeito aos dados de entradas provenientes das medidas de radiâncias obtidas pelos sensores a bordo de satélites. As redes empregadas foram: Perceptron de Camadas Múltiplas com aprendizagem por retropropagação do erro (RPCM), Funções de Base Radial (RFBR) e rede de Hopfield (HOP). Para as redes de funções de Base Radial foi proposta uma nova função de base radial: Função de Base Radial-Não Extensiva (RFBR-NE), composta por funções de base radial baseada na entropia de Tsallis ([TSALLIS, 1988](#)), ([TSALLIS, 1999](#)), que através de um parâmetro  $q$  são obtidas distribuições diferentes

à gaussiana. São realizadas comparações das fases de validação e generalização destas redes neurais.

Os modelos de redes neurais escolhidos são utilizados na análise de diferentes conjuntos contendo dados Globais e do Brasil; e dados de sensores de diferentes satélites. Os testes de validação (ou generalização) das redes neurais são realizados com dados medidos por satélites e os resultados comparados com medidas de radiossondagem.

Embora o uso de RNA na solução de problemas inversos reduza consideravelmente o tempo de processamento, comparado com técnicas tradicionais no processo de inversão, implementações em hardware podem tornar o processamento muito mais rápido, o que é vantajoso quando aplicado em problemas que requerem processamento em tempo-real e/ou embarcado, ou quando há grandes quantidades de dados a serem processados, como no caso dos dados atmosféricos. Os processamentos em tempo-real são principalmente necessários quando há grande quantidade de dados a serem analisados ou que suas soluções sejam necessárias para processos de decisões rápidos. Muitos Problemas Inversos (PI) requerem que suas soluções sejam embarcadas, principalmente em sensoriamento remoto, nos quais os dados adquiridos não estão em contato direto com o objeto, área ou fenômeno sobre investigação.

A Figura 1.1 ilustra o processo de inversão de perfis de temperatura utilizando RNAs. Enfatiza-se a utilização de uma implementação em hardware, abordada neste trabalho onde é escolhida uma topologia de rede neural e desenvolvida uma metodologia para resolução do problema.

Na Figura 1.1 também são destacados os assuntos relacionados aos capítulos seguintes (texto hachurado). No capítulo 2 é apresentado o problema direto, onde é apresentada a física da medida, além de serem descritas as formas de obtenção de suas soluções, empregadas neste trabalho, na geração dos dados para o treinamento, validação e testes das redes neurais.

No capítulo 3, além da teoria geral para solução de equações mal-postas, são discutidos métodos clássicos de solução de problemas inverso.

No capítulo 4 são introduzidas as RNA, onde é apresentado um breve histórico, assim como algumas arquiteturas existentes e alguns algoritmos de treinamento das redes.

No capítulo 5 são introduzidos os dispositivos lógicos programáveis bem como a linguagem de descrição de hardware VHDL (do inglês VHSIC Hardware Description Language - (VHSIC) Very-High-Speed Integrated Circuit).

No capítulo 6 é apresentada a metodologia utilizada e os resultados obtidos. E, para finalizar, no capítulo 7 são apresentadas as conclusões e os futuros trabalhos na área.

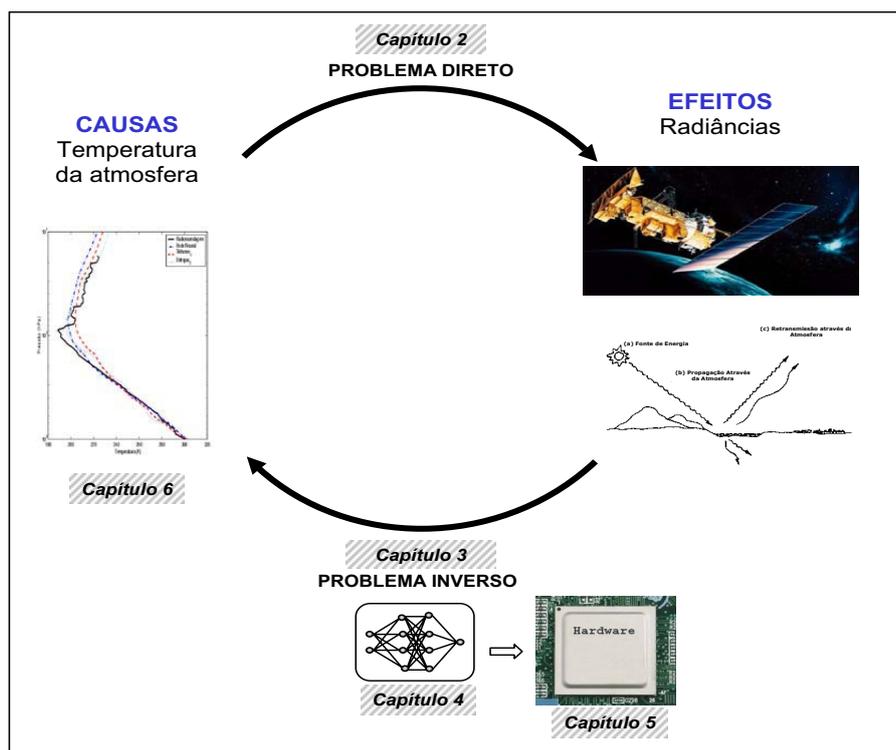


Figura 1.1 - Processo de inversão utilizando RNAs

## CAPÍTULO 2

### TRANSFERÊNCIA RADIATIVA NA ATMOSFERA

O processo mais importante responsável pela transferência de energia na atmosfera é a radiação eletromagnética. Todas as informações sobre a Terra e sua atmosfera, obtidas por satélites artificiais, vêm em forma de radiação eletromagnética emitida, refletida e espalhada pela atmosfera e superfície. Os sensores a bordo de satélites medem radiâncias e irradiâncias em determinadas bandas espectrais. A sondagem remota da atmosfera permite, a partir de um conjunto de radiâncias espectrais, determinar a estrutura vertical de temperatura, umidade e concentração de constituintes atmosféricos. A interpretação destas medidas de radiância, em termos de parâmetros meteorológicos, requer a solução inversa da Equação da Transferência Radiativa (ETR). Esta solução é altamente indeterminada para um dado conjunto de radiâncias observadas, sendo o grau de indeterminação associado à resolução espectral e ao número de canais espectrais (CARVALHO, 1998; FERREIRA, 2004). Além disso, geralmente a solução apresenta-se bastante instável com relação a ruídos que são inerentes aos instrumentos de medidas. Em razão das grandes dificuldades em se obter expressivas soluções da ETR, ou suas versões lineares, que constituem uma equação integral de Fredholm de primeira espécie (TWOMEY, 1977), podem ser encontrados na literatura inúmeros métodos de inversão, uma linha de pesquisa atualmente bastante importante.

O perfil vertical de temperatura para a atmosfera padrão é descrita na Figura 2.1. O perfil representa condições típicas em média latitudes. De acordo com nomenclatura padrão definida pela União Internacional Geodésica e Geofísica (IUGG) em 1960, o perfil é dividido em quatro camadas distintas: a troposfera, estratosfera, mesosfera e termosfera. Os topos dessas camadas são respectivamente chamados de tropopausa, estratopausa, mesopausa e termopausa.

A troposfera é caracterizada por uma diminuição de temperatura com relação à altura com uma taxa de  $6.5^\circ \text{C/km}$ . A estrutura da temperatura nessa camada é uma consequência do balanço radiativo e a convecção do transporte de energia da superfície para a atmosfera. Particularmente, todo o vapor d'água, nuvem e precipitação estão confinados nesta região. A estratosfera é caracterizada por uma camada isotérmica da tropopausa até aproximadamente 20 km de onde a temperatura aumenta para a estratopausa. O ozônio ocorre principalmente na

estratosfera, além de finas camadas de aerossóis serem observadas por persistirem por um longo período do tempo dentro de certos intervalos de altitude da estratosfera. Semelhantemente à troposfera, as temperaturas na mesosfera caem com a altura entre 50 e 85 km. Acima de 85 km e subindo a uma altitude de centenas de quilômetros o intervalo da temperatura fica entre 500°K e 2000°K.

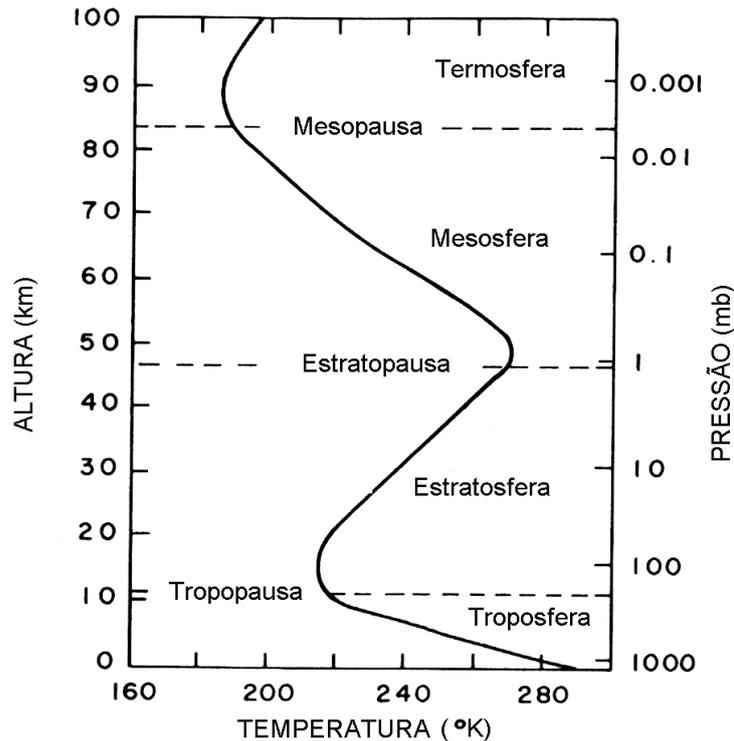


Figura 2.1 - Perfil de temperatura vertical. Adaptado de (FERREIRA, 2004)

## 2.1 Radiação Eletromagnética

A radiação eletromagnética consiste na alternância de campos elétricos e magnéticos. O vetor campo elétrico é perpendicular ao vetor magnético e a direção de propagação é proporcional a ambas. As ondas eletromagnéticas que interagem com um ambiente levam uma assinatura que pode ser usada para verificar a composição e a estrutura do ambiente. Em sensoriamento remoto, observações específicas são feitas dentro de um meio. O princípio associado ao sensoriamento remoto envolve interpretação de medidas radiométricas da radiação eletromagnética, caracterizada por um intervalo espectral específico, que é sensível a algum aspecto físico do ambiente. Basicamente, um sinal eletromagnético é gravado por um detector depois de interagir com um

alvo contendo moléculas e/ou partículas. Se  $T$  e  $S$  representam o alvo e o sinal, respectivamente, então pode-se escrever simbolicamente (LIOU, 1982):

$$S = F(T) \tag{2.1}$$

onde  $F$  representa uma função não necessariamente linear. A inversa da relação é obtida por:

$$T = F^{-1}(S) \tag{2.2}$$

A transferência radiativa transporta energia e momento, não necessitando de um meio material para se propagar e cuja velocidade de propagação no vácuo é uma constante universal ( $3,0 \times 10^8 m/s$ ). Devido a sua natureza ondulatória, a radiação é caracterizada por uma amplitude e por ter uma freqüência característica cuja composição dos diferentes comprimentos de onda formam o espectro eletromagnético. O espectro da radiação eletromagnética engloba raios gama, raios x, ultravioleta, visível, infra-vermelho, microonda e ondas de rádio.

Para proceder uma formulação geral para um feixe de radiação atravessando determinado meio, deve-se levar em conta dois processos: o de emissão e o de espalhamento.

O espalhamento é um processo físico associado com a radiação e sua interação com a matéria, que ocorre em todos os comprimentos de ondas cobrindo o espectro eletromagnético. No espalhamento, uma partícula no caminho de uma onda continuamente abstrai energia da curva incidente e redireciona a energia em todas as direções. O espalhamento pode ser acompanhado da absorção. A absorção de energia por partículas e moléculas leva à emissão, que pode ser associada com a radiação do corpo negro.

Planck em 1901 fez duas suposições sobre osciladores atômicos. Primeiro: postulou que somente pode conter níveis de energia dados por (LIOU, 1982):

$$E = nh\tilde{\nu} \tag{2.3}$$

onde  $\tilde{\nu}$  é a frequência do oscilador,  $h$  é a constante de Planck e  $n$  é um número quântico. A equação (2.3) assegura que o oscilador de energia é quântico. A segunda suposição de Planck é que os osciladores não radiam energia continuamente, mas sim em saltos ou em quanta. Estes quanta de energia são emitidos quando um oscilador muda de um para outro ou sua energia quantizada manifesta. Então, se o número quantum muda por uma unidade, a quantidade de energia radiada é dada por:

$$\Delta E = \Delta n h \tilde{\nu} = h \tilde{\nu} \quad (2.4)$$

Com base nestas duas suposições, Planck foi capaz de derivar do ponto de vista teórico, a função de Planck que é expressa por:

$$B_{\tilde{\nu}}(T) = \frac{2h\tilde{\nu}^3}{c^2 \left( e^{\frac{h\tilde{\nu}}{k_B T}} - 1 \right)} \quad (2.5)$$

onde  $k_B$  é constante de Boltzmann,  $c$  é a velocidade da luz e  $T$  é a temperatura absoluta. As constantes de Planck e de Boltzmann são determinadas experimentalmente e são dadas, respectivamente, por  $h = 6.6262 \times 10^{-27}$  erg sec e  $k_B = 1.3806 \times 10^{-16}$  erg deg<sup>-1</sup>.

A função de Planck relaciona a intensidade monocromática emitida com a frequência e a temperatura da entidade emissora. Utilizando a relação entre a frequência e o comprimento de onda, a equação (2.5) pode ser escrita como (LIOU, 1982):

$$B_{\lambda}(T) = \frac{2hc^2}{\lambda^5 \left( e^{\frac{hc}{k_B \lambda T}} - 1 \right)}. \quad (2.6)$$

As interações entre a radiação e matéria, que podem ser divididas em processos de emissão e espalhamento, são expressas pela equação da transferência radiativa:

$$dI_{\lambda}(t, P, s) = -(k_{\lambda} + \sigma_{\lambda})I_{\lambda}\rho ds + j_{\lambda}\rho ds. \quad (2.7)$$

onde  $I_{\lambda}$  é a intensidade de radiação monocromática ou radiância monocromática, que é função do comprimento de onda  $\lambda$ , do tempo  $t$ , das coordenadas de posição  $P$

e da direção  $s$  do raio incidente.  $\rho$  é a densidade e  $k_\lambda$  a absorção,  $\sigma_\lambda$  o espalhamento e  $j_\lambda$  a função fonte.

O primeiro termo do lado direito contribui para a diminuição da intensidade de radiação, extinção, que se dá através da absorção de radiação. Esta absorção é a transformação da energia incidente em outras formas de energia mais o efeito de atenuação devido a espalhamentos que é o desvio do feixe de radiação incidente ou de parte em outras direções. O segundo termo age como uma fonte de radiação, que se deve a dois fatores distintos: a contribuição da radiação provida pelo espalhamento múltiplo na direção e comprimento de onda considerado, e o outro é efeito de emissão, que é característico do material (LIU, 1982).

A Equação 2.7 é uma formulação geral da ETR, porém quando é aplicado à atmosfera, normalmente se faz uso de algumas considerações que simplificam o seu tratamento matemático. Um caso particular desta equação é a equação de Schwarzschild, que considera um meio sem espalhamento e em equilíbrio termodinâmico local comportando-se como um corpo negro. A função fonte neste caso pode ser expressa pela relação:

$$j_\lambda = k_\lambda B_\lambda(T) \quad (2.8)$$

onde  $B_\lambda(T)$  é a função de Planck. Logo a equação 2.7 pode ser escrita como:

$$dI_\lambda(t, P, s) = (-I_\lambda + B_\lambda)k_\lambda \rho ds. \quad (2.9)$$

## 2.2 A Equação Integral da Transferência Radiativa (EITR)

A Equação 2.9 é uma simplificação da equação da transferência radiativa para uma atmosfera sem espalhamento e emitindo de acordo com a lei de Planck. Introduzindo a representação de atmosfera plano-paralela (ver Figura 2.2), onde se deseja determinar a radiação normal ao plano de estratificação da atmosfera, a Equação 2.9 pode ser reescrita no domínio do número de onda  $\nu$  como:

$$\cos \theta \frac{dI_\nu(z, \theta, \phi)}{k_\nu \rho dz} = -I_\nu(z, \theta, \phi) + B_\nu(T) \quad (2.10)$$

onde  $z$  é a medida de distância na direção normal ao plano de estratificação,  $\theta$  é o ângulo zenital e  $\phi$  descreve o ângulo azimutal.

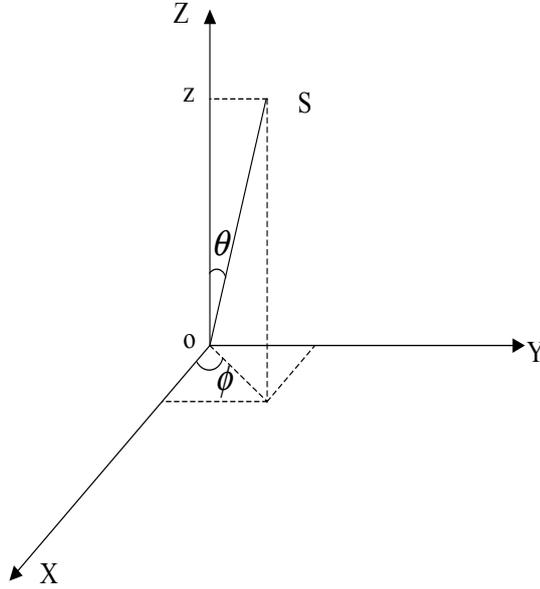


Figura 2.2 - Esquema geométrico para atmosfera plano-paralela

Supondo que a radiação atmosférica não seja função do ângulo azimutal  $\phi$ , reescreve-se a equação (2.10)

$$\mu \frac{dI_\nu(\tau, \mu)}{d\tau} = I_\nu(z, \mu) - B_\nu(T) \quad (2.11)$$

onde  $\mu = \cos\theta$ , ( $\mu > 0$  para radiações saindo da atmosfera em direção ao espaço) e  $\tau$  a profundidade óptica normal ao plano de estratificação:

$$\tau = \int_z^\infty k\rho dz' \quad (2.12)$$

definida em um intervalo que varia entre a altura  $z$  e o topo da atmosfera ( $z = \infty$ ).

Para uma atmosfera finita, limitada por  $\tau = 0$  no topo e  $\tau = \tau_1$  na superfície, a radiação que deixa a atmosfera perpendicularmente ao plano de estratificação pode ser obtida para determinado nível  $z$ , multiplicando-se a Equação (2.11) por  $e^{-\tau/\mu}$  e integrando o intervalo de  $\tau$  a  $\tau_1$ , obtendo-se a expressão:

$$I_\nu(\tau, \mu) = I_\nu(\tau_1, \mu)e^{-(\tau_1-\tau)} + \int_\tau^{\tau_1} B_\nu[T(\tau')]e^{-(\tau'-\tau)/\mu} \frac{d\tau'}{\mu}. \quad (2.13)$$

Considerando que o satélite esteja posicionado próximo ao ângulo zenital do ponto medido, pode-se fazer a aproximação  $\mu = \cos \theta \approx 1$ , obtendo-se:

$$I_\nu(\tau) = I_\nu(\tau_1)e^{-(\tau_1-\tau)} - \int_\tau^{\tau_1} B_\nu[T(\tau')]d[e^{-(\tau'-\tau)}]. \quad (2.14)$$

Para radiâncias próximas ao topo da atmosfera, tem-se que para  $z \rightarrow \infty$ ,  $\tau = 0$  e para  $z = 0$  tem-se  $\tau = \tau + 1$ . Assim a equação integral da transferência radiativa pode ser escrita como:

$$I_\nu|_{z \rightarrow \infty} = I_\nu|_{z=0}\mathfrak{S}|_{z=0} + \int_{z=0}^h B_\nu[T(z)]\frac{\partial \mathfrak{S}(z)}{\partial z} dz \quad (2.15)$$

onde  $\mathfrak{S}(z) = e^{-\tau}$  é a transmitância monocromática e  $h$  o topo da atmosfera.

Portanto, a radiação que chega ao topo da atmosfera e sensibiliza os sensores a bordo do satélite, sem espalhamento, pode ser aproximada por:

$$I(\nu_i) = B[\nu_i, T(p_s)]\mathfrak{S}(\nu, p_s) + \int_{p_s}^{p_0} B[\nu_i, T(p)]\frac{\partial \mathfrak{S}(\nu_i, p)}{\partial p} dp \quad (2.16)$$

que está escrita em coordenadas de pressão, onde  $p$  é a pressão atmosférica;  $p_0$  a pressão no topo da atmosfera;  $p_s$  a pressão na superfície;  $T$  a temperatura;  $\mathfrak{S}$  transmitância e  $\nu_i$  o número de onda médio associado ao intervalo espectral  $\Delta\nu_i$  onde  $i = 1, 2, \dots, N$ . O termo  $B[\nu_i, T(p)]\mathfrak{S}(\nu_i, p)$  está relacionado às condições de contorno desta equação, representando a contribuição da radiação provida da superfície terrestre, cuja intensidade é dada pela função de Planck; o termo dentro da integral representa a contribuição atmosférica para a radiância medida pelo sensor para cada nível diferencial de pressão  $dp$  onde:  $\partial \mathfrak{S}(\nu_i, p)/\partial p$  é conhecido como função peso ou núcleo da integral (LIU, 1982),(CARVALHO, 1998).

A transmitância monocromática de um meio é dada como a razão entre a intensidade de radiação que é transmitida através de um meio com espessura  $\Delta t$  pela intensidade

da radiação incidente, em um determinado comprimento de onda. Desta forma a transmitância monocromática pode ser obtida através da relação:

$$\mathfrak{T}_\nu(\tau) = e^{-\tau} \quad (2.17)$$

onde

$$\tau_\nu(s) = \int_{s_1}^{s_2} k_\nu \rho ds' \quad (2.18)$$

que representa a profundidade ótica entre os pontos  $s_1$  e  $s_2$ , sendo  $k_\nu$  o coeficiente de absorção e  $\rho$  a densidade.

Utilizando-se a teoria da atmosfera plano-paralela, a transmitância monocromática pode ser escrita como:

$$\mathfrak{T}_\nu(z) = \exp \left[ - \int_z^\infty k_\nu(z') \rho(z') dz' \right], \quad (2.19)$$

onde  $z$  corresponde ao nível de altura e o topo da atmosfera está localizado no infinito. Da Equação (2.19) observa-se que a transmitância é uma função do número de onda e da concentração do gás absorvente e geralmente sofre um decaimento exponencial com a altura. A Figura (2.3) apresenta o comportamento das curvas de transmitância padrão para o CO<sub>2</sub> na atmosfera.

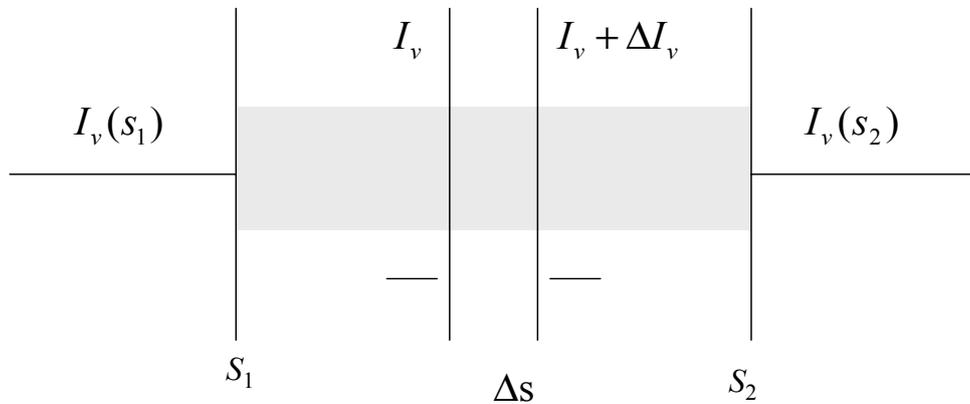


Figura 2.3 - Esquema de um feixe de radiação atravessando um meio absorvente.

Ao se trabalhar com parâmetros atmosféricos, as equações são expressas em coordenadas verticais de pressão, ao invés dos sistemas de coordenadas usuais. Assim, utilizando-se a equação hidrostática:

$$\rho dz = - \left( \frac{Q}{g} \right) dp, \quad (2.20)$$

pode-se escrever a Equação 2.19 da seguinte forma:

$$\mathfrak{S}_\nu(z) = \exp \left[ -\frac{1}{g} \int_{p_0}^p k_\nu(p) Q(p) dp \right] \quad (2.21)$$

onde  $Q$  é a razão de mistura do gás em consideração,  $g$  a aceleração da gravidade local e  $p_0$  a pressão no topo da atmosfera (LIOU, 1982), (CARVALHO, 1998).

### 2.3 Funções Peso

Em problemas relacionados com transferência radiativa atmosférica, a transmitância aparece expressa em termos de uma função, conhecida na literatura por *função peso*. Esta é definida como a taxa de variação da transmitância com relação à pressão  $\frac{\partial \mathfrak{S}(v_j, p)}{\partial p}$ , que quando multiplicada pela Equação de Planck resulta numa medida da contribuição de cada camada atmosférica  $\delta p$  para a radiação que chega ao topo da atmosfera. Na função peso está contida a informação necessária para se proceder a inferência dos perfis verticais de temperatura e umidade através da inversão da Equação Integral de Transferência Radiativa, logo sua exatidão na determinação da transmitância é de fundamental importância, pois pequenos erros podem ser amplificados pelo processo de derivação, resultando em grandes diferenças nos valores a serem estimados.

A utilização das bandas de absorção de CO<sub>2</sub> para inferência de perfis verticais de temperatura está associado ao fato deste gás possuir uma razão de mistura uniforme na atmosfera. Desta forma, é possível se conhecer o comportamento das funções pesos para este constituinte em determinada frequência. Como a função peso entra como um dado fornecido ao problema, a contribuição para a radiação em cada camada passa a ser uma função única da temperatura, que é uma variável contida na função de Planck.

A equação da transferência radiativa também é usada para estimar perfis verticais de umidade da atmosfera a partir de bandas de absorção do vapor d'água. Neste caso, supõe-se que o perfil vertical de temperatura seja conhecido. A qualidade da recuperação dos perfis verticais de umidade diminui consideravelmente devido à razão de mistura do vapor d'água,  $Q(p)$ , definido em (2.21) como expoente da transmitância. Além disso, existem os erros associados ao perfil de temperatura e à influência de outros gases na faixa de absorção medida pelo sensor (LIU, 1982).

## 2.4 Satélites e Sondagem Remota

A rede de satélites ambientais que cobre a maior parte do globo terrestre são divididos em duas classes: os satélites de órbitas polares e os de órbitas geoestacionárias. Os satélites polares ou heliossíncronos orbitam a uma distância aproximada de 850 Km da Terra e a cada volta novas áreas do globo vão sendo monitoradas. O primeiro satélite lançado com sucesso foi o Sputnik, da União Soviética, em 4 de Outubro de 1957. Em 31 de Janeiro de 1958, foi lançado o primeiro satélite dos Estados Unidos, o Explorer 1. Desde então, com a evolução tecnológica, os satélites artificiais se tornaram indispensáveis para o estudo da atmosfera terrestre, suas massas aumentaram de 100 kg para cerca de 2000 kg, as câmeras de TV foram substituídas por radiômetros de varredura multiespectrais, os dados que eram tratados manualmente foram substituídos por processamentos computacionais sofisticados, houve mudança de dados analógicos para digitais, capacidade de realizar sondagens da atmosfera, continentes e oceanos, além de retransmissão de dados registrados com plataformas remotas (FERREIRA, 2004).

O primeiro satélite totalmente dedicado para a meteorologia foi lançado em 1 de Abril de 1960. O TIROS 1 (Television and Infrared Observational Satellite) foi o 22º satélite lançado com sucesso, com uma série de nove satélites, o último da série TIROS foi lançado em 2 de Julho de 1965.

O primeiro satélite geoestacionário verdadeiramente operacional foi o Geostationary Operational Environmental Satellite 1 (GOES 1), lançado no dia 16 de Outubro de 1975. Desde o lançamento do SMS 2 (Synchronous Meteorological Satellite), da primeira geração de satélites semi-operacionais lançado em 6 de Fevereiro de 1975, os Estados Unidos têm mantido dois satélites geoestacionários em órbita, um em 75 graus de longitude oeste e outro a 135 graus de longitude oeste.

O primeiro satélite dedicado à pesquisa foi lançado no dia 5 de Outubro de 1994 do Space Shuttle Challenger chamado Earth Radiation Budget Satellite (ERBS). A história de satélites meteorológicos tem muitas particularidades e um histórico completo pode ser obtido em (KIDDER; HAAR, 1995).

O primeiro satélite brasileiro foi lançado com sucesso em 09 de Fevereiro de 1993, o Satélite de Coleta de Dados 1 (SCD1), com a missão de coleta de dados ambientais. Em sua órbita a 760km de altitude, recebe e retransmite dados captados no solo por estações automáticas, as plataformas coletoras de dados. O segundo satélite SCD2 foi lançado em 22 de outubro de 1998, sendo bastante similar ao SCD1. Através de cooperação com a China, o programa Satélite Sino-Brasileiro de Recursos Naturais CBERS (do inglês “China-Brasil Earth Resource Satellite”), o satélite CBERS1 foi lançado em 14 de Outubro de 1999 e o CBERS2 no dia 21 de Outubro de 2003, para sensoriamento remoto de recursos naturais (FONSECA, 2006).

A aquisição de um maior conhecimento das características atmosféricas aliado à evolução tecnológica dos satélites artificiais levaram ao aparecimento de diversas técnicas para determinação de perfis verticais de temperatura, umidade e demais parâmetros atmosféricos. Neste sentido, foram projetados sistemas de medidas, basicamente constituídos por sensores de radiação e pacotes numéricos utilizados no processamento destas informações.

#### **2.4.1 Instrumentos de Sondagem**

Os satélites da série TIROS-N/NOAA são responsáveis pelo principal sistema de obtenção de dados utilizados na determinação dos perfis de temperatura e umidade. A série TIROS-N/NOAA, é composta de dois satélites operando simultaneamente com frequência de aproximadamente 14 órbitas por dia, cobrindo a superfície do globo a cada 12 horas (CARVALHO, 1998). A Figura 2.4 apresenta a configuração atual dos satélites NOAA. Os principais instrumentos de sondagem a bordo dos satélites NOAA são: AVHRR, HIRS, AMSU-A e AMSU-B (FERREIRA, 2004). Os outros instrumentos apresentados na Figura 2.4 são: BDA (“Beacon Transmitting Antenna”), ESA (“Earth Sensor Assembly”), IMP (“Instrument Mounting Platform”), IMU (“Inertial Measurement Unit”), REA (“Reaction Engine Assembly”), SBUV/2 (“Solar Backscatter Ultraviolet Radiometer”), SEM (“Space Environment Monitor”), SLA (“Search and Rescue Transmitting Antenna”), SOA (“S-Band Omni Antenna”), SRA (“Search-and-Rescue Receiving Antenna”), STX (“S-Band Transmitting An-

tenna”), UDA (“Ultra High Frequency Data Collection System Antenna”), VRA (“Very High Frequency Real-time Antenna”) e SAD (“Solar Array Drive”).

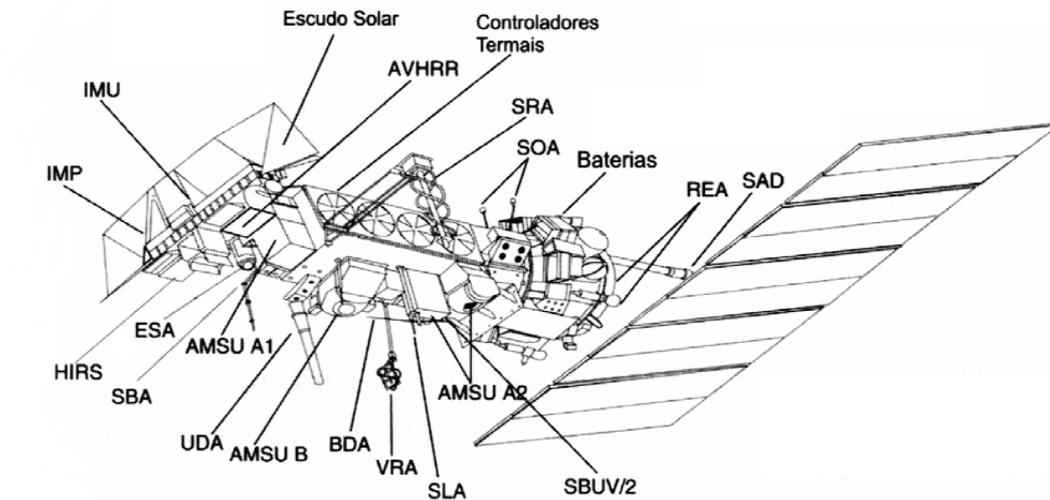


Figura 2.4 - Instrumentos a bordo dos satélites NOAA.

O sensor AVHRR (Radiômetro Avançado de Resolução muito Alta) é um radiômetro imageador de varredura, que detecta a energia nas faixas do visível e infravermelho do espectro eletromagnético, provendo meios para o monitoramento da vegetação, cobertura de nuvens, lagos, litorais, neve, aerossóis e gelo. Possui seis canais espectrais que observam simultaneamente a mesma área da superfície da Terra. Os dados podem ser registrados em alta resolução (1,1 km) ou em resolução de 4 km (FERREIRA, 2004).

O HIRS é um instrumento utilizado principalmente para obtenção de perfis verticais de temperatura, vapor d’água e concentração de ozônio na atmosfera. Possui uma resolução de 42 km cobrindo uma faixa de aproximadamente 1115 km. O HIRS utiliza duas bandas do CO<sub>2</sub> para sondagens de temperatura, sendo sete canais na banda de 15 $\mu$ m e seis canais localizados na banda 4,3  $\mu$ m. Os canais destinados a estimativas de umidade estão localizados na banda de 6.3 $\mu$ m do vapor d’água. O canal de 9.7  $\mu$ m é utilizado para estimativa da quantidade de ozônio. Existindo ainda três canais, dois associados às janelas atmosféricas centrados em 11 $\mu$ m e 3.76  $\mu$ m, destinados à estimativa da temperatura de superfície e um outro canal centrado em 0.69  $\mu$ m (na região do visível), utilizado para detecção de nuvens (CARVALHO, 1998; FERREIRA, 2004).

As unidades de perfilagem por microondas, denominadas AMSU-A1, AMSU-A2, AMSU-B realçam a capacidade do conjunto de produtos de perfilagem e não perfilagem dos satélites da série NOAA. O AMSU melhora a capacidade de perfilagem em escala global, a obtenção de perfis de vapor d'água e de informação sobre precipitação e gelo. Os instrumentos AMSU possuem uma resolução espacial maior e uma capacidade superior de instrumentos MSU de sondagem de microondas (FERREIRA, 2004). A unidade AMSU-A mede a radiância da cena no espectro de microondas. Os dados dos instrumentos são usados em conjunto com os do HIRS para cálculo dos perfis globais de temperatura e umidade da atmosfera. O AMSU-A é fisicamente dividido em dois módulos, cada um operando independentemente. O módulo A-1 composto por treze canais, e o A-2, com dois. A unidade AMSU-B é um radiômetro de varredura transversal contínua e fornece medidas de radiância de cena em cinco canais espectrais projetada para permitir o cálculo de perfis verticais de vapor d'água desde a superfície da Terra até uma altitude de 200 milibares de pressão atmosférica.

Com todos os sensores operando, têm-se continuamente grandes quantidades de dados que são recebidas pelas plataformas de coleta. Estes dados devem ser processados por pacotes computacionais para que as informações sejam extraídas e utilizadas nos modelos numéricos de previsão de tempo ou em outras aplicações afins. O principal pacote computacional que processa os dados do sistema TOVS é o ITPP 5.0. Este pacote consiste num modelo para obtenção de perfis verticais de temperatura e umidade da atmosfera a partir de radiâncias observadas pelos sensores a bordo dos satélites NOAA. Além disso, é utilizado também para obtenção da concentração de ozônio e outros parâmetros atmosféricos de interesse da meteorologia. Além do ITPP, outros pacotes de inversão da ETR têm sido aplicados (MACEDO; CEBALLOS, 2004), (CARVALHO, 1998), como por exemplo 3I (do inglês "Improved Initialization Package"), proposto por (CHEDIN *et al.*, 1985) e ICI (do inglês "Inversion Coupled with Imager") (LAVANT *et al.*, 1995).



## CAPÍTULO 3

### PROBLEMAS INVERSOS

As pesquisas na área de Problemas Inversos (PI) têm crescido nos últimos anos, principalmente em aplicações nos campos da indústria e ciência (DULIKRAVICH *et al.*, 1999). A principal dificuldade no tratamento de PI é a instabilidade de suas soluções com a presença de ruído nos dados medidos ou observados, que é a natureza de problemas mal-postos. Esta dificuldade tem feito com que muitas técnicas de soluções de problemas inversos tenham sido desenvolvidas (BERTERO; BOCCACCI, 1998).

Os problemas inversos podem ser classificados em três tipos, todos eles baseados em observações na evolução do sistema físico envolvido, identificação de parâmetros, determinação do estado inicial do sistema e determinação de condições de contorno (ENGL *et al.*, 1996), (MUNIZ *et al.*, 1999).

Segundo Alifanov (1974), importante referência na área de PI, a solução de um problema inverso determina as causas desconhecidas do problema, baseando-se nos efeitos desejados ou observados. Existem duas diferentes motivações para o estudo de problemas inversos: quando se deseja conhecer estados passados ou parâmetros de um sistema físico e quando se deseja saber como influenciar um sistema através de seu estado presente ou através dos parâmetros, com o objetivo de se obter um estado desejado no futuro.

Na solução de um problema direto determina-se o efeito  $y$  de uma dada causa  $x$ , quando um modelo matemático definido  $K$  é colocado:

$$Kx = y \tag{3.1}$$

Para os problemas diretos assume-se que o operador  $K$  esteja bem definido e seja contínuo, assim há um único efeito  $y$  para cada causa  $x$  e pequenas variações em  $x$  resultam em pequenas variações em  $y$ .

A partir do problema direto, apresentado pela Equação (3.1), podem ser colocados dois tipos de problemas inversos. O problema inverso de causa (dados  $K$  e  $y$ ,

determinar  $x$ ) e o de identificação do modelo (dados  $x$  e  $y$ , determinar  $K$ ). A Figura 3.1 mostra a relação entre os problemas direto e inverso.

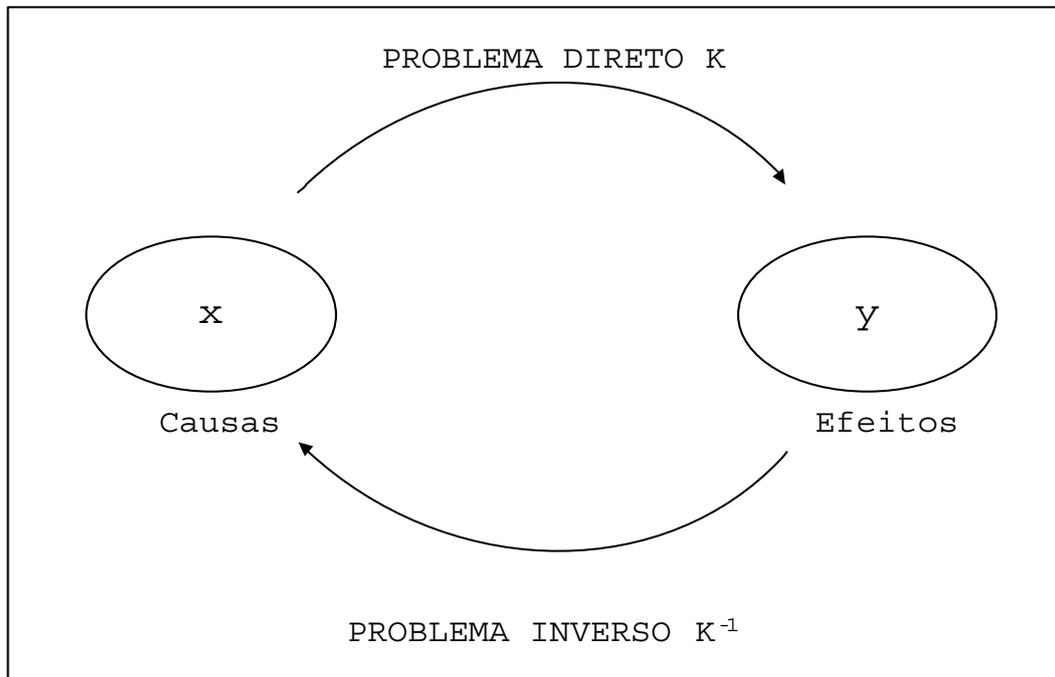


Figura 3.1 - Problema inverso versus problema direto.

### 3.1 Problema Mal-posto

O conceito de problema bem-posto foi proposto pelo matemático francês Hadamard em 1902, num problema de valor de contorno para equações diferenciais parciais e sua interpretação física (BERTERO; BOCCACCI, 1998). Segundo a definição, um problema é considerado bem-posto se satisfaz três propriedades:

- existência,
- unicidade e
- estabilidade.

É considerado mal-posto, se uma destas propriedades não é satisfeita.

Um modelo físico abstrato pode ser descrito por um mapeamento  $K$  de um conjunto  $X$  de parâmetros teóricos num conjunto  $Y$  de resultados:

$$K : X \rightarrow Y \quad (3.2)$$

$$x \rightarrow K(x) = Kx = y \quad (3.3)$$

Segundo Hadamard (1902), um problema é considerado bem-posto se satisfaz a definição:

*Sejam  $X$  e  $Y$  espaços normados,  $K : X \rightarrow Y$  um operador (linear ou não linear). A equação (ou problema)  $Kx = y$  é dita bem-posta se*

- a) *Para qualquer  $y \in Y$  existe (pelo menos um)  $x \in X$  tal que  $Kx = y$ . (Propriedade de Existência).*
- b) *Para qualquer  $y \in Y$  existe no máximo um  $x \in X$  tal que  $Kx = y$ , isto é, se  $Kx_1 = Kx_2, x_j \in X$ , então  $x_1 = x_2$ . (Propriedade de Unicidade)*
- c) *A solução  $x$  depende continuamente de  $y$ , isto é, para qualquer seqüência  $\{x_n\} \subset X$  tal que  $Kx_n \rightarrow Kx(n \rightarrow \infty)$ , então  $x_n \rightarrow x(n \rightarrow \infty)$ . (Dependência contínua dos dados).*

As técnicas de inversão podem ser divididas em duas categorias: explícita e implícita. Na explícita, métodos de inversão são obtidos através de um esquema de inversão explícito, envolvendo um operador que representa o problema direto. O implícito representa um caráter que explora exaustivamente o espaço do modelo (espaço de solução) até que o critério de parada seja satisfeito, considerando-se os dados disponíveis. Existem vários métodos para solução de problemas inversos, como por exemplo: inversão direta, decomposição em valores singulares, mínimos quadrados (e variantes), métodos de regularização, métodos variacionais, entre outros (TARANTOLA, 1987), (TIKHONOV; ARSEININ, 1977), (BERTERO; BOCCACCI, 1998).

### 3.2 Métodos de Solução de Problemas Inversos

O processo de inversão na determinação de perfis de temperatura e umidade da atmosfera caracteriza-se por ser um problema mal-posto. Vários problemas inversos estão relacionados à transferência radiativa em situações envolvendo sensoriamento remoto e meteorologia (CARVALHO, 1998).

Nas próximas seções alguns métodos de solução de problemas inversos são discutidos.

### 3.2.1 Inversão Direta

Métodos explícitos ou inversão direta não são métodos gerais. Normalmente, existe mais um interesse acadêmico do que um esquema metodológico geral a ser seguido. Como exemplo, pode ser citado o problema inverso de condução de calor, onde se busca a estimação da condição inicial, cuja solução exata do problema direto é dada pela equação:

$$T(x, t) = \sum_{m=0}^{+\infty} e^{-\beta_m^2 t} \frac{1}{N(\beta_m)} X(\beta_m, x) \int_0^1 X(\beta_m, x') f(x') dx' \quad (3.4)$$

onde  $X(\beta_m, x)$  são as autofunções associadas ao problema de autovalores obtido pelo método de separação de variáveis,  $\beta_m$  são os autovalores e  $N(\beta_m)$  é a norma ou a integral de normalização (ÖZISIK; ORLANDE, 2000), (MUNIZ *et al.*, 1999).

A solução exata do problema inverso para um perfil de temperatura  $T(x)$  medida num tempo  $t = \tau$  é (MUNIZ *et al.*, 1999):

$$f(x) = \sum_{m=0}^{+\infty} e^{\beta_m^2 \tau} \frac{1}{N(\beta_m)} X(\beta_m, x) \int_0^1 X(\beta_m, x') T(x', \tau) dx' \quad (3.5)$$

### 3.2.2 Mínimos Quadrados

Os mínimos quadrados são muito utilizados na solução de problemas inversos devido à facilidade de implementação. No entanto, sua utilização não garante robustez na inversão pois, por exemplo, são sensíveis a uma pequena quantidade de ruído.

Para encontrar o vetor de parâmetros  $x$ , o funcional é minimizado em relação a  $x$ :

$$\tilde{M} = \min_m \|Kx - y\|_2^2 \leftrightarrow \tilde{M} = (K^T K)^{-1} K^T y \quad (3.6)$$

onde  $Kx$  denota a solução do problema direto e  $y$  representa os dados. Nesta minimização é necessário que seja calculado o problema direto.

### 3.2.3 Métodos de Regularização

Na presença de dados observacionais contaminados com ruído, o método dos mínimos quadrados não fornece uma solução adequada ao problema inverso.

O uso de regularização consiste em obter soluções aproximadas de  $Kx = y$  para problemas mal-postos, tal que sejam estáveis para pequenas variações no valor da variável observada  $y$ . Tikhonov em 1943 observou que informações *a priori* poderiam restaurar alguma estabilidade ao problema inverso mal-posto (TIKHONOV; ARSENIN, 1977).

O método da regularização consiste na determinação da solução aproximada mais suave compatível com os dados de observação, para certo nível de ruído. A busca da solução mais suave (regular) é uma informação adicional, que transforma o problema mal-posto num problema bem-posto. A Figura 3.2 ilustra este procedimento.

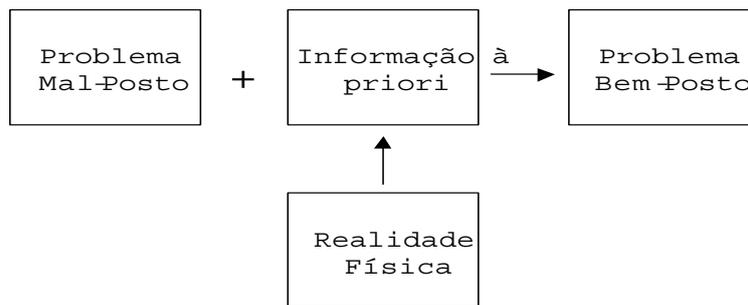


Figura 3.2 - Método de Regularização

A regularização pode ser vista como um procedimento que muda a abordagem por mínimos quadrados (minimização de resíduo) através da adição de termos que pretendem reduzir flutuações na função ou vetor desconhecido  $x$ ; flutuações que são inerentes a problemas mal-postos. Assim, passa-se de uma abordagem natural via mínimos quadrados para uma abordagem com regularização.

$$\min_{x \in X} \|Kx - y\|_2^2 \implies \min_{x \in X} (\|Kx - y\|_2^2 + \alpha \Omega[x]) \quad (3.7)$$

onde  $\Omega[x]$  denota o operador de regularização e  $\alpha$  é o parâmetro de regularização. A seguir são descritos alguns destes operadores.

### 3.2.3.1 Regularização de Tikhonov

Uma técnica de regularização proposta por [Tikhonov e Arsenin \(1977\)](#) pode ser expressa por:

$$\Omega[f] = \sum_{k=0}^N \alpha_k \|x^{(j)}\|_2^2 \quad (3.8)$$

onde  $x^{(j)}$  denota a  $j$ -ésima derivada em relação a  $x$ , sendo  $x = x(t)$  e o parâmetro  $\alpha \geq 0$ .

Se  $\alpha_k = \delta_{kj}$ , delta de Kronecker ([MUNIZ \*et al.\*, 2000](#)), isto é,

$$\Omega[f] = \|x^{(j)}\|_2^2 \quad (3.9)$$

então, o método é chamado regularização de Tikhonov de ordem  $j$  (Tikhonov- $j$ ). Se  $\alpha_k \rightarrow 0$ , o termo dos mínimos quadrados é sobreestimado, que pode não apresentar bons resultados com a presença de ruído. Por outro lado, se  $\alpha_k \rightarrow \infty$ , toda consistência com a informação sobre o sistema é perdida.

### 3.2.3.2 Regularização pelo Princípio da Máxima Entropia

Similarmente à regularização de Tikhonov, o formalismo de máxima entropia busca por regularidade global e gera reconstruções suaves, que são consistentes com os dados avaliáveis ([MUNIZ \*et al.\*, 1999](#)).

O princípio da máxima entropia foi primeiramente proposto para um processo de inferência global por Jaynes em 1957, com base na caracterização axiomática da quantidade de informação de Shannon em 1949 ([MUNIZ \*et al.\*, 1999](#)) ([MUNIZ \*et al.\*, 2000](#)).

Considerando-se o vetor de parâmetros  $\mathbf{f}$  com componentes não negativos, a função de entropia de  $\mathbf{f}$  é definida pelas equações:

$$S(\mathbf{f}) = - \sum_{q=1}^N s_q \log s_q ; \quad \text{com } \mathbf{f} = [f_1 \ f_2 \ \dots \ f_N]^T, \quad s_q = \frac{f_q}{\sum_q f_q} \quad (3.10)$$

onde  $f_q = f(x_q)$ . A função entropia (não negativa)  $S$  atinge seu máximo global quando todos os  $s_q$  são os mesmos, o que corresponde a uma distribuição uniforme com valores de  $S_{\max} = \ln N$ , enquanto o nível de entropia mais baixo,  $S_{\min} = 0$ , é ativado quando todos os elementos  $s_q$  são fixados em zero, exceto num único ponto. É também possível definir funções de entropia de alta ordem, como proposto em (RAMOS; Campos Velho, 1996), (RAMOS *et al.*, 1999).

### 3.3 Determinação do Parâmetro de Regularização

Para se ter uma teoria completa são necessários métodos para calcular o parâmetro  $\alpha$  na Equação (3.7). O balanço entre o termo da diferença quadrática e o termo de regularização é realizado pelo parâmetro de regularização. Diversas técnicas têm sido propostas para determinação deste parâmetro (BERTERO; BOCCACCI, 1998) (ENGL *et al.*, 1996) (MOROZOV, 1992). Dentre elas destaca-se o princípio de discrepância de Morozov.

Em muitos problemas aplicados pode-se avaliar o erro máximo de medida nos dados experimentais. No princípio da discrepância, o parâmetro  $\alpha$  é escolhido numericamente, assumindo-se que o erro de medida é conhecido, ou seja,

$$\|Kx - y_\delta\|_Y = \|y - y_\delta\|_Y \leq \delta \quad (3.11)$$

então o parâmetro de regularização  $\alpha$  é determinado utilizando-se a relação

$$\|Kx^{\alpha(\delta)} - y_\delta\|_Y = \delta \quad (3.12)$$

onde  $\|\cdot\|$  é uma norma em  $Y$  (por exemplo, norma 2) e  $\delta$  é o erro da medida. Assim, busca-se um parâmetro cuja solução  $x^{\alpha(\delta)}$  gere a mesma diferença em relação aos dados experimentais  $y_\delta$  que sejam geradas pela solução exata  $x$ .

Muniz *et al.* (1999) mostraram que o princípio da discrepância de Morozov vale para Tikhonov e Entropia de alta ordem, enquanto foi mostrado que este princípio também vale para entropia não-extensiva de ordem zero em Shiguemori *et al.* (2004).

Nos experimentos numéricos baseados no princípio de Morozov,  $\alpha^*$  é ótimo quando:

$$N_x \sigma^2 \sim \|Cf_{\alpha^*} - T_{experimental}\|_2^2 = R(f^*) \quad (= M^{\alpha^*}[\tilde{T}], f^*] - \alpha^* \Omega[f^*]) \quad (3.13)$$

sendo  $\sigma$  é o desvio padrão dos erros medidos (MOROZOV, 1966), (MUNIZ *et al.*, 1999), (MUNIZ *et al.*, 2000).

Em Campos Velho *et al.* (2007a), a entropia não-extensiva de Tsallis é utilizada como um operador de regularização. No trabalho, o parâmetro de regularização é determinado pela curva-L e o princípio da discrepância de Morozov. O novo operador de alta ordem é aplicado na recuperação dos perfis verticais de temperatura da atmosfera e na recuperação da condição inicial no problema inverso de condução de calor.

### 3.4 Métodos de Otimização

A solução de problemas inversos formulados como um problema de otimização utiliza métodos determinísticos e estocásticos. Uma metodologia interessante que usa a formulação variacional e o método do gradiente conjugado foi proposta pelo pesquisador russo Alifanov (1974) (JARNY *et al.*, 1991). O emprego e comparação de um método quase-Newton (determinístico), do algoritmo genético com epidemia (AGE – primeiro uso em problemas inversos) e o método variacional (com uso de gradiente conjugado) foi apresentado (CHIWIACOWSKY; CAMPOS VELHO, 2006). Se o problema de otimização for linear, a técnica de decomposição em valores singulares pode ser empregada (BERTERO; BOCCACCI, 1998), (BRAGA, 2001), (LEMES *et al.*, 1998a), (LEMES *et al.*, 1998b).

Todavia, pode-se aceitar que, quando um PI é formulado como um problema de otimização, as técnicas podem ser classificadas em duas categorias: algoritmos de busca direta e algoritmos baseados no gradiente. Nos algoritmos de busca direta, somente os valores das funções são usados no processo de busca. Nos métodos baseados no gradiente, os valores das funções e derivadas são utilizados (LIU; HAN, 2003).

Os métodos de busca do gradiente conjugado fazem uso da informação das funções objetivo. A informação do gradiente conjugado da função objetivo é determinada

para direção de busca. Estes métodos são muitas vezes mais rápidos que os métodos de busca direta (LIU; HAN, 2003).

### 3.5 Solução de Problemas Inversos por Redes Neurais Artificiais

As técnicas de redes neurais artificiais podem ser empregadas para resolver problemas inversos e constituem uma metodologia completamente nova no contexto dos problemas inversos.

Devido a suas características, as redes neurais artificiais podem ser utilizadas para resolver problemas complexos que necessitam do conhecimento de um modelo matemático para o problema direto (LIU; HAN, 2003). Alguns trabalhos empregando redes neurais artificiais em problemas inversos podem ser destacados: (HIDALGO; GÓMEZ-TREVIÑO, 1996) em sensoriamento remoto, (ATALLA; INMAN, 1998) em danos estruturais, (KREJSA *et al.*, 1999) em transferência de calor, (ALMEIDA *et al.*, 1999) em físico-química, (WOODBURY, 2000) em transferência de calor. Além abordagem por redes neurais (Hopfield) em soluções de PI (ELSHAFIEY *et al.*, 1994), (ZHANG; PAULSON, 1997), (BRAGA *et al.*, 2000), (NEVES *et al.*, 2002), (SEBASTIÃO *et al.*, 2003), (VITERBO *et al.*, 2004).

Os primeiros trabalhos envolvendo o emprego de redes neurais na solução de problemas inversos desenvolvidos no Laboratório de Computação e Matemática Aplicada (LAC) do INPE consistiram na recuperação da condição inicial no problema inverso de condução de calor (MIKKI *et al.*, 1999) e (ISSAMOTO *et al.*, 1999), nos quais foram utilizadas as redes neurais Perceptron de Múltiplas Camadas e Funções de Base Radial.

Posteriormente, um estudo complementar foi realizado utilizando conjuntos de treinamento e generalização mais abrangentes e outros modelos de redes neurais como a rede neural construtiva Correlação em Cascata, cujos resultados foram comparados com a RPMC e RFBR. Foram obtidos resultados próximos aos desejados mesmo com a perturbação de ruídos aleatórios de 1% e 5%. O desempenho das RNAs foi analisado no problema inverso de condução de calor para estimar condições iniciais (SHIGUEMORI *et al.*, 2001) e (SHIGUEMORI *et al.*, 2003). Dois exemplos de inversões na estimação da condição de contorno utilizando-se redes neurais são apresentados na Figura 3.3. Na Figura 3.3-a) são apresentados os resultados obtidos com a RPMC, enquanto na Figura 3.3-b) os resultados obtidos com a RFBR. A linha

azul indica a condição de contorno exata e as linhas preta e vermelha as estimações usando a rede percpetron de múltiplas camadas treinadas com diferentes conjuntos de treinamento.

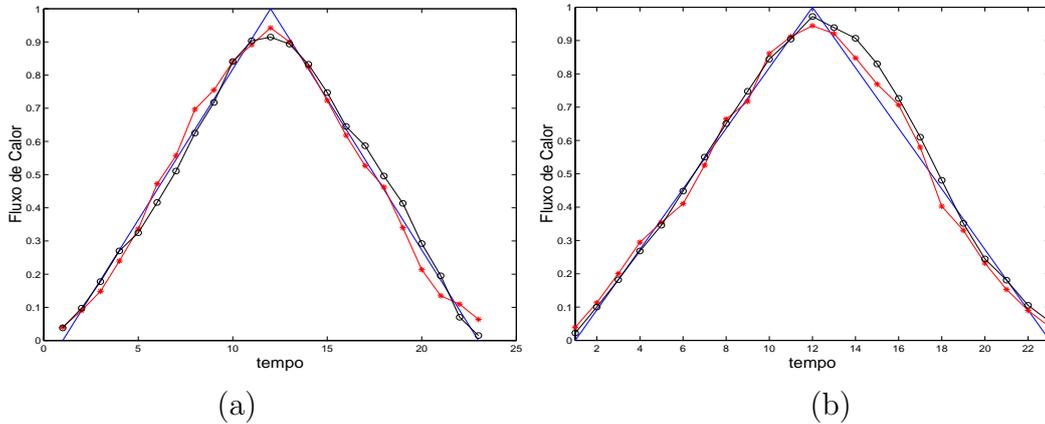


Figura 3.3 - Exemplos de inversões usando redes neurais

Destacam-se outros trabalhos realizados no LAC, aplicando RNA em Problemas Inversos: recuperação de perfis verticais de concentração de metano da atmosfera (CARVALHO *et al.*, 2007), em restauração de imagens (CASTRO; SILVA, 2007b), (CASTRO; SILVA, 2007a), em assimilação de dados (HÄRTER; CAMPOS VELHO, 2005), na detecção de danos (SHIGUEMORI *et al.*, 2005b; SHIGUEMORI *et al.*, 2005a), na recuperação de dados atmosféricos através de medidas de radio ocultação de satélites: perfis de temperatura (CINTRA *et al.*, 2006) e perfis de umidade (CINTRA *et al.*, 2007).

## CAPÍTULO 4

### REDES NEURAIS ARTIFICIAIS

As RNAs têm mostrado sua eficiência em várias aplicações em diferentes áreas, consolidando-se como uma técnica de solução de problemas complexos em reconhecimento de padrões, processamento de sinais, análise de séries temporais e, entre outras aplicações, a solução de problemas inversos.

O sonho de se reproduzir o funcionamento do cérebro humano ainda está muito longe de ser realizado num computador. O cérebro humano é um sistema complexo e distribuído, extremamente rápido, com acesso a memória eficiente e é adaptativo. As redes neurais artificiais surgiram inspiradas na biologia. Longe de ser um modelo completo partem da unidade mais simples do cérebro humano: o neurônio. O neurônio artificial é um modelo muito simples e que não resolve vários problemas numa única rede. No entanto, sua aplicação em funções especializadas têm mostrado sua eficiência. Esta eficiência é fortalecida pela solução de problemas com extrema rapidez, quando comparada com métodos tradicionais, em função do processamento paralelo e distribuído, assim como o funcionamento do cérebro humano. Ainda contendo algumas características do funcionamento biológico, as redes são tolerantes a falhas, tratam dados ruidosos e podem adaptar-se ao ambiente. As RNAs também são chamadas de modelos conexionistas, sistemas adaptativos e neurocomputadores.

A literatura sobre a história, teoria e aplicações das redes neurais artificiais é vasta, incluindo diversos livros e publicações especializadas. Trabalhos de novos modelos e aplicações são frequentemente apresentados, reforçados por congressos e simpósios especializados que acontecem em diversos países, dedicados à disseminação e exploração de novos modelos e aplicações das redes neurais. Desde seu ressurgimento, em 1992, trabalhos e aplicações de RNAs têm aumentado no decorrer dos anos.

A pesquisa das redes neurais artificiais começou em 1943, quando McCulloch e Pitts apresentaram um modelo da atividade de um neurônio biológico. Usando elementos lógicos simples, mostraram como as redes feitas com muitas dessas unidades interconectadas poderiam realizar operações lógicas. Rosenblatt desenvolveu o Perceptron ([ROSENBLATT, 1958](#)) e Widrow e Hoff, em 1960, conceberam a ADALINE ([WIDROW; HOFF, 1960](#)).

Um marco histórico ocorrido na área de pesquisa das redes neurais foi a publicação do livro “Perceptrons” (MINSKY; PAPERT, 1969), onde foram apresentadas restrições dos modelos da época, a de que as redes só poderiam ser aplicadas em problemas linearmente separáveis. As pesquisas ressurgiram com a publicação do artigo de Hopfield em 1982 (HOPFIELD, 1982). Desde então as atividades na área têm crescido exponencialmente (BRAGA *et al.*, 2000; HAYKIN, 1994).

Outras características dos modelos neurais são:

- não-linearidade,
- mapeamento de entrada-saída,
- adaptabilidade,
- aprendizagem com exemplos,
- processamento paralelo e distribuído,
- capacidade de generalização,
- tolerância a falhas e
- baixo custo computacional (após o treinamento).

Nas redes neurais, a informação é totalmente distribuída e propagada entre os pesos, que são ajustados durante a aprendizagem. Estes pesos (conexões) são as unidades de memória das redes e seus valores representam o estado corrente do conhecimento na rede.

As redes neurais também são tolerantes a falhas, podendo tomar decisões com dados incompletos, ou seja, com o conhecimento totalmente distribuído não serão observadas falhas se houver falha de uma porcentagem das entradas.

A computação das redes neurais consiste em interconectar as unidades que agem instantaneamente nos dados de forma paralela. Embora os computadores digitais tenham que simular este paralelismo, redes neurais implementadas em hardware realizam essas operações em paralelo, sendo extremamente rápidas quando comparadas com implementações em software.

## 4.1 Neurônios Biológicos

A célula nervosa, ou neurônio biológico, foi identificada no século XIX pelo neurologista Ramón Cajal. O neurônio possui um corpo celular, ou soma, que é o centro dos processos metabólicos da célula nervosa, a partir dele projetam-se extensões filamentosas, os dendritos e o axônio - ver Figura 4.1.

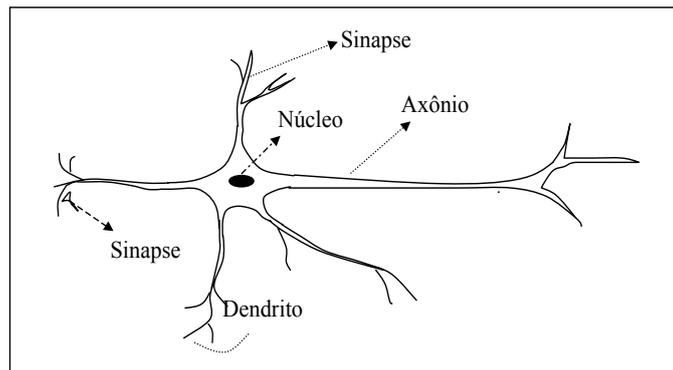


Figura 4.1 - Esquema da célula neural

Os dendritos cobrem um volume muitas vezes maior que o próprio corpo celular e formam uma árvore dendrital, já o axônio conecta uma célula nervosa a outras através de suas ramificações (KOVÁCS, 1996). O neurônio biológico pode ser visto como sendo o dispositivo computacional elementar básico do sistema nervoso, com muitas entradas e uma saída. As entradas ocorrem através das conexões sinápticas, que conectam a árvore dendrital aos axônios de outras células nervosas. Os sinais que chegam por estes axônios são pulsos elétricos conhecidos como impulsos nervosos e constituem a informação que será processada pelo neurônio, para produzir como saída um impulso nervoso no seu axônio.

As sinapses são regiões eletroquímicas ativas, compreendidas entre duas membranas. A pré-sináptica, por onde chega um estímulo proveniente de uma outra célula e a pós-sináptica, que é a do dendrito. Nesta região intersináptica, o estímulo nervoso que chega à sinapse é transferido à membrana dendrital através dos neurotransmissores, que, dependendo do tipo, dará origem a uma conexão excitatória ou inibitória. Uma conexão excitatória provoca uma alteração no potencial da membrana que contribui para a formação de um impulso nervoso no axônio de saída, enquanto que uma conexão inibitória age no sentido oposto (KOVÁCS, 1996).

## 4.2 Neurônios Artificiais

Os componentes de um neurônio artificial têm uma analogia direta com os componentes dos neurônios biológicos. A Figura (4.2) mostra a representação esquemática de um neurônio artificial.

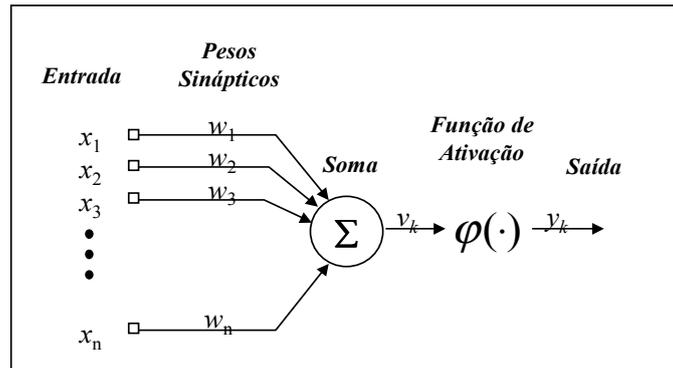


Figura 4.2 - Representação de um neurônio artificial. FONTE:Haykin (2000, p. 36)

Assim como os neurônios biológicos possuem muitas entradas, dadas pelos níveis de estímulos, os neurônios artificiais também têm inúmeras entradas que são apresentadas ao mesmo tempo. Cada uma dessas entradas é amplificada por um peso (ou peso sináptico), representado por  $w_1, w_2, \dots, w_n$ . Os pesos são coeficientes adaptáveis dentro da rede e determinam a intensidade do sinal da entrada. Cada entrada é multiplicada por um peso sináptico, que afeta o seu valor semelhantemente à junção sináptica dos neurônios biológicos. Os produtos das entradas pelos pesos são somados. Matematicamente esse processo pode ser dado pela equação:

$$v_j = \sum_{k=1}^n w_{jk} x_k \quad (4.1)$$

onde,  $x_k$  para  $k = 1, 2, \dots, n$  são os componentes do vetor de entrada e  $w_{jk}$  representa o peso sináptico que conecta a entrada  $j$  com o neurônio  $k$ . O sinal de atividade interna total  $v$  do neurônio  $j$  é o produto interno entre o vetor  $\bar{x}$  e o vetor  $\bar{w}$ .

Semelhantemente aos neurônios biológicos, que emitem um pulso se a atividade elétrica interna supera o limiar  $-50mv$ , no neurônio artificial o sinal passa por uma função de ativação para produzir um efeito de emissão de um pulso.

### 4.3 Funções de Ativação

A partir do modelo de McCulloch e Pitts foram derivados vários outros modelos que permitem a produção de uma saída qualquer, não necessariamente zero ou um, e com diferentes funções de ativação. A Figura 4.3 apresenta a função sinal (a), a função rampa (b), a logística sigmoidal (c) e a tangente hiperbólica (d), respectivamente dadas pelas equações:

$$\varphi(v) = \begin{cases} -1, & \text{se } v < 0, \\ +1, & \text{se } v \geq 0, \end{cases} \quad (4.2)$$

$$\varphi(v) = \begin{cases} 0, & \text{se } v < 0, \\ v, & \text{se } 0 \leq v < 1, \\ +1, & \text{se } v > 1 \end{cases} \quad (4.3)$$

$$\varphi(v) = \frac{1}{1 + e^{-av}} \quad (4.4)$$

$$\varphi(v) = \frac{1 - e^{-av}}{1 + e^{-av}} \quad (4.5)$$

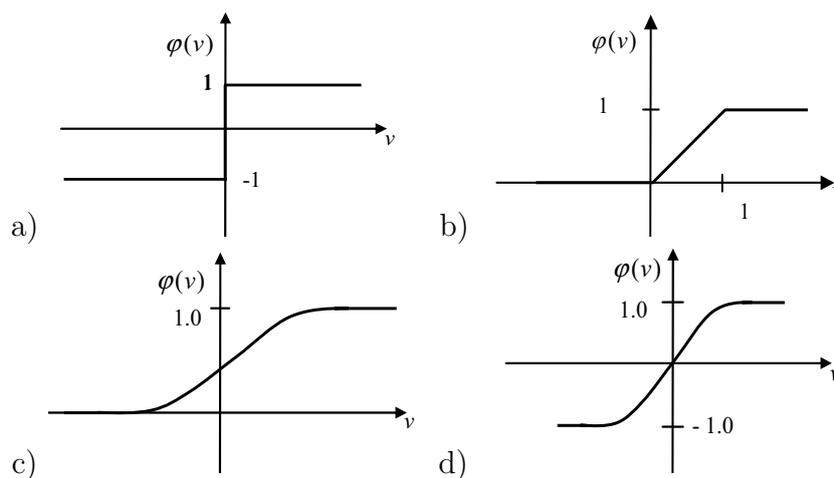


Figura 4.3 - Funções de Ativação

As funções sigmóide e tangente hiperbólica são utilizadas em alguns modelos de redes que requerem a derivada da função no processo de aprendizagem.

#### 4.4 Arquitetura das Redes Neurais Artificiais

Através da combinação dos neurônios artificiais pode-se gerar diferentes arquiteturas de redes. Os neurônios em geral são organizados em camadas, sendo que alguns modelos de redes neurais são constituídos somente por uma camada. As redes com duas ou mais camadas são denominadas redes de camadas múltiplas e quando há realimentação de alguma dessas camadas a rede é chamada de recorrente.

Como mencionado, numa arquitetura mais simples, os neurônios formam uma rede com uma única camada como pode ser observado na Figura (4.4). Nela as entradas se projetam-se diretamente sobre a camada de saída. Como não há realimentação, a rede neural é denominada rede "feed-forward"(de alimentação para frente).

A conexão é total quando todas as saídas de uma camada estão conectadas em todos os neurônios da próxima camada. Na falta de alguma destas conexões, a rede é referida como parcialmente conectada.

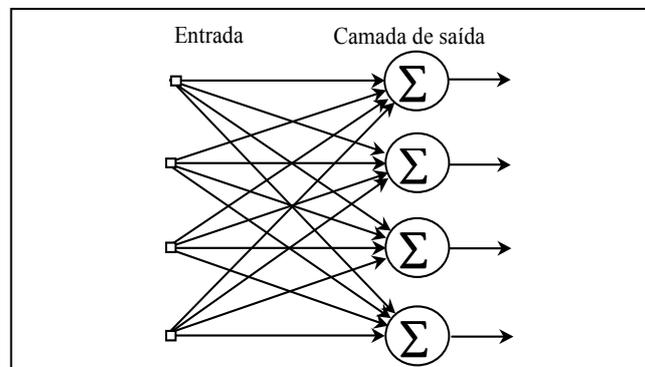


Figura 4.4 - Rede com uma única camada.

Os neurônios também podem estar dispostos de modo a formar uma arquitetura composta com duas ou mais camadas. Na Figura (4.5) tem-se um exemplo, onde a primeira camada é a entrada, a última é a camada de saída e as outras, que não têm contato com o meio externo, são denominadas camadas escondidas, compostas pelos chamados neurônios escondidos.

Com a existência de uma ou mais camadas escondidas, a rede torna-se capaz de extrair características de ordem elevada, adquirindo uma perspectiva global, apesar de sua conectividade local (HAYKIN, 1994). As redes de uma única camada têm a restrição de resolver somente problemas linearmente separáveis. Para a solução de problemas não-lineares, que é o caso resolvido neste trabalho, é necessário o uso de rede com camadas escondidas. A rede com uma única camada escondida pode implementar qualquer função contínua. A utilização de duas camadas intermediárias são aplicadas à aproximação de qualquer função (BRAGA *et al.*, 2000).

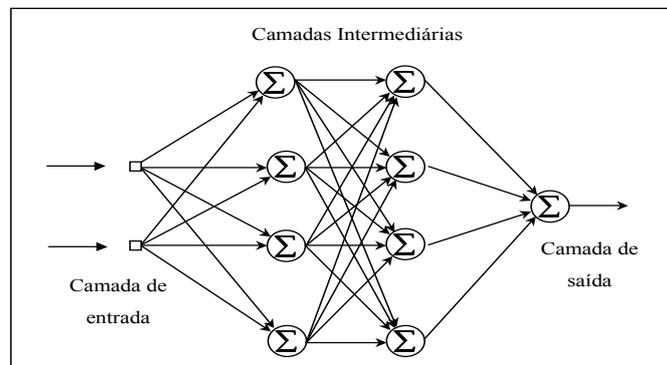


Figura 4.5 - Rede de três camadas.  
 FONTE: Modificada de Haykin (2000, p. 48).

#### 4.5 Funcionamento das Redes Neurais

O processo de aprendizagem, também conhecido como treinamento, consiste no processo de adaptação dos pesos sinápticos das conexões e dos níveis de limiar (bias) dos neurônios em resposta às entradas. A ativação consiste no processo de receber uma entrada e produzir uma saída de acordo com a arquitetura final da rede.

Existem dois principais paradigmas de aprendizado: o aprendizado supervisionado e o aprendizado não supervisionado, que indicam como os pesos das conexões devem ser ajustados de acordo com a resposta da ativação. No aprendizado supervisionado, apresenta-se uma resposta desejada para uma dada entrada. Já no aprendizado não supervisionado, somente o vetor de características é apresentado à entrada da rede. A rede, então, se auto-organiza para que cada neurônio responda a diferentes conjuntos de entrada (HAYKIN, 1994; BRAGA *et al.*, 2000). Uma rede é treinada até que um número máximo de épocas de treinamento seja atingido ou um erro objetivo seja alcançado. Tem-se uma época de treinamento a cada apresentação de todo o

conjunto de treinamento. Deve-se observar que a condição de parada relativa ao erro objetivo só pode ser usada por redes com aprendizagem supervisionada, pois o erro é calculado entre a saída desejada e a saída obtida.

Existem diferentes tipos de redes neurais que se diferenciam principalmente na arquitetura e no algoritmo de aprendizagem. cada qual oferecendo vantagens específicas.

## 4.6 Perceptron

A rede neural Perceptron foi proposta por Rosenblatt em 1958 (HAYKIN, 1994; BRAGA *et al.*, 2000), sendo o primeiro modelo de rede neural com aprendizagem supervisionada. É uma rede simples de uma única camada com pesos e limiares ajustáveis. Roseblatt provou que se os padrões usados para treinar o perceptron são retirados de duas classes linearmente separáveis, então o algoritmo do perceptron converge e posiciona a superfície de decisão na forma de um hiperplano entre as duas classes. A prova de convergência do algoritmo é conhecida com o teorema de convergência do perceptron (HAYKIN, 1994; BRAGA *et al.*, 2000). Um único neurônio perceptron limita-se a realizar classificação de padrões com apenas duas classes. Expandindo-se a camada de saída do perceptron para incluir mais de um neurônio, pode-se classificar mais de duas classes, no entanto as classes devem ser linearmente separáveis.

No processo de adaptação, ou aprendizado, deseja-se obter o valor do incremento  $\Delta\bar{w}$  a ser aplicado ao vetor de pesos  $\bar{w}$  de forma que seu valor atualizado  $\bar{w}(t+1) = \bar{w}(t) + \Delta\bar{w}$  esteja mais próximo da solução desejada que  $\Delta\bar{w}$ .

O erro é calculado através da diferença entre a saída obtida e a saída desejada e é dado pela equação:

$$e_k(n) = d_k(n) - y_k(n) \quad (4.6)$$

onde  $d_k(n)$  e  $y_k(n)$  são os sinais de saída desejado e obtido respectivamente no neurônio  $k$  no tempo  $n$ .

O cálculo dos novos pesos e dos novos limiares é obtido por:

$$w_{ki}(n+1) = w_{ki}(n) + \eta x_i(n) e_k(n) \quad e \quad (4.7)$$

$$b_k(n+1) = b_k(n) + \eta e_k(n) \quad (4.8)$$

onde  $w(n)$ ,  $x(n)$ ,  $e(n)$  e  $b(n)$  são respectivamente os pesos, a entrada, o erro e o limiar;  $\eta$  é a taxa de aprendizagem e  $n$  o tempo.

#### 4.7 Rede Perceptrons de Múltiplas Camadas

Uma das redes mais utilizada na literatura é a rede Rede Perceptron de Múltiplas Camadas, que são alimentadas adiante compondo uma importante classe de redes neurais e têm sido aplicadas com sucesso para resolver diversos problemas complexos, através de seu treinamento de forma supervisionada com um algoritmo bastante popular conhecido como retropropagação do erro (error back-propagation) (HAYKIN, 1994; BRAGA *et al.*, 2000).

O algoritmo de retropropagação do erro foi apresentado por (RUMELHART *et al.*, 1986), dando um passo importante para o ressurgimento da área de redes neurais. Entretanto, desenvolvimentos paralelos também foram realizados por (WERBOS, 1989) e (PARKER, 1987).

A RPMC é composta por uma camada de entrada, uma ou mais camadas escondidas e uma camada de saída. Seu algoritmo de treinamento, aprendizagem por retropropagação do erro, consiste em dois passos através das diferentes camadas da rede: um passo para frente, a propagação e um passo para trás, a retropropagação.

Na fase de propagação da rede, o sinal de entrada se propaga para frente, camada por camada até que um conjunto de saídas seja obtido na última camada. Na primeira camada escondida, multiplica-se cada unidade de entrada por um peso correspondente a cada neurônio. O número de neurônios na camada escondida varia de acordo com a aplicação. Os resultados das multiplicações são somados e a soma (Equação 4.9) passa por uma função de ativação (Equação 4.10).

$$v_j(n) = \sum_{i=0}^m w_{ji}(n)y_i(n) \quad (4.9)$$

$$y_j(n) = \varphi_j(v_j(n)) \quad (4.10)$$

onde  $m$  é o número total de entradas aplicado ao neurônio  $j$ , e  $w_{ji}(n)$  é o peso sináptico da conexão do neurônio  $i$  para o neurônio  $j$ ,  $y_i(n)$  é a entrada do neurônio  $j$ . Se o neurônio  $j$  é a primeira camada escondida da rede,  $m = m_0$  e o índice  $i$  refere-se à  $i$ -ésima entrada da rede, então:

$$y_i(n) = x_i(n) \quad (4.11)$$

onde  $x_i(n)$  é o  $i$ -ésimo elemento do vetor de entrada.

Nas camadas seguintes, o mesmo processo é repetido, sendo que a entrada da próxima camada é a saída da anterior. Na rede, é possível variar o número de neurônios na camada escondida e também o número de camadas.

Durante o processo de propagação, os pesos sinápticos da rede são todos fixos. No passo para trás, os pesos sinápticos são ajustados de acordo com uma regra de correção do erro. A resposta real da rede é subtraída de uma resposta desejada (alvo) para produzir um sinal de erro. Este sinal é então propagado para trás através da rede, contra a direção das conexões sinápticas, conhecido por retropropagação.

#### 4.7.1 Determinação dos pesos sinápticos - $w_{ji}(n)$

Os pesos sinápticos são ajustados para fazer com que a resposta real da rede seja mais próxima da resposta desejada, num sentido estatístico (HAYKIN, 1994). O processo de aprendizado termina quando se atinge um erro desejado ou um número máximo de épocas.

O sinal erro na saída do neurônio  $j$  na iteração  $n$  é definido por:

$$e_j(n) = d_j(n) - y_j(n), \text{ neurônio } j \text{ é um nó de saída} \quad (4.12)$$

O valor instantâneo do erro quadrático para o neurônio  $j$  é dado por:

$$1/2e_j^2(n) \quad (4.13)$$

O valor instantâneo da soma dos erros quadráticos nos neurônios de saída é:

$$\mathcal{E}(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (4.14)$$

onde  $C$  é o conjunto de todos os neurônios na camada de saída da rede. Seja  $N$  o número total de padrões contidos no conjunto de treinamento, a média da soma dos erros quadráticos nos neurônios de saída é obtida por:

$$\mathcal{E}_{\text{med}} = \frac{1}{N} \sum_{n=1}^N \mathcal{E}(n) \quad (4.15)$$

O algoritmo de retropropagação aplica uma correção  $\Delta w_{ji}(n)$ , que é proporcional à derivada parcial  $\partial \mathcal{E}(n) / \partial w_{ji}(n)$ . Aplicando a regra da cadeia, essa derivada é dada por:

$$\frac{\partial \mathcal{E}(n)}{\partial w_{ji}(n)} = \frac{\partial \mathcal{E}(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial w_{ji}(n)} \quad (4.16)$$

A derivada parcial  $\partial \mathcal{E}(n) / \partial w_{ji}(n)$  representa um fator sensitivo, determinando a direção de busca no espaço de pesos sinápticos  $w_{ji}$ .

Derivando ambos os lados da Equação 4.14 com relação à  $e_j(n)$ , tem-se:

$$\frac{\partial \mathcal{E}(n)}{\partial e_j(n)} = e_j(n). \quad (4.17)$$

Derivando ambos os lados da Equação 4.12 com relação à  $y_j(n)$ , tem-se:

$$\frac{\partial e_j(n)}{\partial y_j(n)} = -1. \quad (4.18)$$

Derivando a Equação 4.10 com relação à  $v_j(n)$ , tem-se:

$$\frac{\partial y_j(n)}{\partial v_j(n)} = \varphi'_j(v_j(n)) \quad (4.19)$$

Derivando a Equação 4.9 com relação à  $w_{ji}(n)$  resulta em:

$$\frac{\partial v_j(n)}{\partial w_{ji}(n)} = y_i(n) \quad (4.20)$$

O uso das Equações 4.17 à 4.20 resulta em:

$$\frac{\mathcal{E}(n)}{\partial w_{ji}(n)} = -e_j(n)\varphi'_j(v_j(n))y_i(n) \quad (4.21)$$

A correção  $\Delta w_{ji}(n)$  aplicado à  $w_{ji}(n)$  é definida pela regra delta:

$$\Delta w_{ji}(n) = -\eta \frac{\partial \mathcal{E}}{\partial w_{ji}(n)} \quad (4.22)$$

onde  $\eta$  é a taxa de aprendizagem. O uso do sinal menos da Equação 4.22 representa o gradiente descendente no espaço de pesos.

O gradiente local  $\delta_j(n)$  do neurônio  $j$  é definido por

$$\begin{aligned} \delta_j(n) &= -\frac{\partial \mathcal{E}(n)}{\partial v_j(n)} \\ &= -\frac{\partial \mathcal{E}(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \\ &= e_j(n)\varphi'_j(v_j(n)) \end{aligned} \quad (4.23)$$

Substituindo a Equação 4.23 na Equação 4.22 tem-se a correção expressa de forma proporcional ao gradiente local do neurônio:

$$\Delta w_{ji}(n) = \eta \delta_j(n) y_i(n) \quad (4.24)$$

Os pesos sinápticos da rede neural são ajustados através do gradiente local. O gradiente local  $\delta_j(n)$  para o neurônio de saída  $j$  é igual ao produto do sinal erro correspondente  $e_j(n)$  e pela derivada  $\varphi'_j(v_j(n))$  da função de ativação associada.

Quando o neurônio  $j$  está localizado na camada escondida da rede, não há uma saída desejada para este neurônio o que impede o cálculo do erro. Portanto, o gradiente local  $\delta_j(n)$  é redefinido para os neurônios escondidos  $j$  como:

$$\begin{aligned}\delta_j(n) &= -\frac{\partial \mathcal{E}(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \\ &= -\frac{\partial \mathcal{E}(n)}{\partial y_j(n)} \varphi'_j(v_j(n)), \quad j \text{ é neurônio escondido}\end{aligned}\tag{4.25}$$

Para calcular a derivada parcial  $\partial \mathcal{E}(n)/\partial y_j(n)$  considera-se o cálculo do erro na camada de saída:

$$\mathcal{E}(n) = \frac{1}{2} \sum_{k \in C} e_k^2(n), \quad \text{neurônio } k \text{ de saída}\tag{4.26}$$

Derivando a 4.26 com relação à  $y_j(n)$ , tem-se:

$$\frac{\partial \mathcal{E}(n)}{\partial y_j(n)} = \sum_k e_k \frac{\partial e_k(n)}{\partial y_j(n)}\tag{4.27}$$

Usando a regra da cadeia para a derivada parcial  $\partial e_k(n)/\partial y_j(n)$  e reescrevendo a Equação 4.27:

$$\frac{\partial \mathcal{E}(n)}{\partial y_j(n)} = \sum_k e_k(n) \frac{\partial e_k}{\partial y_k(n)} \frac{\partial y_k(n)}{\partial v_k(n)} \frac{\partial v_k(n)}{\partial y_j(n)}\tag{4.28}$$

Nota-se que:

$$e_k(n) = d_k(n) - y_k(n), \quad \text{neurônio } k \text{ sendo um nó de saída}\tag{4.29}$$

Conseqüentemente

$$\frac{\partial e_k(n)}{\partial v_k(n)} = -\varphi'_k(v_k(n)) \quad (4.30)$$

No processo de ativação tem-se:

$$v_k(n) = \sum_{j=0}^m w_{kj}(n)y_j(n) \quad (4.31)$$

onde  $m$  é o número total de entradas aplicado ao neurônio  $k$ . Derivando a Equação 4.31 com relação à  $y_j(n)$  tem-se:

$$\frac{\partial v_k(n)}{\partial y_j(n)} = w_{kj}(n) \quad (4.32)$$

Usando 4.30 e 4.32 em 4.28 obtém-se:

$$\begin{aligned} \frac{\partial \mathcal{E}(n)}{\partial y_j(n)} &= - \sum_k e_k(n) \varphi'_k(v_k(n)) w_{kj}(n) \\ &= - \sum_k \delta_k(n) w_{kj}(n). \end{aligned} \quad (4.33)$$

Aplicando 4.33 em 4.23, obtém-se a fórmula de retro-propagação para o gradiente local:

$$\delta_j(n) = \varphi'_j(v_j(n)) \sum_k \delta_k(n) w_{kj}(n) \quad (4.34)$$

onde  $\varphi'_j(n)$  envolvido no cálculo do gradiente depende da função de ativação associada com o neurônio escondido  $j$ . O fator envolvendo este cálculo, da soma sobre  $k$ , depende do gradiente local  $\delta_k(n)$  que requer conhecimento do sinal erro  $e_k(n)$ . O termo  $w_{kj}(n)$  consiste dos pesos associados com as conexão do neurônio  $j$ .

Os novos pesos são obtidos pela equação:

$$w_{ji}^L(n+1) = w_{ji}^L(n) + \eta \delta_j^L(n) y_i^{L-1}(n) \quad (4.35)$$

onde  $L$  representa a camada onde o neurônio  $j$  está localizado.

#### 4.8 Rede de Funções de Base Radial

A Rede de Função de Base Radial foi introduzida por Powell (1985), com o intuito de resolver o problema de ajuste de curva num espaço de alta dimensionalidade onde sua generalização é equivalente ao uso da superfície de múltiplas dimensões para interpolar os dados de teste.

A rede é do tipo feed-forward e possui três camadas: a camada de entrada da rede, uma camada escondida e a camada de saída. O algoritmo de aprendizado da rede é supervisionado, no entanto as conexões entre as camadas de entrada e escondida, diferentemente da maioria das redes de múltiplas camadas, representam centros de classes.

O processo de ativação da rede é dado pela equação:

$$F(\bar{x}) = \sum_{k=1}^m w_k \varphi_k(\bar{x}) \quad (4.36)$$

onde  $w_k$  são os pesos do neurônio,  $m$  é o número de neurônios e  $\varphi_k(x) | k = 1, 2, \dots, m$  é conjunto de funções de base, dadas por:

$$\varphi_k(\bar{x}) = G(\|\bar{x} - \bar{t}_k\|), \quad k = 1, 2, \dots, m \quad (4.37)$$

onde  $\bar{t}_k$  para  $k = 1, 2, \dots, m$  é o conjunto de centros e  $G$  a função de base radial. Assim, pode-se redefinir  $F(x)$  como sendo:

$$F(\bar{x}) = \sum_{k=1}^m w_k G(\|\bar{x} - \bar{t}_k\|) \quad (4.38)$$

A aprendizagem consiste na determinação de um novo conjunto de pesos que minimize o custo  $\epsilon(F)$  definido por:

$$\epsilon(F) = \sum_{p=1}^N \left( d_p - \sum_{k=1}^m w_k G(\|\bar{x}_p - \bar{t}_k\|) \right)^2 \quad (4.39)$$

onde  $N$  é o número total de padrões.

Há algumas estratégias de aprendizado que podem ser implementadas numa Rede de Funções de Base Radial que dependem de como os centros da rede são especificados (HAYKIN, 1994). Duas delas são apresentados nas seções seguintes.

#### 4.8.1 Centros Fixos Selecionados Aleatoriamente

Na estratégia mais simples assume-se funções de Base Radial fixas. As localizações dos centros são escolhidas aleatoriamente no conjunto de treinamento. Pode-se empregar funções gaussianas isotrópicas, cujo desvio padrão é fixado de acordo com o espalhamento dos centros. Especificamente, uma função de base radial centrada em  $\bar{t}_k$ , é definida como:

$$G(\|\bar{x} - \bar{t}_k\|^2) = \exp\left(-\frac{M}{d^2} \|\bar{x} - \bar{t}_k\|^2\right), k = 1, 2, \dots, m \quad (4.40)$$

onde  $M$  é o número de centros e  $d$  é a distância máxima entre os centros escolhidos. O desvio padrão ( $\sigma$ ) de todas as funções de base radial são fixadas em:

$$\sigma = \frac{d}{\sqrt{2M}} \quad (4.41)$$

Esta equação assegura que as funções de base radial individuais não sejam pontiagudas demais ou planas demais; estas duas condições extremas devem ser evitadas.

Os únicos parâmetros que devem ser aprendidos nesta abordagem são os pesos na camada de saída da rede.

#### 4.8.2 Seleção Auto-organizada de Centros

Uma outra estratégia de aprendizado tem um processo híbrido constituído de dois diferentes estágios. O primeiro consiste na aprendizagem auto-organizada, para

estimar os centros das funções de base radial da camada escondida. O segundo consiste na aprendizagem supervisionada, na camada de saída.

No estágio da aprendizagem auto-organizada, é usado um algoritmo de agrupamento dos dados similares, colocando-se os centros das funções de base radial nas regiões de espaço de entrada. Um algoritmo de agrupamento empregado é o  $k$ -médias (DUDA; HART, 1973), em que um vetor de entrada é selecionado do conjunto de treinamento, sendo feito um casamento de similaridade entre este vetor e o centro da classe, utilizando-se a distância euclidiana mínima:

$$k(\bar{x}) = \arg \min \|\bar{x}(n) - \bar{t}_k(n)\|, k = 1, 2, \dots, m \quad (4.42)$$

onde  $\arg \min$  corresponde ao argumento da distância mínima entre a entrada  $\bar{x}$  e o centro da  $k$ -ésima função de base radial  $\bar{t}$  na iteração  $n$ ,  $k(\bar{x})$  representa o índice do centro com a menor distância. Os centros são iniciados aleatoriamente.

O ajuste dos centros das funções de base radial é obtido por:

$$\bar{t}_k(n+1) = \begin{cases} \bar{t}_k(n) + \eta[\bar{x}(n) - \bar{t}_k(n)], & k = k(\bar{x}) \\ \bar{t}_k(n), & \text{c.c.} \end{cases} \quad (4.43)$$

onde  $\eta$  é a taxa de aprendizagem.

No processo de ajuste dos pesos e limiares da camada de saída, usa-se o algoritmo de mínimos quadrados.

#### 4.9 Proposta de uma Rede de Funções de Base Radial Não-Extensiva

Desde que a RFBR foi proposta por Powell (1985), vários trabalhos têm sido propostos afim de melhorar a performance da rede neural. Basicamente, a construção de uma RFBR depende de três principais fatores:

- projeto das funções de base radial,
- seleção dos centros das funções e
- determinação dos pesos da camada de saída da rede neural.

A seleção dos centros das funções e determinação dos pesos da camada de saída da rede neural são os principais pontos abordados pelas pesquisas. [Broomhead e Lowe \(1988\)](#) sugeriram que os centros das funções de base radial podem ser distribuídos uniformemente dentro da região de espaço de entrada, ou escolhendo-se um subconjunto de vetores de treinamento por analogia. [Moody e Darken \(1989\)](#) propuseram um processo de aprendizagem híbrido com funções de base radial híbridas, empregando-se um esquema de atualização dos pesos de forma supervisionada. Em [Karayiannis e Mi \(1997\)](#), os centros das funções de base radial foram determinadas por algoritmos de agrupamento  $k$ -médias ou  $c$ -médias. [Poggio e Girosi \(1990\)](#) propuseram uma aproximação supervisionada para RBF com funções gaussianas. [Chen et al. \(1991\)](#) propuseram um processo de aprendizagem para RFBR baseado nos mínimos quadrados ortogonal para selecionar os centros das funções de base radial.

A variação da rede RFBR proposta neste trabalho, foca-se no primeiro item. São utilizadas funções de base radial com a estatística não-extensiva de Tsallis ([TSALLIS, 1988](#); [TSALLIS, 1999](#)), na qual o parâmetro  $q$  tem um papel principal no formalismo termoestatístico de Tsallis. Denominada Rede Funções de Base Radial Não-Extensiva (RFBR-NE), em seu treinamento, os algoritmos para determinar o centro de cada função de base radial e a distância desses centros, encontrados na literatura, podem ser utilizados como por exemplo, o algoritmo de agrupamento  $k$ -médias. Uma vez que os neurônios da camada escondida são relacionados, os pesos da camada de saída podem ser determinados também com os algoritmos encontrados na literatura, como por exemplo, analiticamente usando um método de mínimos quadrados que determina a saída ótima na camada de saída baseado nos dados de treinamento e seleção dos parâmetros dos nós escondidos.

Tomando  $r = \|\bar{x} - \bar{t}_u\|$ , as funções de base radial tradicionalmente utilizadas são:

1. Multiquádricas:

$$G(r) = \sqrt{r^2 + c^2} \text{ para } c > 0 \quad (4.44)$$

2. Multiquádricas inversas

$$G(r) = \frac{1}{\sqrt{r^2 + c^2}} \text{ para } c > 0 \quad (4.45)$$

### 3. Funções gaussianas

$$G(r) = \exp\left(-\frac{r^2}{2\sigma^2}\right) \text{ para } c > 0 \quad (4.46)$$

A ativação da rede neural proposta é dada pela equação:

$$y = \sum_{k=1}^m w_k G(\|\bar{x} - \bar{t}_k\|) \quad (4.47)$$

onde  $\bar{x}$  é a entrada,  $\bar{t}_k$  os  $k$  centros das funções e  $G$  a função de base radial da estatística não-extensiva. A função depende de um parâmetro livre  $q$  apresentando diferentes distribuições (TSALLIS, 1999).

A forma não-extensiva proposta por Tsallis (TSALLIS, 1988) é dada pela expressão:

$$S_q(p(r)) = \frac{k}{q-1} \left(1 - \sum_{i=1}^W p(r)_i^q\right) \quad (4.48)$$

onde  $p_i$  é uma probabilidade,  $W$  o número total de possibilidades e  $q$  é um parâmetro livre. Na termodinâmica, o parâmetro  $k$  é conhecido como constante de Boltzmann. No limite  $q \rightarrow 1$ , a entropia de Tsallis reduz à formula usal de Boltzmann-Gibbs-Shannon (Campos Velho *et al.*, 2007a).

Como apresentado em Tsallis (1999), as distribuições  $p_q(r)$  para diferentes valores de  $q$  são dadas por:

Se  $q > 1$

$$p_q(r) = G(r) = \frac{1}{\sigma} \left[ \frac{q-1}{\pi(3-q)} \right]^{\frac{1}{2}} \frac{\Gamma\left(\frac{1}{q-1}\right)}{\Gamma\left(\frac{3-q}{2(q-1)}\right)} \frac{1}{\left(1 + \frac{q-1}{3-q} \frac{r^2}{\sigma^2}\right)^{\frac{1}{q-1}}} \quad (4.49)$$

Se  $q = 1$

$$p_q(r) = G(r) = \frac{1}{\sigma} \left[ \frac{1}{2\pi} \right]^{\frac{1}{2}} e^{-(r/\sigma)^2/2} \quad (4.50)$$

Se  $q < 1$

$$p_q(r) = G(r) = \frac{1}{\sigma} \left[ \frac{1-q}{\pi(3-q)} \right]^{\frac{1}{2}} \frac{\Gamma\left(\frac{5-3q}{2(1-q)}\right)}{\Gamma\left(\frac{2-q}{1-q}\right)} \left[ 1 - \frac{(1-q)}{(3-q)} \frac{r^2}{\sigma^2} \right]^{\frac{1}{(1-q)}} \quad (4.51)$$

se  $|r| < \sigma[(3-q)/(1-q)]^{1/2}$  e zero caso contrário.

A família de soluções é apresentada na Figura 4.6. Quando  $q = 1$ , a distribuição corresponde à distribuição gaussiana e quando  $q = 2$ , à distribuição de Cauchy.

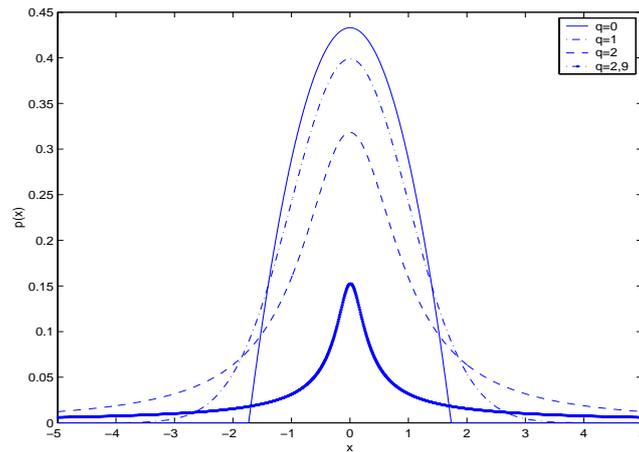


Figura 4.6 - Distribuição de Tsallis para vários valores de  $q$ . Fonte: (TSALLIS, 1999)

A estratégia de aprendizagem adotada foi por seleção auto-organizada dos centros, que é composta de um processo de aprendizado híbrido (HAYKIN, 1994) formado por dois estágios: estágio de aprendizagem auto-organizada e estágio de aprendizagem supervisionada. No primeiro estágio, estimam-se os centros das funções de base radial na camada oculta e no segundo estágio são estimados os pesos e limiares dos neurônios na camada de saída, que são compostos por funções lineares.

Foi empregado um algoritmo de agrupamento para particionar o conjunto de dados em subgrupos. Utilizou-se o algoritmo de agrupamento k-médias proposto por Duda

e Hart em 1973 (HAYKIN, 1994). O algoritmo de agrupamento pode ser assim resumido:

- a) os centros  $\bar{t}_k(0)$  são iniciados aleatoriamente  $\bar{t}_k(0)$ ;
- b) um vetor  $x$  é definido a partir do espaço de entrada;
- c) Faz-se o casamento de similaridade.  $k(\bar{x})$  é o índice do centro com melhor casamento (vencedor) com o vetor de entrada  $\bar{x}$ . Encontra-se  $k(\bar{x})$  na iteração  $n$  usando a distância euclidiana mínima como critério:

$$k(x) = \arg \min_k \|\bar{x}(n) - \bar{t}_k(n)\|, k = 1, 2, \dots, m_l \quad (4.52)$$

- d) Os centros das funções de base radial são atualizados usando a regra:

$$\bar{t}_k(x+1) = \begin{cases} \bar{t}_k(n) + \eta [\bar{x}(n) - \bar{t}_k(n)], k = k(\bar{x}) \\ \bar{t}_k(n), \text{ caso contrário} \end{cases} \quad (4.53)$$

onde  $\eta$  é a taxa de aprendizado no intervalo  $0 < \eta < 1$

- e) Incrementa-se  $n$  de 1 e retorna para o passo b. O procedimento continua até que não sejam mais observadas modificações nos centros  $t_k$

Uma vez selecionados os centros das funções de base radial, a determinação dos pesos da camada de saída da RFBR-NE pode ser realizada pelo método de mínimos quadrados, determinação que foi empregada por Chen *et al.* (1991) na RFBR clássica.

#### 4.10 Rede de Hopfield

O modelo de Hopfield (1982) foi responsável pelo ressurgimento das RNAs depois de mais de 10 anos sem pesquisas na área. Trata-se de um modelo recorrente, onde as saídas são ligadas às entradas por um atraso de tempo, assim as características temporais implicam na dependência de seu estado anterior (BRAGA *et al.*, 2000).

A rede de Hopfield faz parte de uma classe de redes neurais que aborda a neurodinâmica, na qual o tempo é incorporado na operação da rede de uma maneira implícita através do uso da realimentação.

A rede de Hopfield consiste de um conjunto de neurônios em que a saída de cada neurônio é realimentada, através de um atraso unitário, para cada um dos outros neurônios da rede.

No estudo da rede de Hopfield, usa-se o modelo neurodinâmico baseado no modelo aditivo de um neurônio (HAYKIN, 1994):

$$C_j \frac{dv_j(t)}{dt} + \frac{v_j(t)}{R_j} = \sum_{i=1}^N w_{ji} x_i(t) + I_j \quad (4.54)$$

onde o termo capacitivo  $C_j dv_j(t)/dt$  é o modo de se acrescentar dinâmica (memória) ao modelo de um neurônio,  $R_j$  é a resistência de fuga e  $I_j$  é a corrente fonte que apresenta o limiar. Em termos físicos, os pesos sinápticos  $w_{j1}, w_{j2}, \dots, w_{jN}$  representam condutâncias, e as entradas respectivas  $x_1(t), x_2(t), \dots, x_N(t)$  representam potências,  $N$  é o número de entradas. As entradas são aplicadas a uma junção aditiva de corrente caracterizada por: baixa resistência de entrada, ganho de corrente unitário e alta resistência de saída (HAYKIN, 1994). A partir do campo local induzido  $v_j(t)$ , pode-se determinar a saída do neurônio  $j$  utilizando-se a relação não-linear:

$$x_j(t) = \varphi(v_j(t)). \quad (4.55)$$

Reconhecendo-se que  $x_i(t) = \varphi_i(v_i(t))$ , a equação 4.54 pode ser reescrita como:

$$C_j \frac{d}{dt} v_j(t) = -\frac{v_j(t)}{R_j} + \sum_{i=1}^N w_{ji} \varphi(v_i(t)) + I_j, \quad j = 1, \dots, N \quad (4.56)$$

Para prosseguir, são feitas as seguintes suposições:

- a) A matriz de pesos sinápticos é simétrica, como mostrado por:

$$w_{ji} = w_{ij} \text{ para todo } i \text{ e } j \quad (4.57)$$

- b) cada neurônio tem uma ativação não-linear.

c) a inversa da função de ativação não-linear existe, e dada por:

$$v = \varphi_i^{-1}(x) \quad (4.58)$$

considerando-se que a função  $\varphi_i(v)$  é definida pela função tangente hiperbólica:

$$x = \varphi_i(v) = \tanh\left(\frac{a_i v}{2}\right) = \frac{1 - \exp(-a_i v)}{1 + \exp(-a_i v)} \quad (4.59)$$

A relação inversa de entrada-saída da Equação 4.58 pode ser escrita na forma:

$$v = \varphi_i^{-1}(x) = -\frac{1}{a_i} \log\left(\frac{1-x}{1+x}\right) \quad (4.60)$$

Assim, a equação 4.60 pode ser reescrita como:

$$\varphi_i^{-1}(x) = \frac{1}{a_i} \varphi^{-1}(x) \quad (4.61)$$

A função de energia da rede de Hopfield é definida por (HOPFIELD, 1982):

$$E = -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N w_{ji} x_i x_j + \sum_{j=1}^N \frac{1}{R_j} \int_0^{x_j} \varphi_j^{-1}(x) dx - \sum_{j=1}^N I_j x_j \quad (4.62)$$

A dinâmica da rede é descrita por um mecanismo que busca os vários mínimos.

Diferenciando-se  $E$  em relação ao tempo, tem-se:

$$\frac{dE}{dt} = - \sum_{j=1}^N \left( \sum_{i=1}^N w_{ji} x_i - \frac{v_j}{R_j} + I_j \right) \frac{dx_j}{dt} \quad (4.63)$$

Reconhecendo-se o termo dentro dos parênteses no lado direito da Equação 4.63 como sendo  $C_j dv_j(t)/dt$  em virtude da equação neurodinâmica 4.56, a simplificação de 4.63 é dada por:

$$\frac{dE}{dt} = - \sum_{j=1}^N C_j \left( \frac{dv_j}{dt} \right) \frac{dx_j}{dt} \quad (4.64)$$

Usando-se a equação 4.58 em 4.64 produz-se:

$$\frac{dE}{dt} = - \sum_{j=1}^N C_j \left[ \frac{d}{dt} \varphi_j^{-1}(x_j) \right] \frac{dx_j}{dt} \quad (4.65)$$

$$\frac{dE}{dt} = - \sum_{j=1}^N C_j \left( \frac{dx_j}{dt} \right)^2 \left[ \frac{d}{dt} \varphi_j^{-1}(x_j) \right] \quad (4.66)$$

Sendo a relação inversa de entrada-saída  $\varphi_j^{-1}(x_j)$  uma função monotonamente crescente da saída  $x_j$ , segue-se que:

$$\frac{d}{dx_j} \varphi_j^{-1}(x_j) \geq 0, \text{ para todo } x_j \quad (4.67)$$

Nota-se também que:

$$\left( \frac{dx_j}{dt} \right)^2 \geq 0, \text{ para todo } x_j \quad (4.68)$$

Sendo assim, todos os fatores que compõem a soma do lado direito da Equação 4.66 são positivos, ou seja, para a função de energia  $E$  definida na Equação 4.62, tem-se:

$$\frac{dE}{dt} \leq 0 \quad (4.69)$$

A evolução temporal do modelo de Hopfield contínuo, descrito pelo sistema de equações diferenciais de primeira ordem não-linear, representa uma trajetória no espaço de estados, que procura o mínimo da função de energia  $E$  e para num ponto fixo. Da equação 4.66, nota-se que a derivada  $dE/dt$  se anula se:

$$\frac{d}{dt}x_j(t) = 0 \text{ para todo } j \quad (4.70)$$

Portanto,

$$\frac{dE}{dt} < 0, \text{ exceto em um ponto fixo} \quad (4.71)$$

Sendo assim, a equação fornece a base para o teorema:

”A função de energia  $E$  de uma rede de Hopfield é uma função monotonamente decrescente no tempo” (SEBASTIÃO *et al.*, 2003),(BRAGA *et al.*, 2000).

Conseqüentemente, a rede de Hopfield é global e assintoticamente estável e os pontos fixos atratores são os mínimos da função de energia e vice-versa.

As redes de Hopfield são classificadas em dois tipos: discreta e contínua. Na rede discreta, a operação é baseada no modelo de McCulloch-Pitts. O estado de cada neurônio tem valores  $-1$  ou  $+1$  (HAYKIN, 1994):

$$x_j = \begin{cases} +1 & \text{para } v_j = \infty \\ -1 & \text{para } v_j = -\infty \end{cases} \quad (4.72)$$

O ponto médio encontra-se na origem:

$$\varphi_j(0) = 0 \quad (4.73)$$

Podendo-se fixar o limiar  $I_j$  igual a zero para todo  $j$ .

Na formulação da função de energia  $E$  para o modelo de Hopfield contínuo, permite-se que os neurônios tenham auto-realimentação. Por outro lado, um modelo de Hopfield discreto não tem auto-realimentações, podendo-se simplificar fazendo  $w_{jj} = 0$  para todo  $j$  em ambos os modelos. Logo, pode-se redefinir a função de energia de um modelo de Hopfield contínuo como:

$$E = -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N w_{ji} x_i x_j + \sum_{j=1}^N \frac{1}{a_j R_j} \int_0^{x_j} \varphi^{-1}(x) dx \quad (4.74)$$

onde  $a$  é a inclinação da função de ativação (HAYKIN, 1994).

A rede de Hopfield tem sido usada com sucesso na solução de problemas inversos não-lineares (BRAGA *et al.*, 2000), (SEBASTIÃO *et al.*, 2003), (Sebastião; BRAGA, 2005a), (Sebastião *et al.*, 2006), (Sebastião; BRAGA, 2005b).

#### 4.11 Utilização da Rede de Hopfield na estimação de perfis verticais de temperatura da atmosfera

Em Viterbo *et al.* (2004) a rede de Hopfield foi empregada, com sucesso, no processo de inversão da Equação de Transferência Radiativa na estimação de perfis verticais de temperatura da atmosfera. Considerou-se a relação entre a intensidade de radiação  $I$ , para uma dada temperatura  $T$ , descrita pela equação de Planck (LIOU, 1982). A temperatura é dependente de alguns outros parâmetros, por exemplo a pressão. Considerando a intensidade de radiação num dado intervalo e a função de Planck, pode-se escrever:

$$I_\lambda = \frac{2hc^2}{\lambda^5} \int_{p_1}^{p_2} \left[ \frac{1}{e^{hc/\lambda k_B T(p)} - 1} \right] \frac{\partial \Gamma}{\partial p} dp \quad (4.75)$$

sendo  $\partial \Gamma / \partial p$  a função peso,  $p$  a pressão atmosférica,  $\lambda$  o comprimento de onda,  $c$  a velocidade da luz,  $h$  a constante de Planck e  $k_B$  a constante de Boltzmann.

Seguindo o caso linear da rede de Hopfield, a função de energia é definida como (HAYKIN, 1994; SEBASTIÃO *et al.*, 2003):

$$E = \frac{1}{2} \sum_{i=1}^{N_\lambda} e_j^2 = \frac{1}{2} \sum_{i=1}^{N_\lambda} \left[ \left( \sum_{i=1}^{N_p} K_{ij} \right) - I_j \right]^2 \quad (4.76)$$

com  $e_j \equiv \left( \sum_i K_{ij} \right) - I_j$ ,  $N_\lambda$  o número de canais espectrais e  $N_p$  o número de camadas atmosféricas. As quantidades  $I_j$  e  $K_{ij}$  são, respectivamente, a intensidade de radiação e matriz (discreta), representação do termo integral da Equação 4.77:

$$K_{ij} = \frac{2hc^2/\lambda_i^5}{e^{hc/\lambda_i k_B T_j}} \left( \frac{\partial \Gamma}{\partial p} \right) w_j \quad (4.77)$$

sendo  $w_j$  os pesos da rede,  $N_\lambda$  o número de canais espectrais e  $N_p$  o número de camadas atmosféricas em diferentes níveis de pressão  $p$ . Após definida a condição para a Equação 4.76,  $dE/dt < 0$ , o conjunto de equações diferenciais é definido (SEBASTIÃO *et al.*, 2003):

$$\frac{du_i}{dt} = - \sum_{j=1}^{N_\lambda} \frac{\partial K_{ij}}{\partial T_i} e_j \quad (4.78)$$

obtendo-se a temperatura  $T_i$  relacionada ao estado variável pela função de ativação:

$$T_i(u) = \tanh(u_i(t)). \quad (4.79)$$



## CAPÍTULO 5

### DISPOSITIVOS LÓGICOS PROGRAMÁVEIS

Vários problemas requerem processamento em tempo-real devido à importância de se apresentar uma solução no menor tempo possível, principalmente quando a quantidade de informações a ser avaliada é grande ou quando estas informações são essenciais para processamentos seguintes. Muitos destes problemas requerem que as soluções sejam embarcadas como, por exemplo, em robótica e navegação autônoma (AZOUAOUI; CHOIRA, 2002), (LI *et al.*, 2003), (KUMAR *et al.*, 2006), (BOLUDA; PARDO, 2003), processamento de imagens em reconhecimento de impressões digitais (HSIAO *et al.*, 2006), sistema de fluxo ótico (DIAZ *et al.*, 2007), sistemas de reconhecimento de faces (GOTTUMUKKAL *et al.*, 2006), imagens médicas (DILLINGER *et al.*, 2006), (LEONG *et al.*, 2006), (LEESER *et al.*, 2005), entre muitas outras. Uma implementação em hardware, além de oferecer o processamento em tempo-real, possibilita que a solução seja embarcada.

Nos últimos anos, vários modelos de redes neurais artificiais têm sido configurados em hardware. O termo "configuração" do dispositivo é utilizado em lugar de "programação" para evitar uma confusão com as linguagens de software. O interesse destas implementações justifica-se por algumas características das redes neurais artificiais como: intrínseco processamento paralelo, baixo custo computacional e capacidade de adaptação. As implementações em software realizadas em máquinas convencionais de Von Neumann (ver Patterson e Hennessy (2000)) são úteis para investigar as capacidades das redes neurais. Já as configurações em hardware exploram seu paralelismo inerente e modularidade, sendo úteis para aplicações que requerem processamento em tempo-real e/ou embarcados. O paralelismo se dá devido a possibilidade dos neurônios da mesma camada serem processados simultaneamente. E o aspecto de modularidade se refere a todo neurônio da rede neural realiza o mesmo tipo de computação, ou seja, toda arquitetura da rede pode ser dividida em módulos computacionais básicos.

Um dos objetivos deste trabalho é mostrar a viabilidade da implementação em hardware de RNAs na solução do problema inverso para estimação de perfis verticais de temperatura da atmosfera a partir de informações de dados de satélites. Interessa aos meteorologistas que a solução deste problema seja feita no menor tempo possível, devido à grande quantidade de dados disponibilizados pelos satélites e pela

necessidade de se obter as informações necessárias a serem utilizadas nos modelos numéricos de previsão do tempo. O baixo custo computacional e a miniaturização apresentados pela implementação possibilitam que o sistema seja embarcado em satélites, enviando medidas atmosféricas já inferidas, disponibilizando os dados a qualquer estação de solo e liberando cargas computacionais utilizadas para este fim nos centros de previsão numérica do tempo.

O rápido aperfeiçoamento do hardware reconfigurável dos dispositivos lógicos programáveis, juntamente com a utilização de ferramentas de software, tem simplificado e acelerado todo o ciclo de desenvolvimento de projetos. Estes avanços tecnológicos também têm incentivado o emprego de FPGA (Field-Programmable Gate Array) na implementação de redes neurais artificiais. Neste trabalho são estudadas a implementação neste dispositivo e a utilização da linguagem de descrição de hardware.

A vantagem de se usar VHDL dá-se pela flexibilidade de implementação, além de ser uma linguagem padrão (IEEE 1076) e independente da ferramenta de desenvolvimento, ou seja, com uma mesma descrição de projeto, muitas arquiteturas de dispositivos podem ser incluídas. Nas seções seguintes uma breve descrição dos dispositivos lógicos programáveis e das linguagens de descrição de hardware são apresentadas.

## **5.1 Dispositivos FPGA**

Os hardwares modernos são baseados em pequenas peças de silício que funcionam como circuitos lógicos eletrônicos chamados de circuitos integrados. Alguns tipos são: os dispositivos de memória; microprocessadores; Dispositivos Lógicos Programáveis (PLD); Circuitos Integrados de Aplicação-Específica (ASICs); Partes Padrão de Aplicação-Específicas (ASSPs) e FPGAs.

Os PLDs são dispositivos cuja arquitetura interna é definida pelos fabricantes, mas podem ser configurados pelo usuário para realizar uma variedade de tarefas. Diferentemente dos dispositivos FPGA, contêm um número limitado de portas lógicas, sendo aplicados a projetos menores e mais simples. Os dispositivos ASICs e ASSPs podem conter milhões de portas, podendo ser usados para realizar funções complexas. No entanto, são projetados por encomenda para endereçar uma aplicação específica. Embora disponibilizem grandes capacidades em tamanho, complexidade

e desempenho, projetá-los e construí-los são processos custosos, além de não permitirem modificações após suas implementações. (MAXFIELD, 2004).

Os dispositivos FPGA estão entre os PLDs e ASICs. Tal como os dispositivos PLDs, podem ser programados em "campo" pelo usuário e como os ASICs, podem conter milhões de portas lógicas, usados para implementar funções grandes e complexas. O custo de um projeto FPGA é muito menor quando comparado a um ASIC, além das mudanças dos projetos FPGA serem mais fáceis, reduzindo o tempo para lançar produtos finais. Assim, as FPGAs têm permitido que projetistas individuais ou pequenos grupos realizem projetos de hardware e software em plataforma de testes FPGA sem a necessidade de aquisição de ferramentas de alto custo associados a projetos ASICs (MAXFIELD, 2004).

FPGA são circuitos integrados digitais que contêm blocos ou células lógicas configuráveis, podendo ser programados via software. Esses blocos são interconectados, conexões estas que também são configuráveis. A FPGA comporta a implementação de circuitos lógicos relativamente grandes, consistindo em um arranjo destas células lógicas e interconexões, contidas num único circuito integrado. O termo programável vem do fato de que podem ser programadas em "campo", sem a necessidade de serem implementadas em fábricas especializadas, podendo ser realizadas em projetos de pesquisa, laboratórios de universidades ou pequenas empresas.

As FPGAs surgiram em meados dos anos 80, sendo usadas em funções não muito complexas e processamentos relativamente limitados. O aumento na capacidade e sofisticação começaram nos anos 90 com mercados nas áreas de telecomunicações e área de redes de computadores, envolvendo grandes blocos de processamento de dados. No final dos anos 90 são usadas em aplicações automotivas e industriais. Nos anos 2000, as FPGAs contêm milhões de portas lógicas e podem ser aplicadas nas mais diversas áreas, segundo (MAXFIELD, 2004), ocupando alguns dos maiores segmentos do mercado: ASIC, DSP (Processador de Sinais Digitais) e aplicações de microcontrolador.

Com o aumento da capacidade das FPGAs, uma grande variedade de projetos, antes somente implementados em ASIC, podem ser realizados. Além disso, algumas FPGAs contendo multiplicadores embutidos, aritmética dedicada e grandes quantidades de memória RAM (memória de acesso aleatório) facilitam operações DSP. Os microcontroladores embutidos realizam pequenas funções de controle. Estes

dispositivos de baixo-custo contêm programas, instruções de memória, relógio e periféricos de entrada/saída. Com a miniaturização e diminuição dos custos, as FPGAs têm se tornado atrativas para implementação. Uma descrição detalhada pode ser obtida em (MAXFIELD, 2004).

FPGAs são bastante usadas para implementações de protótipos e na apresentação de plataformas em hardware para testar implementações físicas de novos algoritmos. No entanto, seu baixo custo de desenvolvimento e otimização no tempo de projeto têm aumentado o número de produtos finais.

Os dispositivos FPGA consistem de um grande arranjo de células configuráveis que podem ser utilizadas para implementação de funções lógicas. São compostos por três elementos básicos:

- um conjunto de blocos lógicos ou células lógicas (CLB);
- chaves de conexão (SB) e
- blocos de entrada/saída.

Na Figura 5.1 apresenta-se funcionalidades dos blocos lógicos, assim como as chaves de conexão, são configuráveis por software. Estes blocos formam uma matriz bidimensional. Em seu interior existem diferentes modos para implementação de funções lógicas como, por exemplo, Tabela de Busca (LUT - Look-up Table), que contêm células que são utilizadas para implementar pequenas funções lógicas. Na Figura 5.2 são apresentadas as chaves de conexão que são organizadas em canais de comunicação horizontal e vertical entre as linhas e colunas dos blocos lógicos. Esses canais de comunicação possuem chaves de conexão programáveis que permitem conectar os blocos lógicos de acordo com as necessidades.

Uma característica é que as células de armazenamento e LUTs de um FPGA são voláteis, havendo perda do conteúdo de armazenamento na falta de suprimento de energia, gerando a necessidade da reprogramação do dispositivo toda vez que houver falta de energia. Geralmente uma memória EEPROM (Memória Somente de Leitura Apagada e Programada Eletricamente) é utilizada para carregar automaticamente as células lógicas.

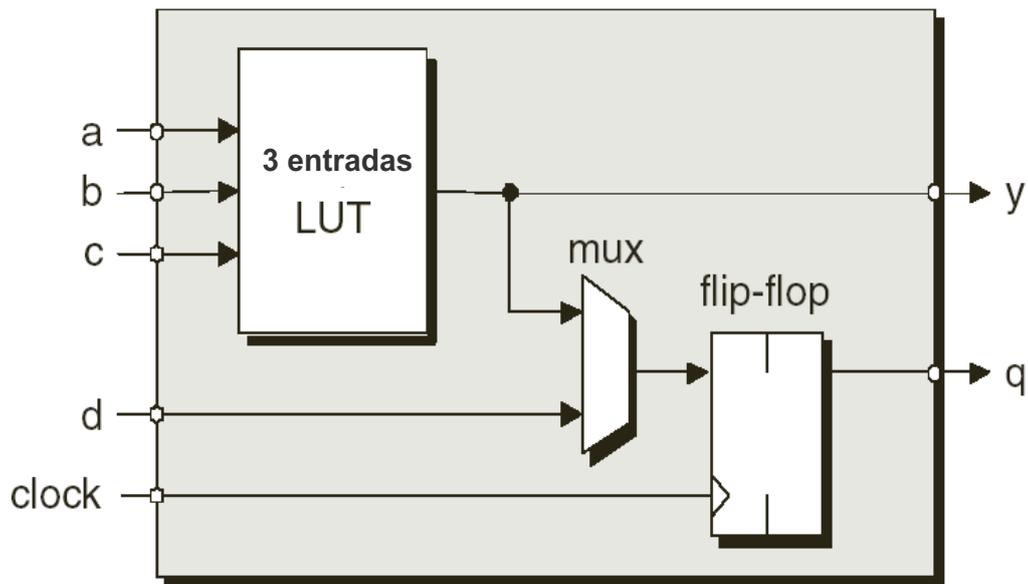


Figura 5.1 - Elementos formando um único bloco lógico programável. Fonte: Maxfield, 2004.

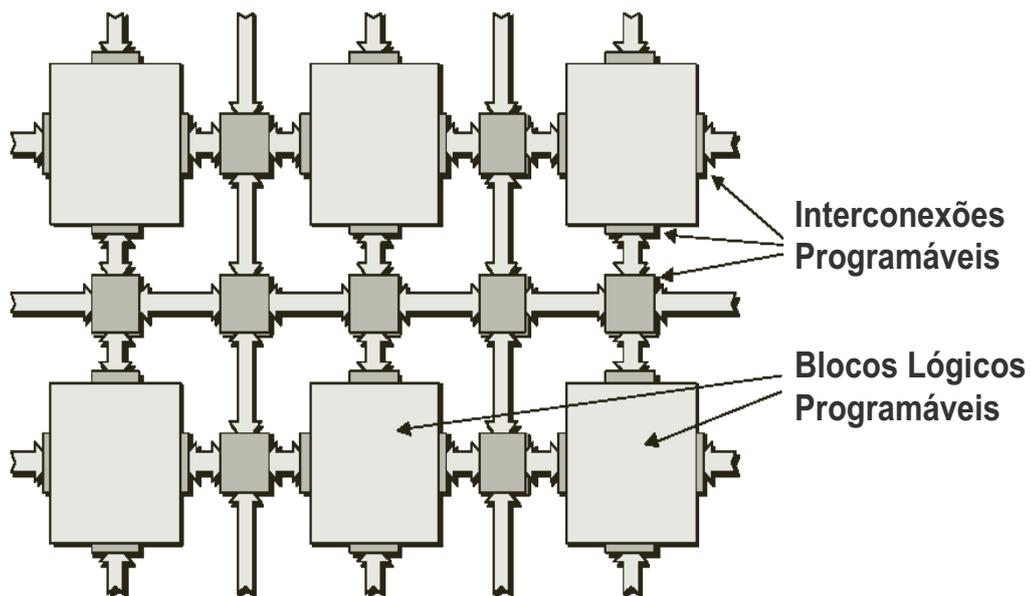


Figura 5.2 - Visão de cima para baixo de uma arquitetura FPGA genérica. Fonte: Maxfield, 2004.

## 5.2 Implementação utilizando Dispositivos Lógicos Programáveis

Os dispositivos lógicos programáveis são implementados através de ferramentas de Automação de Projeto Eletrônico (EDA). Em geral, essas ferramentas para programação de dispositivos lógicos programáveis englobam as seguintes tarefas:

- entrada do projeto;

- simulação funcional e
- programação no dispositivo.

Existem algumas ferramentas computacionais usuais e apropriadas para gerar a entrada do projeto. Alguns projetistas preferem a entrada através do esquemático, enquanto outros preferem linguagens de descrição de hardware como Verilog, VHDL, Handle-C, entre outras. No final dos anos 80, com o crescimento de projetos em tamanho e complexidade, fluxos ASICs baseado em esquemático começaram a diminuir. Além disso, o fato de captura de um grande projeto ao nível de porta de abstração é propenso a erros e também consome muito tempo. Assim alguns fornecedores de Automação de Projeto Eletrônico (EDA do inglês Electronic Design Automation) começaram a desenvolver ferramentas e fluxos baseados no uso de Linguagem de Descrição de Hardware (HDL). A funcionalidade de um circuito digital pode ser representada por diferentes níveis de abstração e diferentes HDLs para extensões maiores ou menores ([MAXFIELD, 2004](#)).

Na verificação funcional, a lógica é testada através da simulação do funcionamento completo do circuito, sendo realizada em vários níveis da implementação. Os projetos podem ser programados no dispositivo através de uma variedade de ferramentas e fluxos. Essas técnicas geram um arquivo de configuração contendo informações e este arquivo pode ser carregado nos dispositivos FPGA, se for programado para realizar funções específicas. Os primeiros dispositivos FPGAs faziam uso da chamada porta de configuração, que ainda hoje é amplamente usada por ser relativamente simples e bem entendida. Uma descrição detalhada deste procedimento é apresentada em ([MAXFIELD, 2004](#)). No entanto, técnicas mais sofisticadas estão disponíveis para que estes arquivos sejam carregados nos dispositivos FPGA, por exemplo, a interface JTAG (em inglês Joint Test Action Group), conhecida pelo padrão IEEE1149.1. Este padrão surgiu devido à necessidade de testar placas de circuitos impressos, que se tornaram muito complexas, devido a avanços na tecnologia e diminuição no tamanho das placas. Logo, os métodos tradicionais de testes começaram a aumentar os custos de desenvolvimento destes circuitos. Em 1980, a especificação JTAG foi apresentada para varredura de borda (BST - do inglês boundary-scan test) oferecendo a capacidade de testar componentes de placas de circuito impresso consumindo pouco espaço. Muitos dispositivos modernos, incluindo FPGAs, são equipados com portas JTAG, pelas quais o arquivo de configuração é carregado ([MAXFIELD, 2004](#)).

Apesar de existirem outras arquiteturas, a maioria dos computadores existentes hoje são máquinas Von Neumann, sendo classificadas como tal, quando:

- há três subsistemas de hardware básicos:
  - uma CPU (Unidade Central de Processamento);
  - uma memória principal e
  - um sistema de entrada/saída;
- o programa é armazenado, a memória principal contém o programa que controla a operação do computador e o computador pode manipular seu próprio programa;
- as instruções são executadas sequencialmente e
- tem um único caminho entre o sistema de memória principal e a unidade de controle da CPU.

As máquinas convencionais de Von Neumann têm um caminho para endereços e um segundo para dados e instruções. Uma outra arquitetura, que é como uma classe das máquinas Von Neumann é similar aos computadores convencionais mas tem caminhos diferentes para endereços, dados, endereço de instruções e instruções, permitindo o acesso à CPU e aos dados simultaneamente.

Tradicionalmente, as redes neurais são implementadas em software, treinadas e simuladas em computadores seqüenciais do tipo Von Neumann. Embora algumas implementações de redes neurais sejam dedicadas em sistemas de hardware, as implementações têm crescido devido a maior flexibilidade na modificação estrutural e diminuição dos custos com a utilização de FPGAs, que oferecem velocidades comparáveis a hardware dedicado e aceleração dos algoritmos paralelos. O ambiente em hardware baseado em FPGA é capaz de implementar diferentes arquiteturas, topologias e grandes RNAs num único dispositivo.

A principal razão do avanço em lógica programável está na miniaturização da tecnologia de fabricação dos componentes que, segundo a lei de Moore, duplicam a cada 18 meses.

### 5.3 VHDL

Existem diferentes ferramentas para projeto de sistemas digitais. Uma delas é a ferramenta de projeto auxiliado por computador (CAD), que suporta todas as etapas do projeto digital: (1) descrição (especificação), (2) projeto (síntese) para diminuir o custo e melhorar o desempenho e (3) verificação (por simulação ou formalmente).

A descrição é feita de uma forma gráfica, fornecendo um diagrama lógico do sistema em diferentes níveis, mostrando os módulos e suas interligações. Há ferramentas que permitem gerar e editar através de esquemáticos. Uma outra abordagem é o uso de linguagem de descrição de hardware (HDL). Duas principais padronizações da linguagem é a Verilog e VHDL. As duas abordagens CAD e HDL podem coexistir, através de ferramentas que convertem uma descrição em HDL para o esquemático e de esquemático para HDL (ERCEGOVAC *et al.*, 2000).

As ferramentas de síntese e otimização são empregadas na implementação a partir da descrição e são úteis para melhorar algumas características como, por exemplo, o número de módulos e os retardos da rede (ERCEGOVAC *et al.*, 2000).

As ferramentas de simulação são usadas para verificar a operação do sistema, empregando-se a descrição do sistema, sendo úteis para detectar erros do projeto e determinar características como retardos e consumo de energia.

A linguagem VHDL foi desenvolvida como uma ferramenta de projeto e documentação para o projeto de Circuito Integrado de Velocidade Muito Alta (VHSIC - do inglês Very High Speed Integrated Circuit) do Departamento de Defesa dos Estados Unidos no início dos anos 80. Após a remoção de algumas instruções por parte do departamento de defesa, a linguagem foi apresentada em 1985. No ano de 1987, foi apresentado o pacote padrão IEEE-1076-1987 para a linguagem e, após a padronização, foram apresentados pelo IEEE o pacote 1164 e o pacote 1076.3. No pacote padrão 1164 .3 são definidas funções que realizam operações com tipos de dados inteiros ou reais.

Na implementação que utiliza VHDL, deve-se considerar que todos os comandos são executados concorrentemente, significando que a ordem de apresentação dos comandos é irrelevante para o comportamento da descrição. A ocorrência de um evento em um sinal leva à execução de todos os comandos sensíveis ao sinal, da mesma forma que um circuito, no qual a mudança de um valor em um determinado

nó afeta todas as entradas ligadas a este ponto. Um exemplo de execução conjunta é apresentado na Figura 5.3.

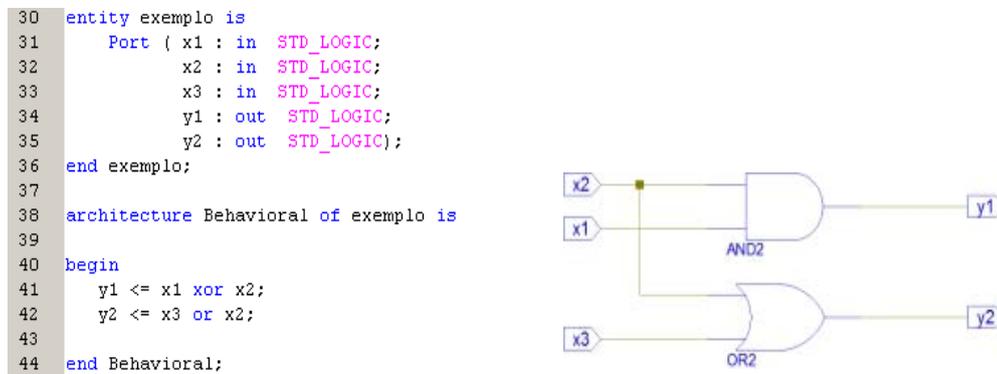


Figura 5.3 - Concorrência de uma descrição. Fonte: Adaptado de d'Amore, 2005.

A entidade, do inglês "entity", apresentada no exemplo da Figura 5.3 pode representar desde uma porta lógica a um sistema completo, sendo composta de declaração da entidade e arquitetura. A declaração da entidade define a interface entre a entidade e o ambiente exterior, por exemplo, entradas/saídas. A arquitetura contém a especificação das relações entre a entidade e as entradas e saídas. Uma descrição completa e abrangente da linguagem VHDL é apresentada em (D'AMORE, 2005)



## CAPÍTULO 6

### IMPLEMENTAÇÃO E RESULTADOS

Neste capítulo são avaliados os diferentes modelos de redes neurais empregados para a obtenção da solução do problema inverso na recuperação de dados atmosféricos a partir de medidas obtidas por diferentes sensores de radiâncias e satélites. A metodologia seguida nesta tese para a avaliação dos modelos é apresentada na Figura 6.1, e detalhada nas próximas seções.

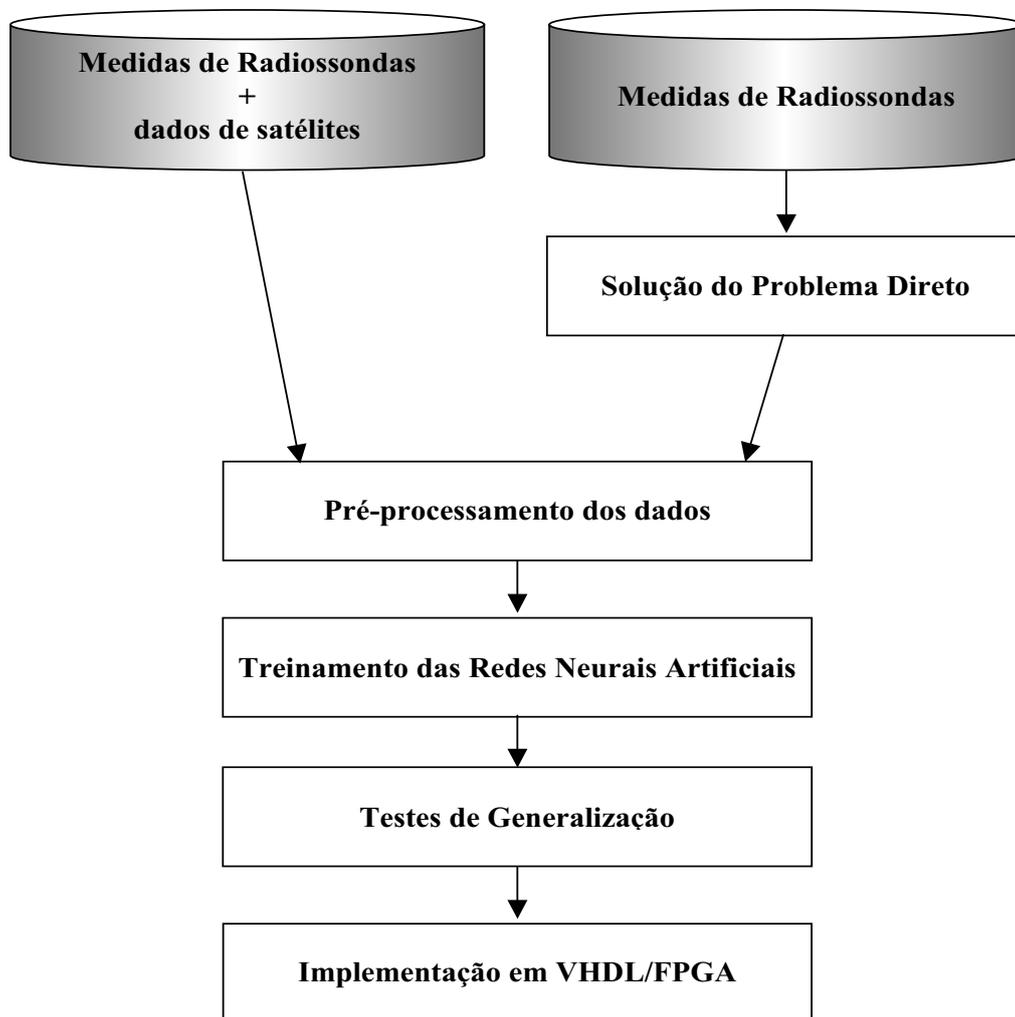


Figura 6.1 - Metodologia

A fim de validar o emprego das RNAs, fez-se uso de dados atmosféricos de diferentes regiões do globo, dados do Brasil e dados sintéticos, obtidos por medidas de

radiossondas e de radiâncias por satélites e resultados numéricos de radiâncias geradas pela solução ETR. Os dados atmosféricos medidos por radiossondagem são utilizados com radiâncias coincidentes com as medidas realizadas pelos satélites. No entanto, há uma carência destes dados, uma vez que o lançamento da radiossonda deve coincidir com a passagem do satélite. Em razão da existência de poucos dados, conjuntos de dados são gerados, aplicando-se o modelo direto em bancos de perfis atmosféricos obtidos por radiossondagens ao redor do mundo e no Brasil. Os dados sintéticos são radiâncias geradas a partir de alguns perfis de temperatura medidos por radiossondas no Brasil pela Equação 2.16 e adicionando um ruído gaussiano para simular radiâncias medidas no satélite.

Para apresentação desses dados às redes neurais, é necessário um pré-processamento para que os dados sejam normalizados em relação à faixa de ativação das redes neurais. Para aumentar a robustez da generalização das redes, são adicionados ruídos aos dados que, em seguida, são divididos em subconjuntos de treinamento, generalização e um terceiro para ser utilizado como condição de parada pela validação cruzada (PRECHELT, 1994),(HAYKIN, 1994). O primeiro e o último conjunto de dados são utilizados na fase de treinamento da rede e o de generalização na fase de testes de desempenho.

O treinamento é a fase de maior custo computacional, quando se usam redes neurais. Destaca-se que esse processamento é realizado sem conexão com o processo de estimação dos dados atmosféricos. Para avaliar o desempenho da metodologia, as redes neurais são submetidas a testes de generalização, onde dados não utilizados no treinamento são apresentados.

Por fim, os pesos e limiares obtidos na fase de treinamento e testados na generalização são implementados em linguagem de descrição de hardware. A rede é simulada e avalia-se a implementação nos dispositivos lógicos programáveis.

## 6.1 Medidas de Radiossondas

Através de trabalhos conjuntos com a Divisão de Satélites e Sistemas Ambientais (DSA) do INPE foram utilizados dados dos bancos TIGR (do inglês TOVS Initial Guess Retrieval), NESDISPR (National Environmental Satellite, Data, and Information Service) e CLASS1 juntamente com soluções do modelo direto obtidas pelo código de transferência radiativa de processamento rápido, o RTTOV (do inglês

fast Radiative Transfer model for ATOVS). Estes bancos de dados têm sido usados em modelos no Centro de Previsão de Tempo e Estudos Climáticos (CPTEC)/INPE (MACEDO; CEBALLOS, 2004) (SOUZA *et al.*, 2004). O TIGR (do inglês TOVS Initial Guess Retrieval) - TOVS (do inglês TIROS Operational Vertical Sounder) - TIROS (do inglês Television Infrared Observation Satellite) e banco NESDISPR contêm dados globais, enquanto o CLASS1 (MACEDO; CEBALLOS, 2004) contém dados do Brasil. A utilização dos dados globais para o treinamento da rede neural resulta na estimação de perfis de temperatura de diferentes regiões do planeta, portanto a metodologia pode ser aplicada a parte do mundo. Já o uso do banco CLASS1 torna a metodologia especializada para as regiões do Brasil. As características destes bancos são apresentados na Tabela 6.1. Os dados globais são compostos por perfis de todo o globo, enquanto o CLASS1 exclusivamente com dados do Brasil.

Tabela 6.1 - Bancos de dados atmosféricos

Banco	Número de Perfis	Regiões
TIGR	1761	Global
NESDIS-PR	1205	Global
CLASS1	657	Brasil

O conjunto de dados TIGR é uma biblioteca representativa de situações atmosféricas, selecionada através de métodos estatísticos de 80.000 medidas de radiossondas TIGR (CHEDIN *et al.*, 1985), (TIGR, 2006). Cada situação é descrita por sua temperatura, vapor d'água e perfis de ozônio em 40 níveis de 1013 hPa a 0,05 hPa. As situações no TIGR são divididas por uma classificação hierárquica em 5 tipos: tropical, temperado (médias latitudes-1), temperado frio e verão polar (médias latitudes-2), hemisfério Norte polar muito frio (polar-1) e inverno polar (polar-2). As situações são transmitâncias de céu limpo, temperatura e Jacobianos (derivadas parciais de temperatura de brilho com relação à temperatura, concentração de gás para H<sub>2</sub>O, O<sub>3</sub>, CO<sub>2</sub>, etc., temperatura de superfície e emissividade, etc). O banco foi elaborado pelo Laboratoire de Météorologie Dynamique - LMD, na França (CHEDIN *et al.*, 1985). A versão utilizada do banco TIGR contém:

- 322 tropical;
- 388 média latitude-1;
- 354 média latitude-2;
- 104 polar-1;

- 593 polar-2.

O banco NESDISPR é um banco com perfis globais disponibilizado pela NOAA/NESDIS. Assim como o banco TIGR, o NESDISPR é utilizado no sistema ICI para recuperação de perfis verticais de temperatura e umidade da atmosfera na geração de perfis iniciais (ICI, 2006) (MACEDO; CEBALLOS, 2004).

O CLASS1 é um banco de dados contendo perfis de temperatura e umidade, elaborado com a mesma estrutura do banco TIGR, porém com radiossondagens exclusivamente brasileiras. Foi objeto da dissertação de mestrado de Macedo e Ceballos (2004). O banco foi derivado de 32000 perfis de radiossondagens que foram classificados segundo suas similaridades, resultando elementos representativos com diferentes condições atmosféricas de temperatura e umidade. Um método iterativo foi utilizado para agrupar populações utilizando critério de semelhança, à distância Euclidiana, resultando num banco composto por 657 perfis.

Na Figura 6.2 são apresentados as médias dos perfis e desvios padrão dos três bancos de perfis, pertencente respectivamente aos bancos TIGR, NESDISPR e CLASS1.

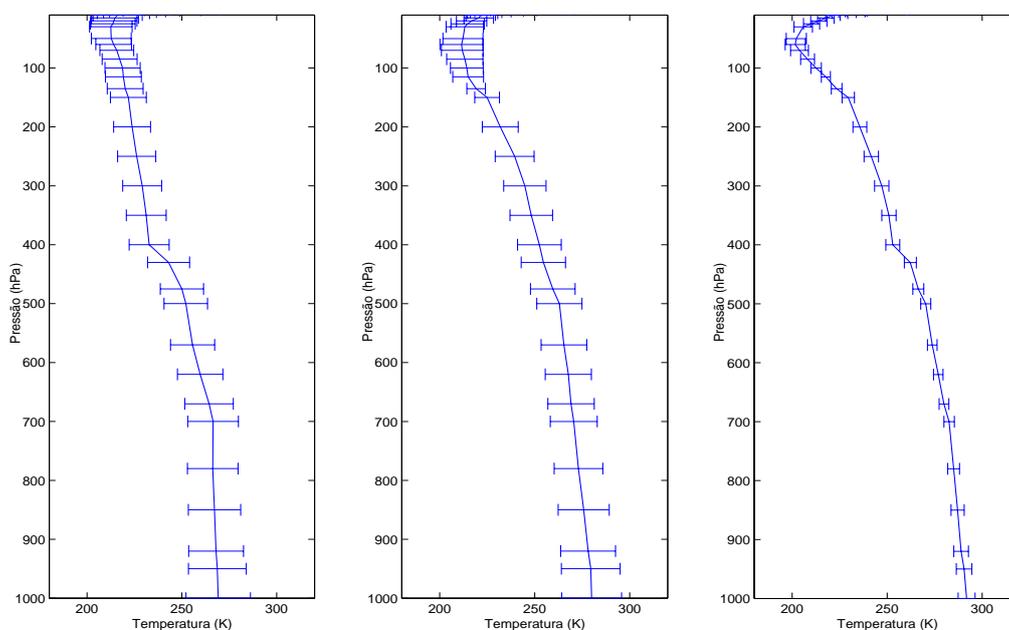


Figura 6.2 - Média das temperaturas dos bancos e seus desvios padrão

## 6.2 Solução do Problema Direto

Em função da ausência de dados experimentais, uma solução simples é a utilização do modelo direto para, a partir de dados de radissondagem, gerar radiâncias correspondentes. Neste trabalho o problema direto é resolvido de duas maneiras: a primeira, aproximando a Equação 2.16 por diferenças finitas, e a segunda, utilizando um modelo utilizado no CPTEC/INPE, o modelo RTTOV.

A aplicação da solução está na formação dos subconjuntos de treinamento, validação e generalização das redes neurais com aprendizagem supervisionada. Nas redes com aprendizagem não-supervisionada não são utilizados os dois primeiros subconjuntos.

Numa primeira fase do trabalho, o problema direto foi resolvido pelo método de diferenças finitas, seguindo-se a mesma metodologia realizada em (CARVALHO, 1998). Para comparação das metodologias de solução do problema inverso, o mesmo estudo de caso foi usado, empregando dados medidos por radiossondagem combinados com a passagem de satélite. Foram utilizadas transmitâncias padrão obtidas da literatura (LIOU, 1982) (CARVALHO, 1998). Os canais estão associados à banda de absorção do CO<sub>2</sub> centradas em 15  $\mu m$  e são distribuídos de modo a fazer uma cobertura vertical da atmosfera. Os primeiros canais estão associados aos níveis mais altos da atmosfera, enquanto os últimos aos mais baixos.

A Equação 2.16 é resolvida aproximadamente, usando diferenças finitas centrais (CARVALHO, 1998):

$$I_i = B_{i,s}(T_s)\mathfrak{S}_{i,s} + \sum_{j=1}^{N_p} \left( \frac{B_{i,j} + B_{i,j-1}}{2} \right) [\mathfrak{S}_{i,j} - \mathfrak{S}_{i,j-1}] \quad (6.1)$$

onde  $i = 1, \dots, N_\lambda$ ;  $I_i \equiv I_{\lambda_i}$ ;  $B_{i,j} = B_{\lambda_i}(T_j)$ ;  $\mathfrak{S}_{i,j} = \mathfrak{S}_{\lambda_i}(p_j)$ ;  $\mathfrak{S}_{i,s}$  a transmitância do canal  $i$  na superfície  $s$ ; e  $N_p$  é o número de camadas atmosféricas consideradas. Assume-se que cada camada atmosférica tem uma temperatura característica  $T_j$  a ser calculada.

Um exemplo de solução do problema direto é apresentado na Figura 6.3. A Figura 6.3-a) apresenta o perfil de temperatura medido por radiossondagem em 40 camadas e 6.3-b) os valores das radiâncias em 7 canais gerados pelo modelo direto.

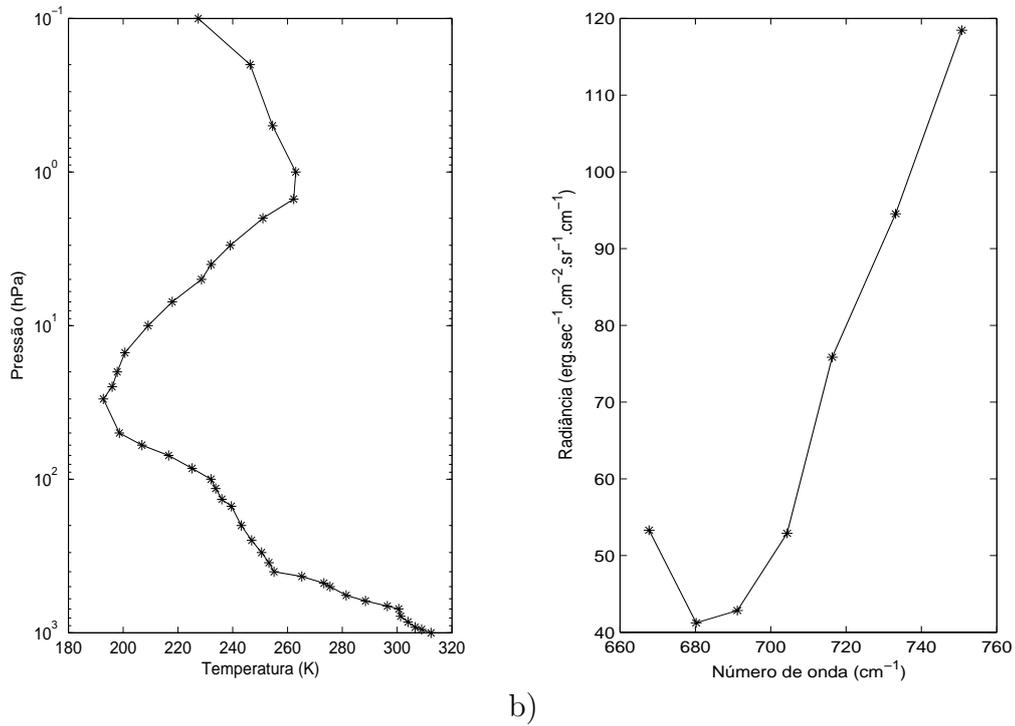


Figura 6.3 - Exemplo da solução da ETR (a) temperatura e (b) radiância

Em seguida, os dados experimentais que, intrinsecamente contêm erros em aplicações reais, são simulados adicionando-se ruído gaussiano à solução exata do problema direto:

$$I = I_{exato} + \sigma\mu \quad (6.2)$$

onde  $\sigma$  é o desvio padrão do ruído e  $\mu$  é uma variável aleatória com distribuição gaussiana, assim como realizado em [Carvalho \(1998\)](#). Na ocorrência de nuvens, este modelo matemático para esta janela espectral não pode ser usado.

### 6.3 Pré-processamento dos dados

Inicialmente, os valores na entrada devem ser normalizados para valores no intervalo da função de ativação das unidades de processamento da rede neural. Após o treinamento e a ativação da rede, deve ser feito o processo inverso para os intervalos originais das variáveis estimadas.

Os dados foram normalizados com base na observação dos valores máximos nos bancos de dados de temperatura e radiância, mais uma pequena porcentagem de tolerância de aproximadamente 5%.

## 6.4 Treinamento

As diferentes redes neurais empregadas neste trabalho foram treinadas com os bancos de dados globais e específicos do Brasil e considerados dados de diferentes sensores e satélites, variando-se: conjuntos de treinamento; funções de ativação e número de neurônios nas camadas escondidas. Os conjuntos de treinamento são usados pelo algoritmo de treinamento para o ajuste dos parâmetros, pesos e limiares da rede. Diferentes treinamentos foram realizados para os dados sintéticos, TIGR, NESDISPR e CLASS1, considerando-se diferentes sensores e satélites. Para estes treinamentos foram variados o número de neurônios na camada escondida e os tipos de funções de ativação. Um exemplo do par entrada/saída utilizado no treinamento é apresentado na Figura 6.4.

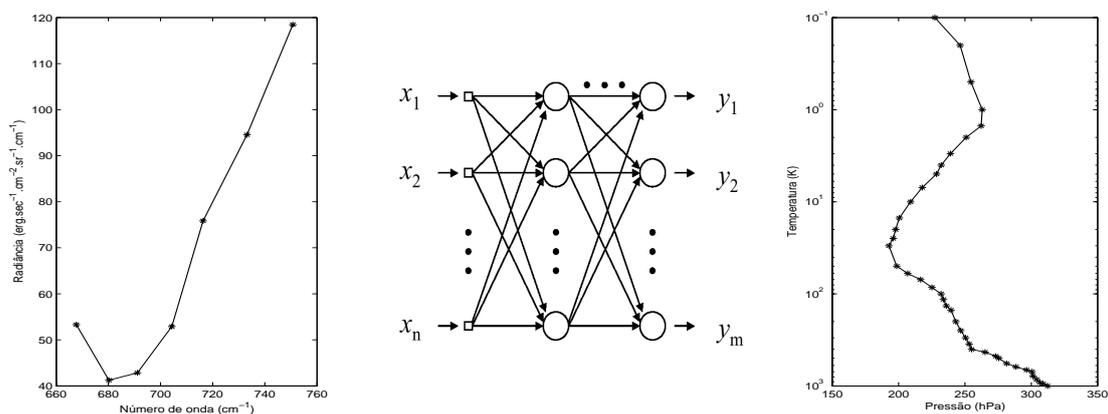


Figura 6.4 - Exemplo de uma par de treinamento.

## 6.5 Generalização

Na fase de generalização, o conjunto não utilizado na fase de treinamento é apresentado à rede para verificação de seu desempenho.

Uma vez treinada, validada e generalizada a rede neural, dados reais são apresentados para testes antes de ser implementada em linguagem de descrição de hardware. Nesta fase, as redes com aprendizagem não supervisionada também são testadas. Neste trabalho são comparadas todas as redes com aprendizagem supervisionada e não supervisionada.

## 6.6 Implementação em VHDL/FPGA

Como foi mencionado no Capítulo 5, existem formas diferentes de implementação em lógica programável. Uma delas é através da linguagem VHDL, que apresenta a vantagem de que o mesmo código seja implementado em diferentes dispositivos. Os dispositivos lógicos programáveis utilizados nesta tese são as FPGAs, que são reprogramáveis, diminuindo-se os custos de implementação. Embora algumas funções sejam aplicadas somente na simulação, o comportamento do hardware pode ser simulado antes de uma implementação no dispositivo FPGA, diminuindo-se o tempo de implementação.

## 6.7 Diferentes testes para análise da metodologia

Foram testadas diferentes situações para análise da metodologia, variando o sensor embarcado no satélite, número de canais espectrais, além de diferentes implementações da ETR para obtenção das radiâncias utilizadas nos treinamentos e testes. Essas variações são apresentadas nas Tabelas 6.2, 6.4 e 6.5. A primeira coluna indica o banco de dados atmosféricos utilizados, a segunda coluna o número de perfis do banco. Nas colunas 3 e 4, respectivamente tem-se, o sensor e o satélite, na 5 o número de canais espectrais utilizados, nas colunas 6 e 7, respectivamente, os níveis de pressão dos quais são estimados os dados atmosféricos e na última camada a forma de solução do modelo direto.

Foram reproduzidas e comparadas as estimações apresentadas em (CARVALHO, 1998), utilizando-se os canais espectrais do sensor HIRS do satélite NOAA-14, além dos mesmos perfis de transmitâncias e funções peso, onde o modelo direto foi resolvido pela Equação 6.1.

Um banco sintético de perfis de temperatura foi criado a partir de alguns perfis conhecidos do Brasil, resultando em 101 perfis (BD-1), para realizar os testes iniciais. Tal como utilizado em (CARVALHO, 1998), foram utilizados 7 canais espectrais e a temperatura foi estimada em 40 níveis da atmosfera. A coluna 1 apresenta o conjunto de dados, a coluna 2 o número de perfis de cada conjunto e a última coluna informações da origem dos perfis.

Estes parâmetros e dados também foram utilizados nos bancos TIGR. Parte do banco TIGR foi utilizado, sendo empregados 646 perfis selecionados aleatoriamente. Neste trabalho, o banco resultante da seleção é chamado de TIGR-P.

Um terceiro banco foi produzido pela junção dos dois primeiros bancos, o e BD-1+BD2. Para simular observações ruidosas dos satélites, estes três bancos foram contaminados com 5% de ruído gaussiano.

Tabela 6.2 - Experimentos com o HIRS/2 - NOAA-14

Banco	Perfis	Sensor	Satélite	Can. Util.	Níveis	Mod. Dir.
Sintéticos(BD-1)	101	HIRS/2	NOAA-14	7	40	Eq. 6.1
TIGR-P(BD-2)	646	HIRS/2	NOAA-14	7	40	Eq. 6.1
BD1+BD2	747	HIRS/2	NOAA-14	7	40	Eq. 6.1

O desempenho das redes neurais também foi testado com dados do HIRS/NOAA-16 globais e do Brasil, empregando-se os bancos TIGR, NESDISPR e CLASS1. O modelo direto foi resolvido pelo RTTOV-versão 7 e, assim como nos testes anteriores, as radiâncias foram contaminadas por ruídos aleatórios. Os ruídos foram gerados com distribuição gaussiana nos intervalos dos erros presentes nos canais de 1 à 12 do sensor HIRS/NOAA-16 (NOAA, 2004). Os valores dos intervalos apresentados na Tabela 6.3 em ( $\text{erg} \cdot \text{sec}^{-1} \cdot \text{cm}^{-2} \cdot \text{sr}^{-1} \cdot \text{cm}^{-1}$ ).

Tabela 6.3 - Erros de Medidas

Canal	Limite Inferior	Limite Superior
1	3,00000	5,19869
2	0,67000	1,38493
3	0,50000	1,20069
4	0,31000	0,82209
5	0,21000	0,65781
6	0,24000	0,64173
7	0,20000	0,40828
8	0,10000	0,11572
9	0,15000	0,23034
10	0,15000	0,44818
11	0,20000	0,32032
12	0,20000	0,44043

Tabela 6.4 - Experimentos com o HIRS/NOAA-16

Banco	Perfis	Sensor	Satélite	Can. Util.	Níveis	Mod. Dir.
NESDISPR(BD-3)	1205	HIRS	NOAA-16	12	40	RTTOV
CLASS1(BD-4)	647	HIRS	NOAA-16	12	40	RTTOV
TIGR-C(BD-5)	1761	HIRS	NOAA-16	12	40	RTTOV

O banco de dados resultante das junções dos bancos TIGR-C, NESDISPR e CLASS1 foi gerado com o intuito de, além de estimar perfis de temperatura, estimar perfis de umidade da atmosfera utilizando redes neurais. Resultando num banco de 3613 perfis, o sensor considerado foi o AIRS (do inglês Atmospheric Infrared Sounder) do satélite AQUA, seguindo trabalhos anteriores (SOUZA *et al.*, 2006).

Tabela 6.5 - Experimentos com o AIRS/AQUA

Banco	Perfis	Sensor	Satélite	Can. Util.	Níveis	Mod. Dir.
BD4+BD5+BD6	3613	AIRS	AQUA	149	40	RTTOV

## 6.8 Cálculo dos Erros

Uma vez que os dados foram normalizados antes de serem tratados pelas redes neurais, as estimações feitas pelas redes neurais devem passar pelo processo inverso, sendo realizada a multiplicação dos resultados obtidos pelo mesmo fator utilizado no processo de normalização. Os erros apresentados nas tabelas das próximas seções, referentes aos dados estimados são obtidos pela Raiz quadrada do Erro Médio Quadrático (REMQ) dado pela equação:

$$REMQ = \sqrt{\frac{1}{N_z} \sum_{i=1}^{N_z} (T_i^{\text{Modelo}} - T_i^{\text{Estimado}})^2} \quad (6.3)$$

onde  $T$  é a temperatura nas  $i = 1, 2, \dots, N_z$  camadas.

Os erros foram calculados em 5 subcamadas da atmosfera para análises mais detalhadas da eficiência nas estimações em regiões de maior interesse para a meteorologia, com a camada-1 [1000 hPa a 500 hPa]; camada-2 [500 hPa a 250 hPa]; camada-3 [250 hPa a 85 hPa]; camada-4 [85 hPa a 20 hPa] e camada-5 [15 hPa a 0.2 hPa], como apresentado na Figura 6.5. Seguindo a mesma metodologia do trabalho apresentado por Carvalho (1998), alguns pontos são amostrados nas subcamadas e assim denominados:

- **camada 1:** 500; 570; 620; 670; 700; 780; 850; 920; 950; 1000 hPa;
- **camada 2:** 250; 300; 350; 400; 430; 475 hPa;
- **camada 3:** 85; 100; 115; 135; 150; 200 hPa;
- **camada 4:** 20; 25; 30; 50; 60; 70 hPa e
- **camada 5:** 0.10; 0.20; 0.50; 1.0; 1.50; 2.0; 3.0; 4.0; 5.0; 7.0; 10.00; 15.00 hPa.

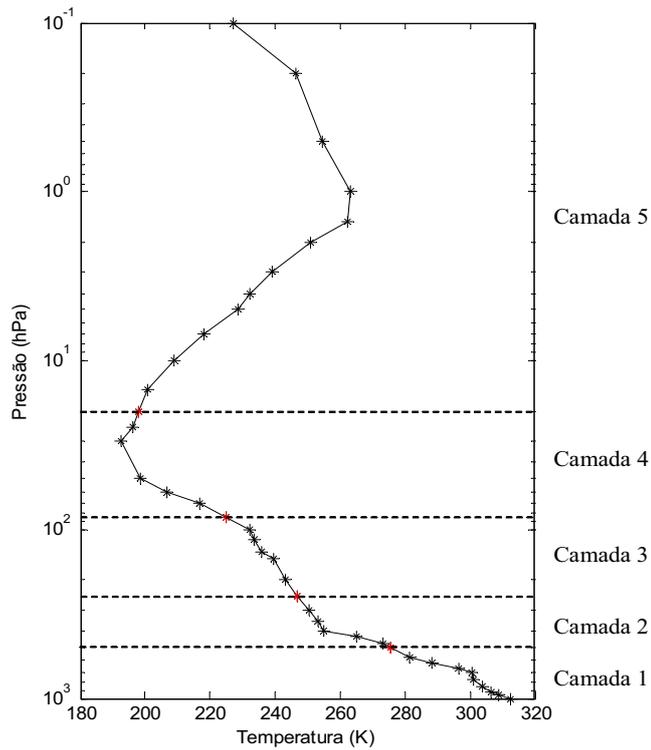


Figura 6.5 - Camadas para análise dos erros

Para comparar a capacidade de generalização das redes neurais, quando empregados diferentes subconjuntos de treinamento e validação, foram realizados 5 experimentos com ruídos gerados variando-se as sementes geradoras de valores pseudo-aleatórios e realizadas permutações aleatórias para diversificar os perfis atmosféricos utilizados. Este procedimento é ilustrado na Figura 6.6.

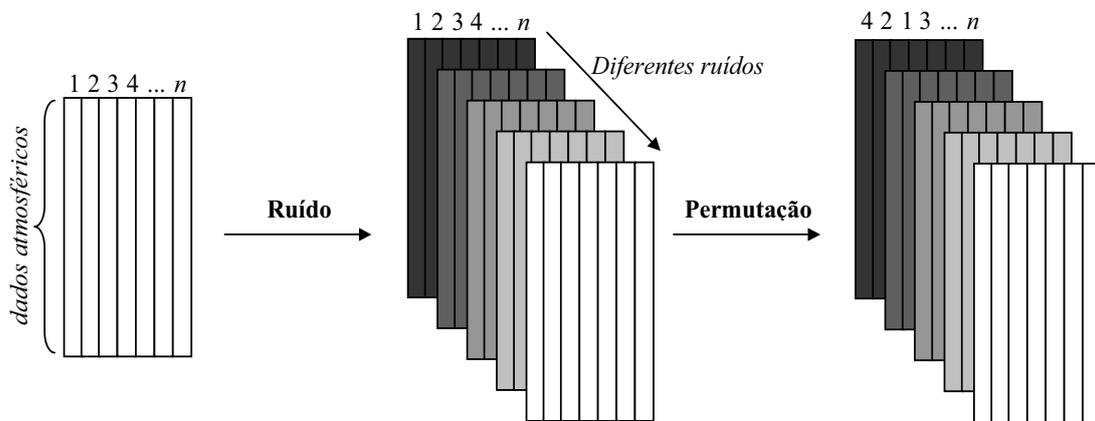


Figura 6.6 - Testes

## 6.9 Recuperação de dados atmosféricos utilizando a rede Perceptron de Múltiplas Camadas - RPMC

Como discutido na seção 6.7, foram variados os conjuntos de dados e sensores atmosféricos. O uso da rede tipo RPMC no processo de inversão considera 7 canais do sensor HIRS a bordo do satélite NOAA-14, 12 canais do sensor HIRS do NOAA-16 e 149 canais do sensor AIRS do satélite AQUA com os bancos sintéticos, TIGR-P, TIGR-C, NESDISPR e CLASS1. Uma única camada escondida é usada com funções de ativação do tipo logística sigmoidal, variando-se a quantidade de neurônios de 1 a 25.

### 6.9.1 Recuperação dos perfis verticais de temperatura com uso da RPMC - sensor HIRS/NOAA-14

Os resultados alcançados para a rede neural com dados do sensor HIRS/NOAA-14 são os empregados por (CARVALHO, 1998). Os testes foram realizados para comparação da metodologia quando utilizados dados medidos por satélite combinados com o lançamento de radiossonda. Os resultados estão publicados em Shigemori *et al.* (2004), Shigemori *et al.* (2005a) e Shigemori *et al.* (2006).

#### 6.9.1.1 Resultados utilizando-se o banco de dados sintéticos

Os resultados da validação e generalização podem ser assim resumidos: dados do sensor HIRS; satélite NOAA-14; perfis sintéticos; 7 canais espectrais; temperatura estimada em 40 níveis; número de neurônios na camada escondida variando entre 1 e 25; função de ativação logística sigmoidal nas camadas escondida e de saída; perfis no conjunto de treinamento: 150; número de perfis no conjunto de generalização 250; solução do modelo direto pela Equação 6.1.

Na Tabela 6.6 apresenta-se o valores médios das REMQ obtidos nos 5 experimentos nas camadas atmosféricas 1-5 e na Tabela 6.7, os desvios padrão dos erros. Os erros das temperaturas são apresentados em Kelvin, mostrando-se aceitáveis por serem inferiores a 3°K nas camada atmosféricas 1 e 2.

Tabela 6.6 - Média dos erros da generalização dos Dados Sintéticos

Neurônios	Camada 1	Camada 2	Camada 3	Camada 4	Camada 5
11	0,7172	0,8531	1,7400	0,9296	0,8696
12	0,5265	0,7136	1,1810	0,8731	0,6516
13	0,6111	0,7522	1,5754	0,9664	0,7537

Tabela 6.7 - Desvios padrão dos erros da generalização dos Dados Sintéticos

Neurônios	Camada 1	Camada 2	Camada 3	Camada 4	Camada 5
11	0,0254	0,0269	0,0227	0,0267	0,0144
12	0,0249	0,0217	0,0105	0,0283	0,0354
13	0,0227	0,0216	0,0139	0,0331	0,0396

Observou-se que os melhores resultados, utilizando-se o banco com dados sintéticos, foram obtidos empregando-se de 11 a 13 neurônios na camada escondida. Por esta razão somente os erros destas arquiteturas são apresentados. O melhor desempenho foi obtido empregando 12 neurônios na camada escondida. Pelos desvios padrão apresentados, observa-se que não há variações significativas nos experimentos iniciados com valores aleatórios diferentes.

Dois exemplos de inversões, dentre os 250 utilizados nos testes de generalização que representam o desempenho médio do processo de inversão são apresentados nas Figuras 6.7 e 6.8. Na Figura 6.7-a) são apresentados o perfil de temperatura estimado, representado pela linha contínua, e a medida de radiossondagem, tracejada. Na Figura 6.7-b) é apresentado o perfil de erro absoluto entre o perfil medido e o estimado. Na Figura 6.8 é apresentado outro exemplo de generalização, sendo obtidos com o emprego de 12 neurônios na camada escondida.

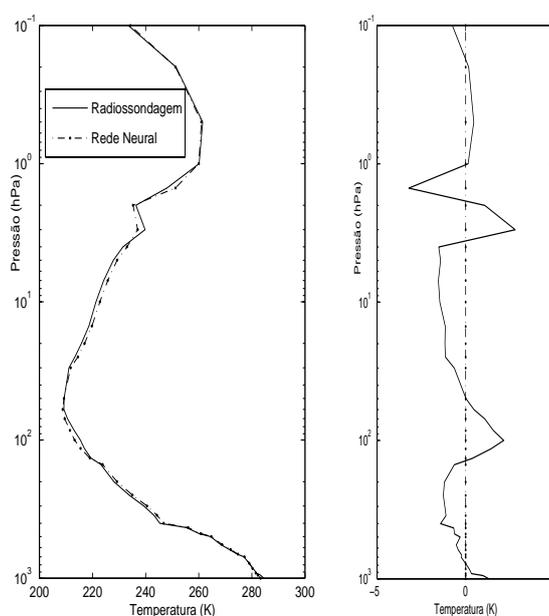


Figura 6.7 - Exemplo 1 (a) Perfil de temperatura obtido com a RPMC e o banco sintético, (b) erro da recuperação em relação à radiossondagem.

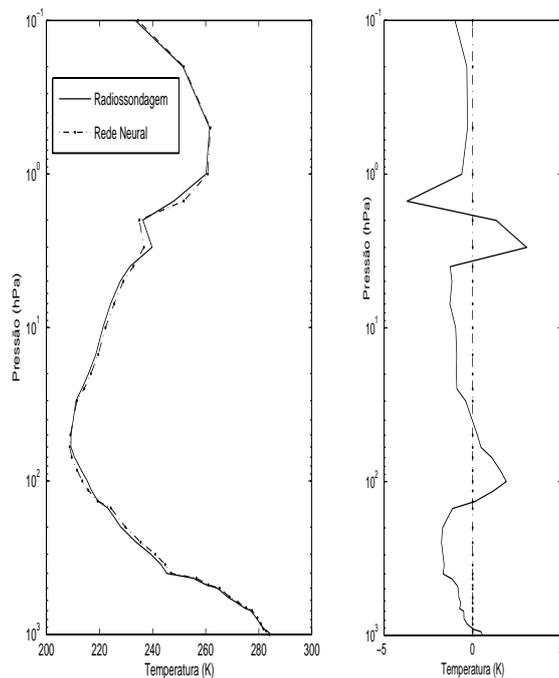


Figura 6.8 - Exemplo 2: (a) Perfil de temperatura obtido com a RPMC e o banco sintético, (b) erro da recuperação em relação à radiossondagem.

### 6.9.1.2 Resultados utilizando-se o banco TIGR-P

O uso de parte do banco de dados atmosféricos TIGR, contendo perfis de temperatura globais, pode ser assim resumido: dados do sensor HIRS; satélite NOAA-14; canais espectrais 7; temperatura estimada em 40 níveis; número de neurônios na camada escondida variando entre 1 e 25; função de ativação logística sigmoidal nas camadas escondida e de saída; número de perfis no conjunto de treinamento: 323; número de perfis no conjunto de generalização 250; solução do modelo direto, Equação 6.1.

No treinamento, os melhores resultados foram obtidos empregando-se de 6 a 8 neurônios na camada escondida. Na Tabela 6.8 apresenta-se a média dos erros das inversões de 250 perfis não utilizados na fase de treinamento, e na Tabela 6.9 são apresentados os desvios padrão dos erros dos 5 experimentos.

Tabela 6.8 - Média dos erros da generalização do banco TIGR-P

Neurônios	Camada 1	Camada 2	Camada 3	Camada 4	Camada 5
6	1,2224	1,4434	2,1334	1,7168	1,9746
7	1,2239	1,4415	2,1349	1,7152	1,9690
8	1,2245	1,4443	2,1264	1,7204	1,9758

Tabela 6.9 - Desvios padrão da generalização do banco TIGR-P

Neurônios	Camada 1	Camada 2	Camada 3	Camada 4	Camada 5
6	0,1024	0,1110	0,1264	0,1224	0,0678
7	0,0997	0,1157	0,1293	0,1317	0,0755
8	0,0939	0,1094	0,1358	0,1278	0,0623

Assim como com a utilização da RPMC empregando os dados sintéticos, no emprego dos dados do banco TIGR-P, os perfis estimados são bem próximos aos desejados. Também não existem variações significativas nos diferentes experimentos realizados com diferentes sementes na geração do ruído aleatório, pesos iniciais e perfis de treinamento. O bom desempenho das inversões utilizando 7 neurônios na camada escondida é exemplificado através de duas inversões que, juntamente com seus perfis de erro, são apresentadas nas Figuras 6.9 e 6.10. Mesmo com uma maior variabilidade nos dados, a RPMC mostrou boa capacidade de generalização, apresentando resultados próximos aos desejados também com perfis mais abrangentes.

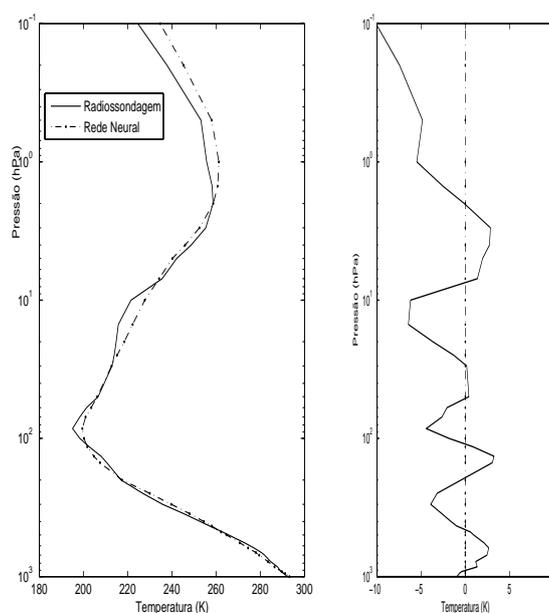


Figura 6.9 - Exemplo 1: (a) Perfil de temperatura obtido com a RPMC e o banco TIGR-P, (b) erro da recuperação em relação à radiossondagem.

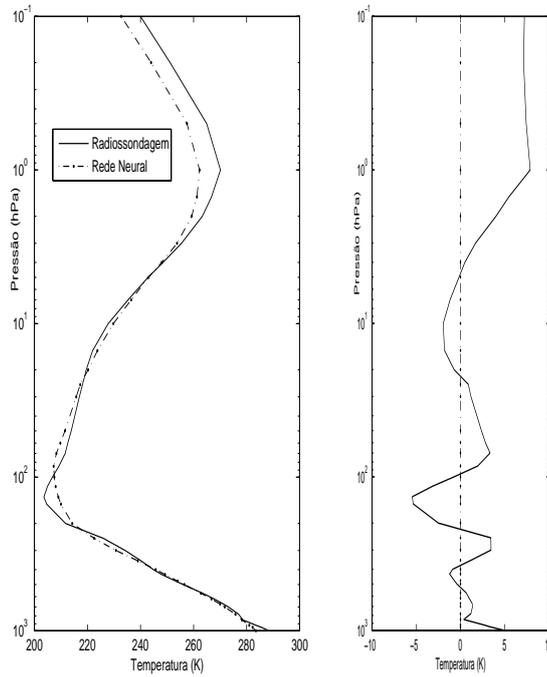


Figura 6.10 - Exemplo 2: (a) Perfil de temperatura obtido com a RPMC e o banco TIGR-P, (b) erro da recuperação em relação à radiosondagem.

### 6.9.1.3 Resultados utilizando-se o banco Sintético+TIGR-P

Testes foram realizados utilizando-se a junção dos dois bancos de dados atmosféricos anteriores, o sintético e o TIGR-P, sendo assim resumidos: dados do sensor HIRS; satélite NOAA-14; canais espectrais 7; temperatura estimada em 40 níveis; número de neurônios na camada escondida variando entre 1 e 25; função de ativação logística sigmoideal nas camadas escondida e de saída; número de perfis no conjunto de treinamento: 398; número de perfis no conjunto de generalização 348; solução do modelo direto Equação 6.1.

As médias das REMQ dos 348 perfis de temperatura, não utilizados na fase de treinamento, são apresentadas nas Tabela 6.10, divididas nas 5 camadas atmosféricas. Na Tabela 6.11 os desvios padrão dos erros. Dois exemplos das inversões, obtidos com 6 neurônios na camada escondida, são apresentados nas Figuras 6.11 e 6.12.

Tabela 6.10 - Média dos erros da generalização do banco sintético + TIGR-P

Neurônios	Camada 1	Camada 2	Camada 3	Camada 4	Camada 5
5	0,5604	0,8329	1,1396	0,9443	0,6958
6	0,5265	0,7136	1,1810	0,8731	0,6516
7	0,7546	1,4242	2,6157	1,3983	1,1610

Tabela 6.11 - Desvios padrão da generalização do banco sintético + TIGR-P

Neurônios	Camada 1	Camada 2	Camada 3	Camada 4	Camada 5
5	0,0132	0,0191	0,0238	0,0124	0,0214
6	0,0108	0,0194	0,0236	0,0192	0,0102
7	0,0085	0,0208	0,0212	0,0127	0,0141

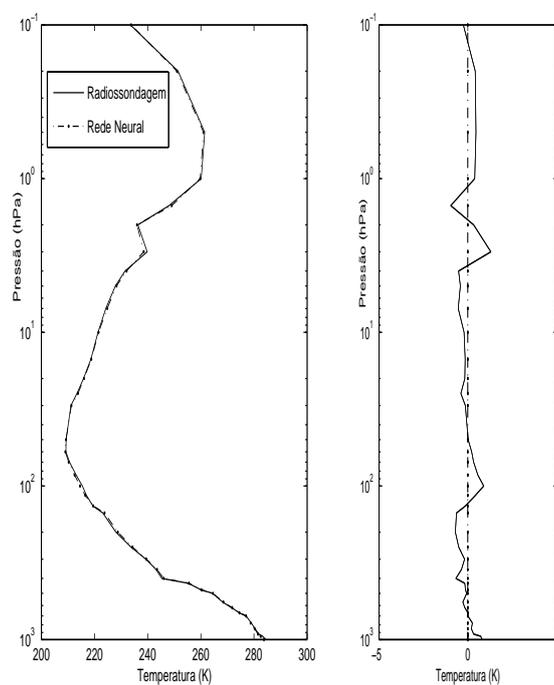


Figura 6.11 - Exemplo 1: (a) Perfil de temperatura obtido com a RPMC e o banco Sintético+TIGR-P, (b) erro da recuperação em relação à radiossondagem.

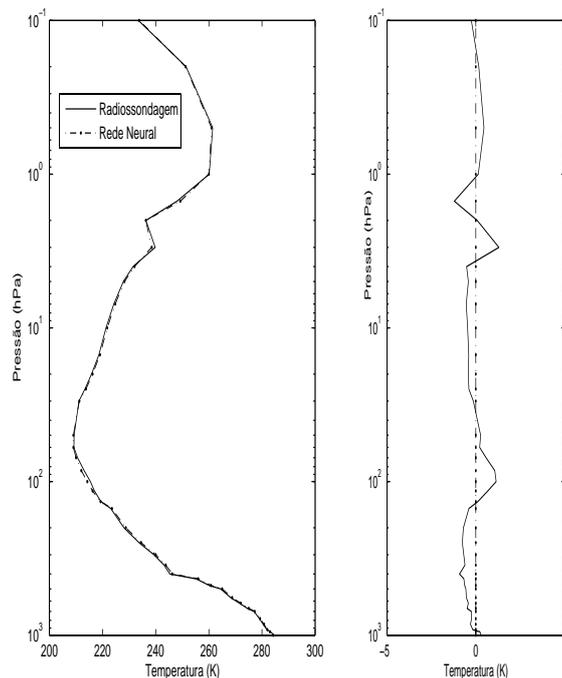


Figura 6.12 - Exemplo 2: (a) Perfil de temperatura obtido com a RPMC e o banco Sintético+TIGR-P, (b) erro da recuperação em relação à radiossondagem.

Pode-se observar que RPMC comporta-se bem nas três situações, utilizando dados globais, sintéticos e a junção dos bancos. Os perfis obtidos são bem próximos aos utilizados pelo modelo direto na geração das radiâncias, mesmo com a adição de 5% ruído nas radiâncias apresentadas na entrada da rede neural, principalmente nas regiões de maior interesse, as camadas atmosféricas 1 e 2.

### 6.9.2 Estimação de dados reais do HIRS/NOAA-14

Na última etapa de teste envolvendo a RPMC e o satélite NOAA-14, foi efetuada uma comparação entre o perfil de temperatura recuperado pela rede neural, métodos de regularização (CARVALHO, 1998) e o perfil real da atmosfera, obtido por radiossondagem. Foi utilizado um perfil vertical de temperatura medido durante a campanha de lançamento do Veículo Lançador de Satélites (VLS) no dia 27 de Outubro de 1997 às 14 horas e 58 minutos (horário local) em Alcântara no Estado do Maranhão, cidade situada a 2.19 S e 44.22 W. Os critérios utilizados para a escolha da data e hora mais adequadas para a utilização da sondagem foram a ocorrência de céu claro e horário sincronizado com a passagem do satélite sobre o ponto considerado.

As três configurações da RPMC geradas com o treinamento dos três bancos de perfis apresentados são testadas com caso real. Na Figura 6.13-(a) é apresentado o resultado do teste de generalização obtido com a RPMC treinada com os dados sintéticos. Os resultados são comparados com métodos de regularização de Tikhonov de ordem 1 e Máxima Entropia de ordem 2 (CARVALHO, 1998). Na Figura 6.13-(b) podem ser observados os erros em relação à radiossondagem. Nas Figuras 6.14 e 6.15, respectivamente, são apresentadas as inversões com a rede treinada com dados do banco TIGR-P e com a junção dos bancos sintético e TIGR-P. O perfil em preto-contínuo é a medida da radiossondagem, a inversão em azul foi obtida pela RPMC, e as inversões em vermelho e preto-tracejado, respectivamente, Tikhonov de ordem 1 e Máxima Entropia de ordem 2.

Embora os perfis verticais de temperatura tenham sido estimados pela RNA em 40 níveis de pressão atmosférica (0.10 hPa à 1000 hPa), os dados da radiossondagem foram capturados até 16.90 hPa, resultando em 28 camadas analisadas: 20, 25, 30, 50, 60, 70, 85, 100, 115, 135, 150, 200, 250, 300, 350, 400, 430, 475, 500, 570, 620, 670, 700, 780, 850, 920, 950 e 1000 hPa.

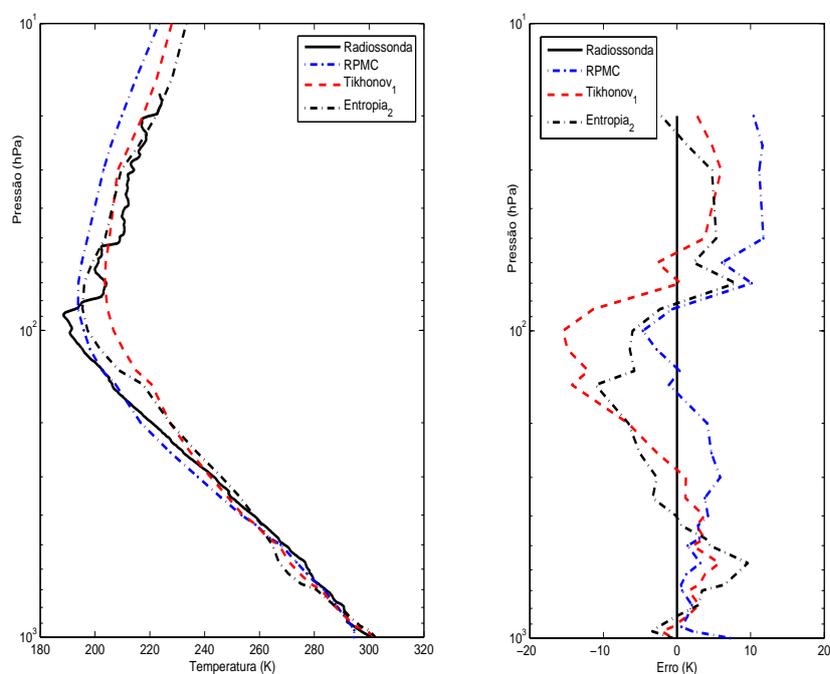


Figura 6.13 - (a) Perfil de temperatura obtido com a RPMC treinada com o banco Sintético, (b) erro da recuperação em relação à radiossondagem.

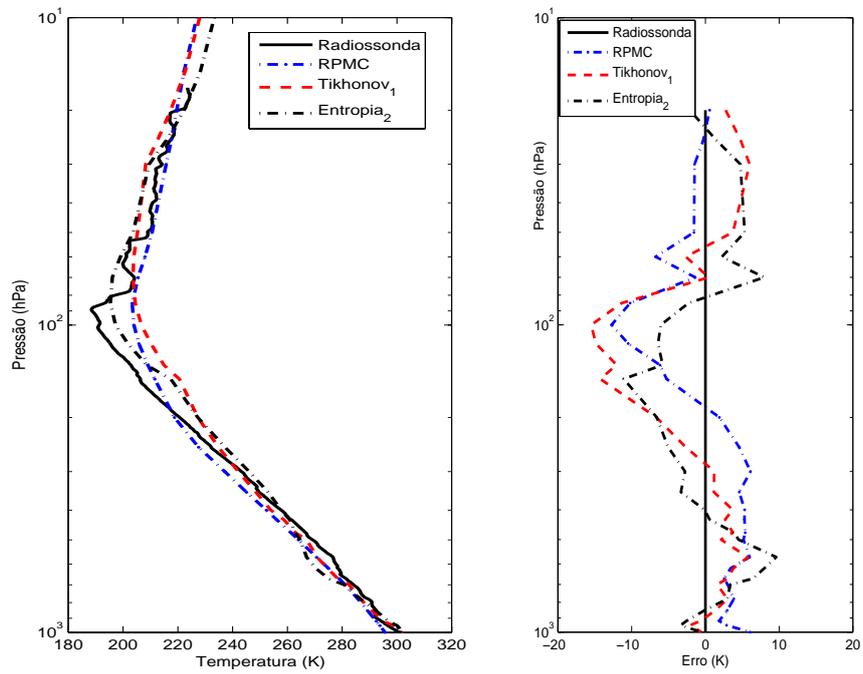


Figura 6.14 - (a) Perfil de temperatura obtido com a RPMC treinada com o banco TIGR-P, (b) erro da recuperação em relação à radiossondagem.

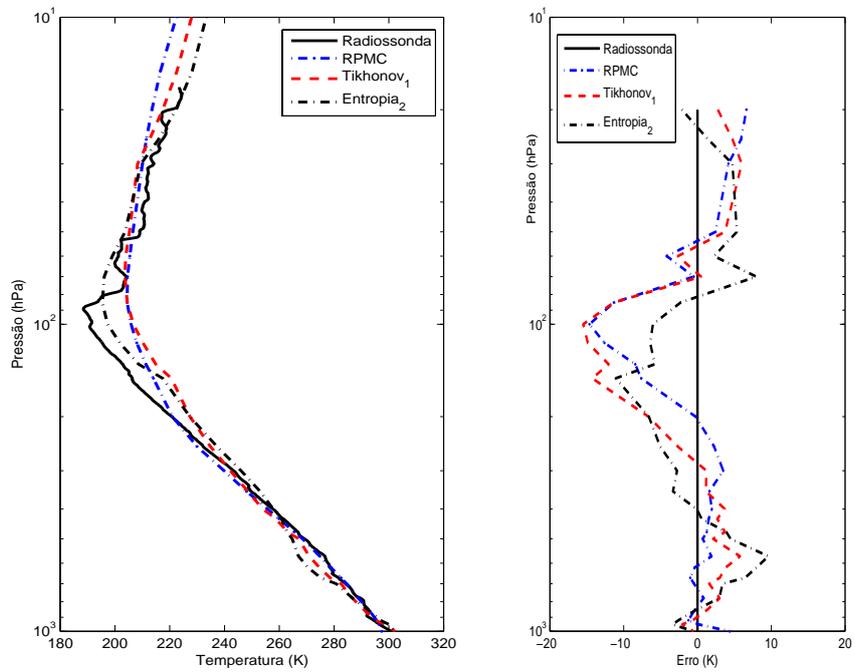


Figura 6.15 - (a) Perfil de temperatura obtido com a RPMC treinada com o banco Sintético+TIGR-P, (b) erro da recuperação em relação à radiossondagem.

Nesta seqüência de experimentos observa-se a eficiência da RPMC na recuperação dos perfis de temperatura com o uso do satélite NOAA-14. Os resultados são próximos aos desejados e superiores aos obtidos por métodos de regularização. A região de maior interesse para a meteorologia é a mais próxima da superfície terrestre, onde se obtém melhores inversões. Nos três testes a RPMC mostrou-se eficiente no processo de inversão. O melhor resultado foi obtido com a rede treinada com a junção dos dados sintéticos e TIGR-P.

### **6.9.3 Recuperação de perfis de temperatura utilizando a RPMC com dados do HIRS/NOAA-16**

Após serem testadas e generalizadas as inversões empregando a RPMC, um passo seguinte foi mostrar que a metodologia pode ser facilmente migrada quando novos sensores e satélites são disponibilizados. Por exemplo, a RPMC é utilizada para recuperar dados do sensor HIRS do satélite NOAA-16, necessitando somente de novos treinamentos.

Três conjuntos de dados atmosféricos são empregados para o HIRS/NOAA-16: dois contendo dados globais e um para verificar o desempenho da metodologia para o Brasil, empregando-se um banco composto somente com informações do Brasil. Resultados preliminares foram apresentados em [Shiguemori \*et al.\* \(2005b\)](#).

As radiâncias foram obtidas através da solução do problema direto pelo modelo RTTOV; os dados foram disponibilizados pela divisão DSA do CPTEC/INPE.

#### **6.9.3.1 Resultados utilizando-se o banco TIGR-C**

Uma versão completa do conjunto de dados TIGR foi utilizada nestes testes, que podem ser assim resumidos: dados do sensor HIRS; dados do satélite NOAA-16; canais espectrais 12; temperatura estimada em 40 níveis; número de neurônios na camada escondida variando entre 1 e 25; função de ativação logística sigmoideal nas camadas escondida e de saída; número de perfis no conjunto de treinamento: 587, de validação 587 e de generalização 587; solução do modelo RTTOV. Os valores dos erros médios dos 587 perfis são apresentados na Tabela [6.12](#) e os desvios padrão dos erros na Tabela [6.13](#).

Tabela 6.12 - Resultados da generalização do banco TIGR-C

Neurônios	Camada 1	Camada 2	Camada 3	Camada 4	Camada 5
12	0,9299	1,2564	1,1756	1,7000	3,1079
13	0,8988	1,2068	1,1638	1,6997	3,0829
14	0,9327	1,2560	1,1810	1,6999	3,1193

Tabela 6.13 - Desvios padrão dos erros empregando o banco TIGR-C

Neurônios	Camada 1	Camada 2	Camada 3	Camada 4	Camada 5
12	0,0349	0,0660	0,0216	0,0108	0,0717
13	0,0357	0,0281	0,0285	0,0371	0,0814
14	0,0421	0,0640	0,0536	0,0505	0,1067

Observa-se que os erros e os desvios padrão das inversões são semelhantes aos obtidos nos experimentos HIRS/NOAA-14. Deve-se notar que os intervalos dos ruídos são menores, como apresentado na Tabela 6.3, comparados aos 5% de ruído com distribuição gaussiana com média 0 e variância igual a 1 nos experimentos do NOAA-14. Exemplos da recuperação dos perfis de temperatura utilizando 13 neurônios na camada escondida para o NOAA-16 são apresentados na Figura 6.16 e 6.17, com seus respectivos erros. Observa-se que o número de neurônios na camada escondida é maior do que o número de neurônios da rede neural usada na inversão com dados do NOAA-14.

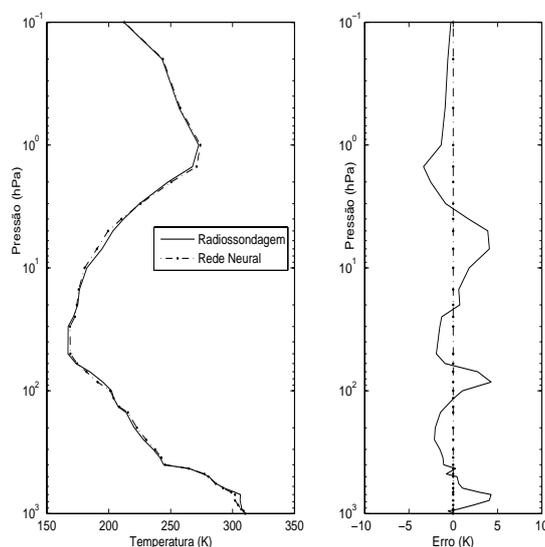


Figura 6.16 - Exemplo 1: (a) Perfil de temperatura obtido com a RPMC com os dados TIGR-C, (b) erro da recuperação em relação à radiossondagem.

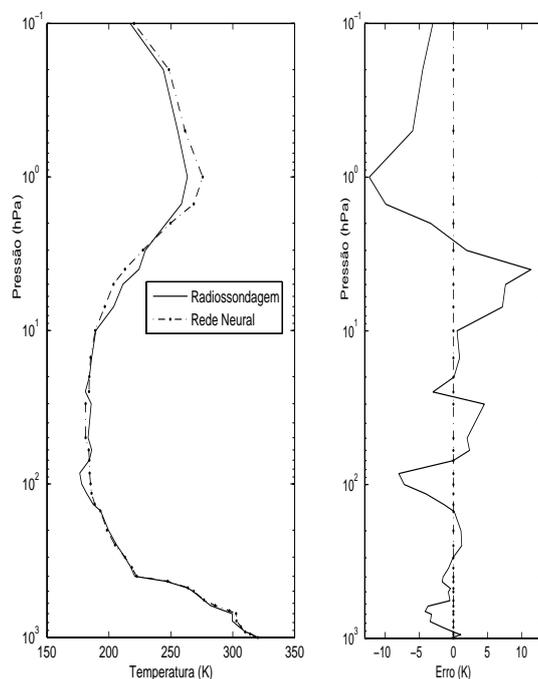


Figura 6.17 - Exemplo 2: (a) Perfil de temperatura obtido com a RPMC com os dados TIGR-C, (b) erro da recuperação em relação à radiossondagem.

### 6.9.3.2 Resultados utilizando o banco NESDISPR

Os resultados foram obtidos para o sensor HIRS; dados do satélite NOAA-16; perfis do banco NESDISPR; 12 canais espectrais; temperatura estimada em 40 níveis; neurônios na camada escondida variando entre 1 e 25; função de ativação logística sigmoideal nas camadas escondida e de saída; número de 400 perfis no conjunto de treinamento, 400 no conjunto de validação e 405 no de generalização; solução do modelo direto RTTOV. Os valores dos erros médios dos 405 perfis não utilizados no treinamento são apresentados na Tabela 6.14, e os desvios padrão dos erros na Tabela 6.15.

Tabela 6.14 - Média dos erros dos resultados da generalização do banco NESDISPR

Neurônios	Camada 1	Camada 2	Camada 3	Camada 4	Camada 5
8	0,8307	0,6721	1,2875	1,1863	1,5977
9	0,8322	0,6788	1,2871	1,1809	1,6001
10	0,8266	0,6683	1,2567	1,1752	1,5895
11	0,8302	0,6681	1,2697	1,1750	1,5831
12	0,8268	0,6671	1,2563	1,1759	1,5900

Tabela 6.15 - Desvios padrão dos erros

Neurônios	Camada 1	Camada 2	Camada 3	Camada 4	Camada 5
8	0,0231	0,0109	0,0271	0,0321	0,0221
9	0,0094	0,0245	0,0371	0,0046	0,0139
10	0,0153	0,0123	0,0333	0,0146	0,0178
11	0,0128	0,0053	0,0217	0,0102	0,0265
12	0,0159	0,0086	0,0376	0,0357	0,0266

Não foram observadas grandes variações utilizando-se de 8 a 12 neurônios na camada escondida da rede neural, intervalo onde foram obtidos os melhores resultados e que são apresentados nas Tabelas 6.14, 6.15. Dois exemplos de soluções do problema inverso e seus erros utilizando-se o banco NESDISPR são apresentados nas Figuras 6.18 e 6.19. Os perfis foram obtidos utilizando-se 10 neurônios na camada escondida.

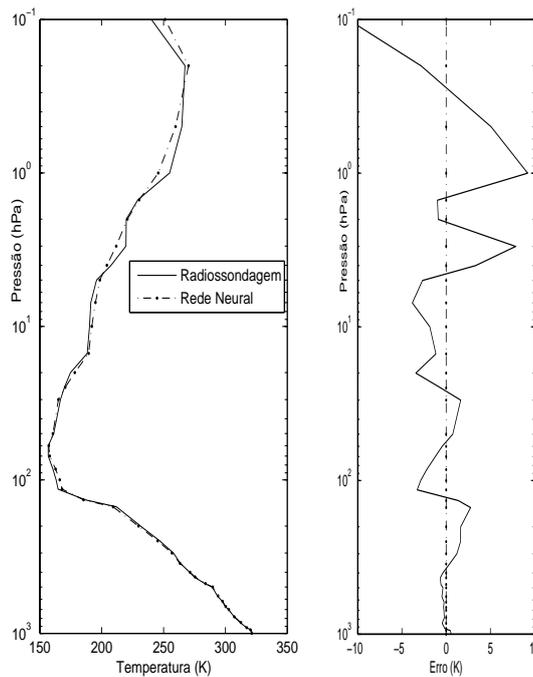


Figura 6.18 - Exemplo 1: (a) Perfil de temperatura obtido com a RPMC com os dados NESDISPR, (b) erro da recuperação em relação à radiossondagem.

Assim como apresentado com a estimação de perfis de temperatura utilizando dados do sensor HIRS do satélite NOAA-14, a RPMC apresenta bom desempenho quando utilizados dados do NOAA-16, utilizando dados globais e do Brasil como é apresentado na próxima seção.

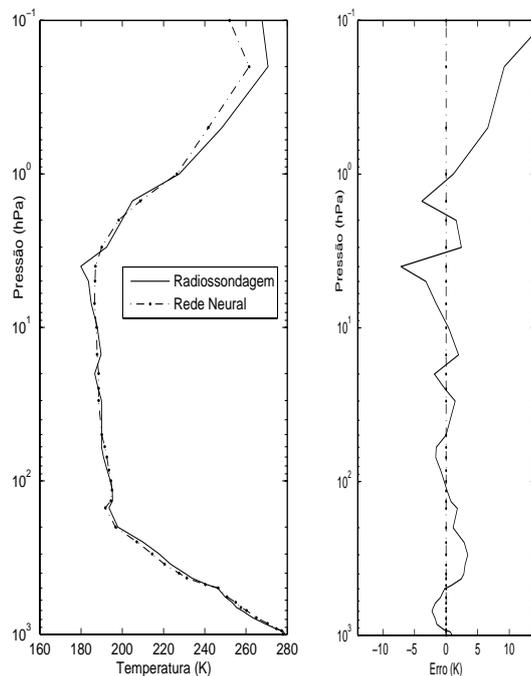


Figura 6.19 - Exemplo 2: (a) Perfil de temperatura obtido com a RPMC com os dados NESDISPR, (b) erro da recuperação em relação à radiossondagem.

### 6.9.3.3 Resultados utilizando-se o banco CLASS1

A utilização do banco com dados do Brasil com os dados do sensor HIRS; dados do satélite NOAA-16 pode ser assim resumida: perfis do banco CLASS1; canais espectrais 12; temperatura estimada em 40 níveis; neurônios na camada escondida 1 a 25; função de ativação logística sigmoideal nas camadas escondida e de saída; número de perfis no conjunto de treinamento, validação e generalização, respectivamente, 215, 215 e 217; solução do modelo direto RTTOV. Na Tabela 6.16 são apresentados os erros médios dos 217 perfis não utilizados na fase de treinamento e na Tabela 6.17 os desvios padrão dos erros.

Tabela 6.16 - Erros do conjunto de generalização do banco CLASS1

Neurônios	Camada 1	Camada 2	Camada 3	Camada 4	Camada 5
6	1,1080	1,7419	1,6119	1,1554	1,2865
7	1,0617	1,6168	1,4641	0,9218	0,8479
8	1,0701	1,6492	1,4996	0,9232	0,8653
9	1,0700	1,6620	1,5099	0,9326	0,8756

Tabela 6.17 - Desvios padrão dos erros do conjunto de generalização do banco CLASS1

Neurônios	Camada 1	Camada 2	Camada 3	Camada 4	Camada 5
6	0,0019	0,0028	0,0018	0,0097	0,0032
7	0,0091	0,0329	0,0242	0,0139	0,0212
8	0,0029	0,0086	0,0113	0,0066	0,0125
9	0,0026	0,0120	0,0136	0,0066	0,0062

Observa-se que os perfis verticais de temperatura para o Brasil recuperados pela RPMC são próximos aos desejados, o que também ocorreu com os bancos de dados globais TIGR-C e NESDISPR. Nota-se que foi necessário um número menor de neurônios na camada escondida para o banco CLASS1, atentando que há variações menores nos perfis de temperatura para uma região específica como o Brasil, quando comparados com os bancos TIGR-C e NESDISPR. Estas variações são apresentadas na Figura 6.2.

As Figuras 6.20 e 6.21 apresentam dois exemplos do conjunto de generalização do banco CLASS1 e seus respectivos erros, utilizando-se 8 neurônios na camada escondida.

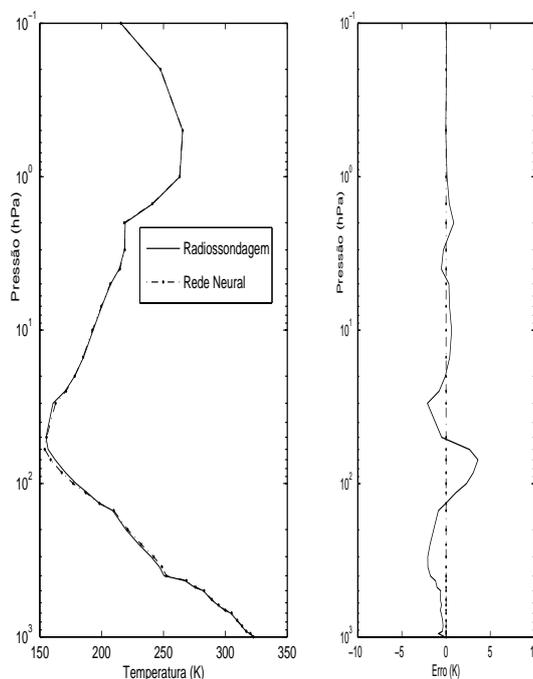


Figura 6.20 - Exemplo 1: (a) Perfil de temperatura obtido com a RPMC com os dados CLASS1, (b) erro da recuperação em relação à radiossondagem.

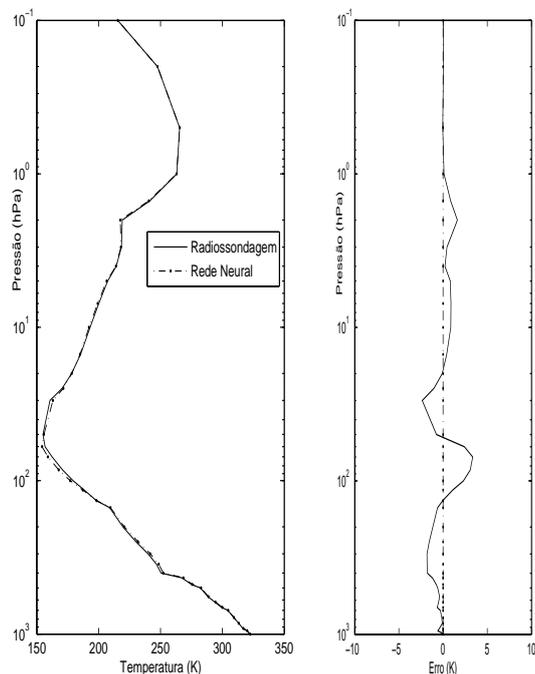


Figura 6.21 - Exemplo 2: (a) Perfil de temperatura obtido com a RPMC com os dados CLASS1, (b) erro da recuperação em relação à radiossondagem.

#### 6.9.4 Recuperação dos perfis verticais de temperatura com uso da RPMC - AIRS/AQUA

Para finalizar os testes com a RPMC na estimação de perfis de temperatura, considerou-se o sensor AIRS do satélite AQUA. Resultados preliminares foram apresentados em Souza *et al.* (2006). Com apresentado na Tabela 6.5, utilizou-se 149 canais do sensor AIRS.

Uma junção dos bancos NESDISPR, TIGR-C e CLASS1 foi realizada, assim como os 5 experimentos com o banco resultante. Os erros do conjunto de generalização são apresentados na Tabela 6.18 e os desvios padrão dos erros na Tabela 6.19.

Tabela 6.18 - REMQ dos resultados da generalização do banco BD4+BD5+BD6

Neurônios	Camada 1	Camada 2	Camada 3	Camada 4	Camada 5
15	0,5827	0,7698	0,8894	0,8167	0,8902
16	0,5833	0,7618	0,9260	0,8643	0,9765
17	0,5777	0,7175	0,8513	0,7815	0,8876
18	0,5754	0,7380	0,8685	0,7950	0,9199
19	0,5589	0,7266	0,8484	0,7491	0,8881

Tabela 6.19 - Desvios padrão das REMQ da generalização do banco BD4+BD5+BD6

Neurônios	Camada 1	Camada 2	Camada 3	Camada 4	Camada 5
15	0,0351	0,0751	0,0635	0,0731	0,0772
16	0,0396	0,0741	0,0326	0,0762	0,1539
17	0,0144	0,0208	0,0458	0,0200	0,0461
18	0,0291	0,0566	0,0624	0,0777	0,1300
19	0,0352	0,0524	0,0954	0,0664	0,1286

Nota-se que as inversões obtidas com a RPMC para o sensor AIRS do satélite AQUA são satisfatoriamente próximos aos desejados. Atenta-se também que não há grandes variações nos diferentes experimentos realizados, como pode ser analisado na Tabela 6.19. Os erros apresentados na Tabela 6.18 correspondem às REMQ de 723 perfis não utilizados na fase de treinamento de dados globais e exclusivos do Brasil. Dois exemplos de inversões são apresentados nas Figuras 6.22 e 6.23 com seus erros.

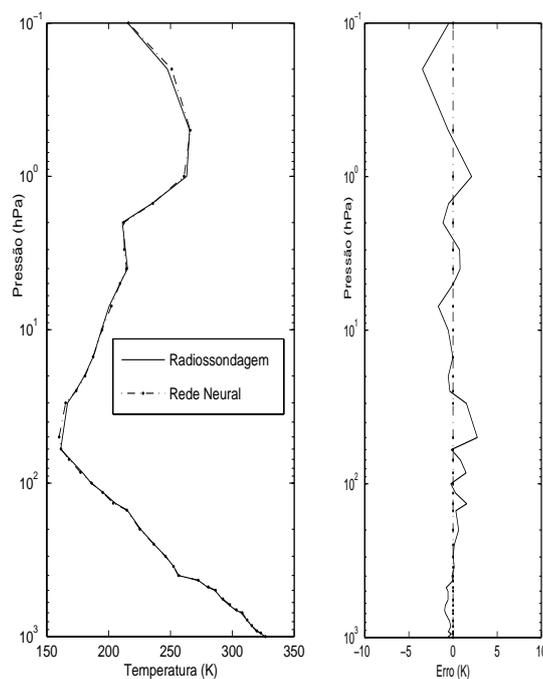


Figura 6.22 - Exemplo 1: (a) Perfil de temperatura obtido com a RPMC com os dados BD4+BD5+BD6, (b) erro da recuperação em relação à radiosondagem.

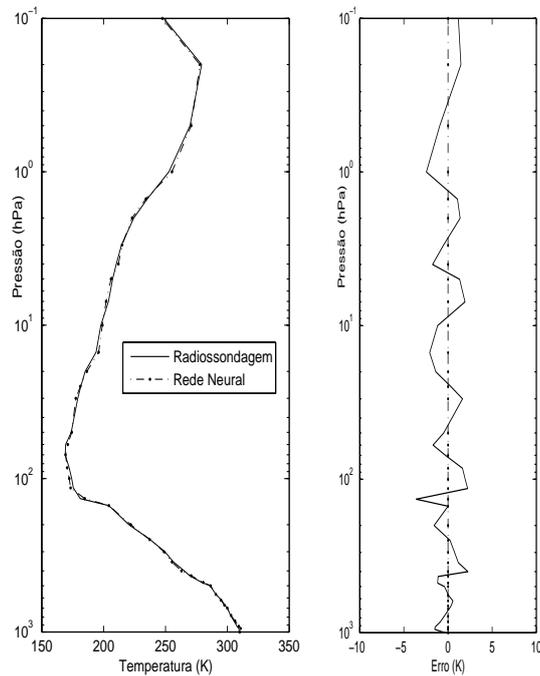


Figura 6.23 - Exemplo 2: (a) Perfil de temperatura obtido com a RPMC com os dados BD4+BD5+BD6, (b) erro da recuperação em relação à radiossondagem.

Nos testes com a RPMC, nas várias situações consideradas, foram realizados 5 experimentos utilizando-se diferentes sementes nos geradores de números aleatórios para iniciar os pesos e limiares, para selecionar os perfis empregados no treinamento e para gerar os ruídos. Como não foram observadas grandes variações entre os experimentos, mostrados pelos desvios padrão, a partir desta rede neural, somente as tabelas dos erros são apresentadas.

### 6.9.5 Estimação de perfis verticais de umidade da atmosfera utilizando-se redes neurais artificiais

A rede Perceptron de Múltiplas Camadas foi empregada em diferentes situações e resultados próximos aos desejados foram obtidos na estimação de perfis verticais de temperatura. A mesma metodologia pode ser seguida para estimar outras informações da atmosfera a partir de dados de satélites, como a umidade. Neste trabalho aplicou-se a RPMC para estimar tais informações. Resultados preliminares são apresentados em [Shiguemori et al. \(2006\)](#). Nos testes foram utilizados os bancos TIGR-C, nos quais a rede neural é treinada usando-se dados apresentados pelo modelo direto caracterizado pela Equação de Transferência Radiativa. A análise dos

resultados da rede neural revela que os perfis gerados são próximos aos resultados dos dados experimentais, mostrando assim a eficiência do modelo baseado em rede neural na solução do problema inverso para recuperação de perfis verticais de umidade a partir de dados de satélites.

Tal como na estimação de perfis verticais de temperatura, a análise inversa com técnicas de redes neurais envolve as seguintes fases: (i) treinamento, (ii) validação e (iii) generalização da rede neural artificial, sendo necessários pares de entrada/saída - radiâncias e umidade. Estes dados podem ser obtidos de forma experimental ou, conhecendo-se o modelo direto, por sua solução. No trabalho, os dados utilizados nas fases mencionadas foram obtidos pela solução do modelo direto utilizando o modelo RTTOV-7, simulando as informações medidas pelo sensor "High Resolution Radiation Sounder"(HIRS) do satélite NOAA-16.

Foi utilizado um banco de dados contendo perfis verticais de temperatura e umidade medidos por radiossondas, o banco TIGR com 1761 perfis (TIGR, 2006). Após a solução do problema direto para gerar as radiâncias correspondentes, simulando ângulos de visada no nadir e em condições de céu livre de nuvens, dividiu-se em 587 pares de entrada/saída para o treinamento, 587 para a validação e 587 para a generalização. Os conjuntos de treinamento e validação são utilizados durante o treinamento, enquanto o de generalização é usado nos testes da RNA.

Assim como nos experimentos com perfis de temperatura, os dados experimentais, que contêm erros em aplicações reais, são simulados adicionando-se ruído gaussiano à solução exata do problema direto dada pela Equação 6.2. Os intervalos dos erros correspondem aos valores reais de erros medidos pelo sensor HIRS/NOAA-16, onde cada canal do sensor corresponde a um comprimento de onda.

Durante o treinamento da rede foram utilizados os subconjuntos de treinamento contendo 587 padrões e o de validação contendo 587 pares de entrada/saída. A Tabela 6.20 apresenta os REMQ destes perfis, cujos erros são apresentados em  $\ln(g/kg)$ . Na abordagem foram necessários 20 neurônios na camada escondida. A função de ativação utilizada na camada de escondida e de saída da rede neural foi a logística sigmoidal.

Tabela 6.20 - Erros obtidos nos testes de validação

Neurônios	Camada 1	Camada 2	Camada 3	Camada 4	Camada 5
20	0,1270	0,2500	0,2300	0,0730	0,0280

Nos testes de generalização foram utilizados 587 perfis não utilizados no treinamento. Os erros dos 587 perfis de generalização nas cinco subcamadas são apresentados na Tabela 6.21.

Tabela 6.21 - Erros obtidos nos testes de generalização

Neurônios	Camada 1	Camada 2	Camada 3	Camada 4	Camada 5
20	0,1300	0,2400	0,2230	0,0700	0,0330

Os erros obtidos nos testes de generalização são muito próximos aos obtidos nos testes de validação, mostrando a capacidade de generalização da rede neural a novos dados. A Figura 6.24 apresenta exemplos da generalização. Os perfis de umidade ( $\ln(\text{g}/\text{kg})$ ) são apresentados em função da pressão (hPa).

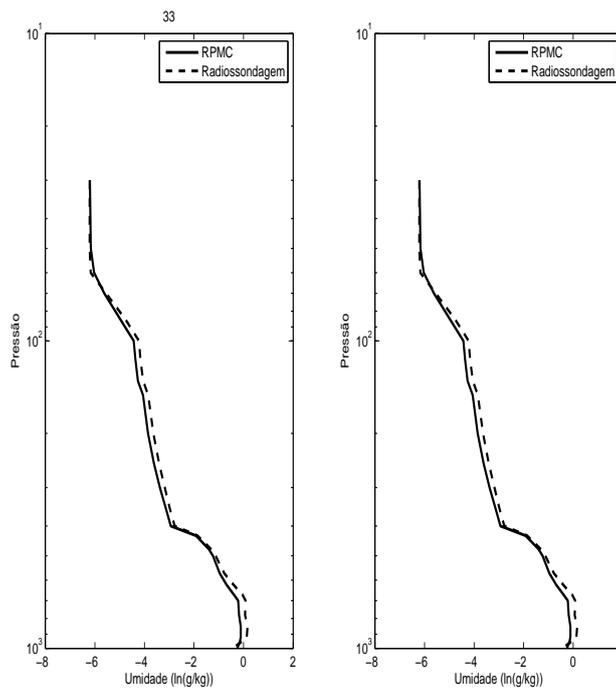


Figura 6.24 - Exemplos de perfis de umidade obtidos com a RPMC do banco TIGR-C.

Pode-se observar que os resultados apresentados nas Tabelas 6.20 e 6.21 e ilustrados na Figura 6.24 obtidos pela RNA são próximos aos perfis de umidade utilizados na solução do problema direto mostrando a eficiência da rede mesmo para dados não utilizados no conjunto de treinamento.

Na prática, algoritmos de inversão operacionais reduzem o risco de caírem num mínimo local iniciando o processo de busca iterativo de uma estimativa inicial suficientemente próxima ao perfil verdadeiro, particularmente em regiões onde pelo menos uma informação a priori é conhecida (CHEDIN *et al.*, 1985). RNAs podem relaxar essa restrição incorporando mais dados na fase de aprendizagem.

## **6.10 Recuperação de perfis verticais de temperatura da atmosfera utilizando-se a rede Funções de Base Radial**

A segunda rede neural empregada neste trabalho foi a RFBR, sendo utilizada a seleção auto-organizada dos centros na camada escondida, e unidades de saída compostas por funções lineares.

Primeiramente é realizada a abordagem com funções de base radial gaussianas, com seleção dos centros por auto-organização. Em seguida é proposta a utilização de funções de ativação baseada na entropia não-extensiva. Para a RFBR foram variados os conjuntos de dados e sensores atmosféricos empregando o sensor HIRS a bordo do satélite NOAA-14.

### **6.10.1 Recuperação dos perfis verticais de temperatura com uso da RFBR - sensor HIRS/NOAA-14**

Os resultados para a RFBR apresentados em Shiguemori *et al.* (2004) foram obtidos utilizando os mesmos canais do sensor HIRS/NOAA-14 empregados em Carvalho (1998) e apresentados nas próximas seções.

#### **6.10.1.1 Resultados utilizando-se o banco de dados sintéticos**

O estudo empregando a RFBR foi baseado no sensor HIRS, satélite NOAA-14, utilizando-se 7 canais espectrais para as medidas de radiância, estimando-se a temperatura em 40 níveis, função de base radial gaussiana na camada escondida e linear na camada de saída. Foram utilizados 150 perfis no conjunto de treinamento, 250 no conjunto de validação e 250 na generalização. A solução do modelo direto foi obtida pela Equação 6.1. Na Tabela 6.22 são apresentados os erros nas estimações dos 250 perfis não utilizados na fase de treinamento.

Inversões com RFBR estão próximas aos perfis de radiossondagem, principalmente nas camadas atmosféricas 1 e 2. Dois exemplos de estimações que representam o

Tabela 6.22 - Resultados da generalização do banco Sintético

Neurônios	Camada 1	Camada 2	Camada 3	Camada 4	Camada 5
11	0,8366	0,7978	1,2608	1,0787	0,7701
12	0,8224	0,7973	1,2766	1,0401	0,7829
13	0,7988	0,7808	1,2752	1,0249	0,8337
14	0,7718	0,7640	1,2763	1,0370	0,8759
15	0,7780	0,8439	1,3084	1,1787	0,8511

desempenho médio da rede neural, utilizando 13 neurônios na camada escondida, e seus erros são apresentadas nas Figuras 6.25 e 6.26.

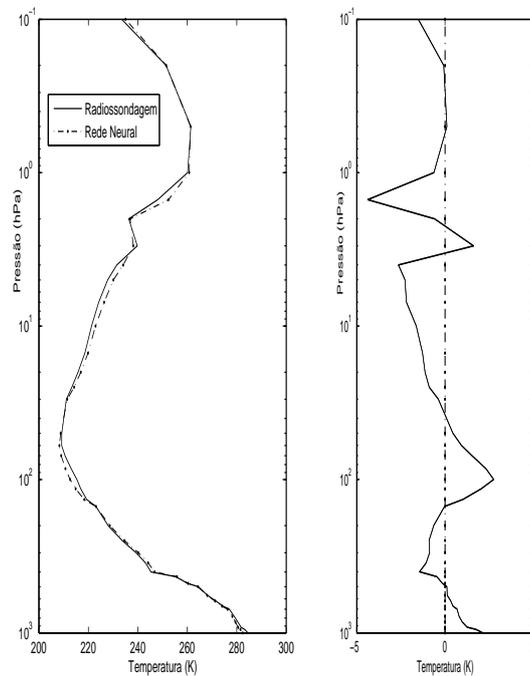


Figura 6.25 - Exemplo 1: (a) Perfil de temperatura obtido com a RFBR com os dados sintéticos, (b) erro da recuperação em relação à radiossondagem.

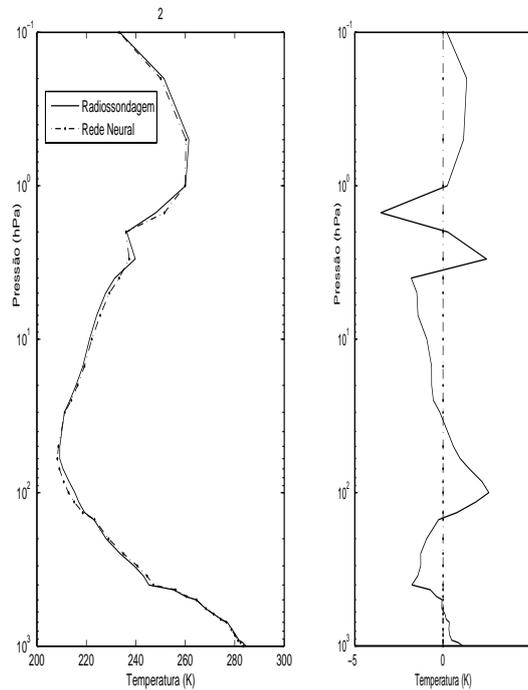


Figura 6.26 - Exemplo 2: (a) Perfil de temperatura obtido com a RFBR com os dados sintéticos, (b) erro da recuperação em relação à radiossondagem.

### 6.10.1.2 Resultados utilizando o banco TIGR-P

A RFBR também foi aplicada na solução do problema inverso utilizando o banco TIGR-P. Foram utilizados 323 perfis no conjunto de treinamento e 323 no conjunto de generalização. Os erros destes 323 perfis do conjunto de generalização são apresentados na Tabela 6.23. Nas Figuras 6.27 e 6.28 são apresentados 2 exemplos contidos neste conjunto.

Tabela 6.23 - Resultados da generalização do banco TIGR-P

Neurônios	Camada 1	Camada 2	Camada 3	Camada 4	Camada 5
11	1,2997	1,5024	2,3801	1,9346	2,1330
12	1,2722	1,4986	2,2693	1,8651	2,1087
13	1,2359	1,5018	2,3485	1,8984	2,0677
14	1,2339	1,5422	2,3642	1,9247	2,0746
15	1,2021	1,5101	2,2663	1,8139	2,1160

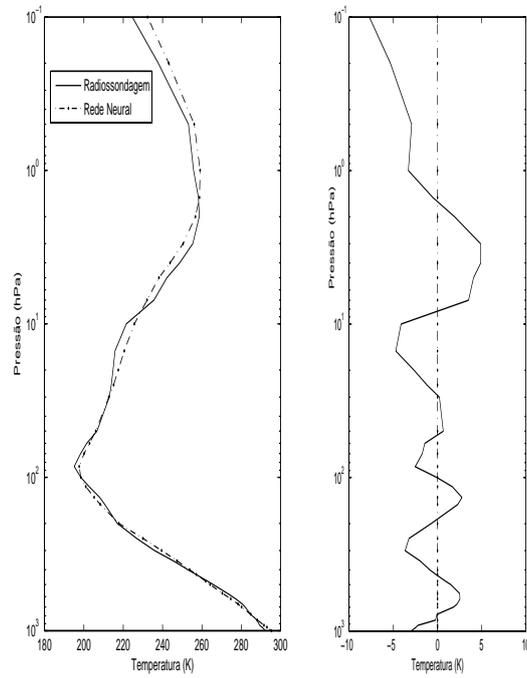


Figura 6.27 - Exemplo 1: (a) Perfil de temperatura obtido com a RFBR e o banco TIGR-P, (b) erro da recuperação em relação à radiosondagem.

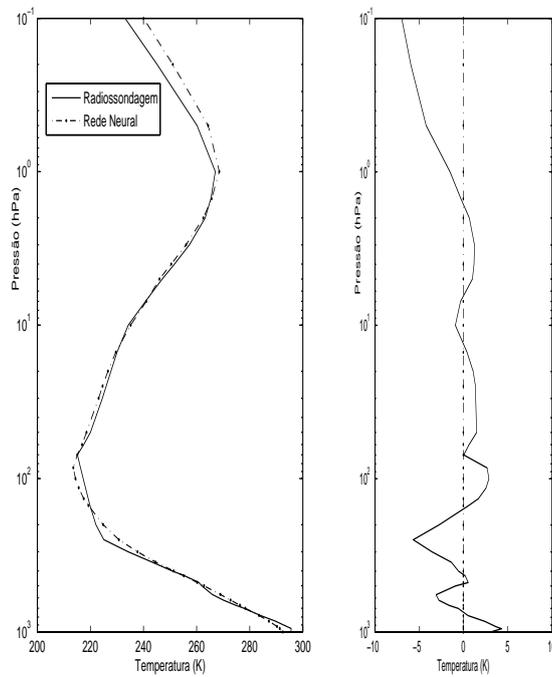


Figura 6.28 - Exemplo 2: (a) Perfil de temperatura obtido com a RFBR e o banco TIGR-P, (b) erro da recuperação em relação à radiosondagem.

Assim como com o emprego da RPMC, a RFBR apresenta bom desempenho nas inversões do banco sintético principalmente nas camadas 1 e 2. A RFBR apresentou resultados semelhantes aos obtidos pela RPMC e próximos aos desejados mostrando também a eficiência da rede neural empregada.

### 6.10.1.3 Resultados utilizando o banco Sintético+TIGR-P

Os testes utilizando a junção dos bancos sintéticos e TIGR-P também foram aplicados à RFBR, para o sensor HIRS/NOAA-14. Os erros médios dos testes dos 348 perfis de temperatura são apresentados na Tabela 6.24. Dois exemplos da generalização são apresentados nas Figuras 6.29 e 6.30.

Tabela 6.24 - Resultados da generalização do banco Sintético + TIGR-P

Neurônios	Camada 1	Camada 2	Camada 3	Camada 4	Camada 5
20	0,4887	1,2796	2,7643	1,4737	1,2644
21	0,4736	1,2221	2,4897	1,5770	1,1683
22	0,4676	1,2012	2,6920	1,4059	1,2574
23	0,5697	1,3329	3,0458	1,4310	1,3889
24	0,5030	1,2441	2,7126	1,4036	1,3068

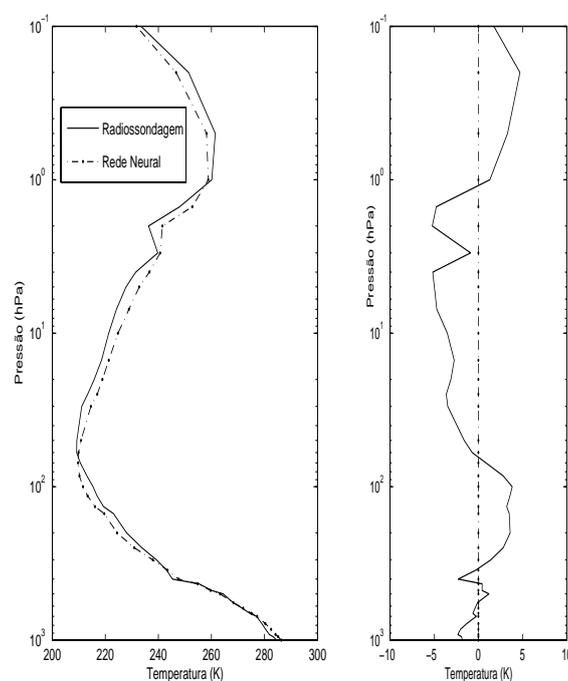


Figura 6.29 - Exemplo 1: (a) Perfil de temperatura obtido com a RFBR e o banco Sintético+TIGR-P, (b) erro da recuperação em relação à radiossondagem.

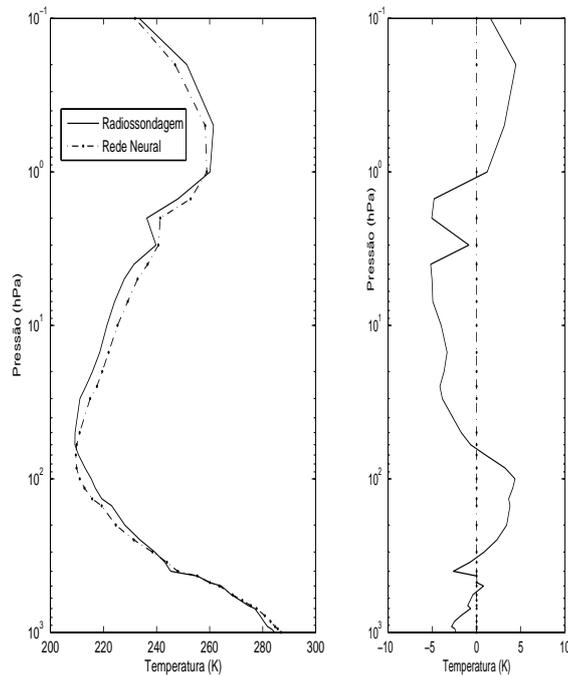


Figura 6.30 - Exemplo 2: (a) Perfil de temperatura obtido com a RFBR e o banco Sintético+TIGR-P, (b) erro da recuperação em relação à radiossondagem.

A RFBR foi submetida a testes com o sensor HIRS/NOAA-14 utilizando três bancos de dados, apresentando-se eficiente na generalização e robusta a dados ruidosos.

### 6.10.2 Estimação de dados reais do HIRS/NOAA-14 com uso da RFBR

Os dados reais medidos por satélites e comparados com medidas de radiossondagem também foram testados empregando-se a RFBR. Assim como nos testes da RPMC, foi efetuada a comparação entre o perfil de temperatura recuperado pela rede neural, pelos métodos de regularização (CARVALHO, 1998) e o perfil real da atmosfera medido por radiossondas. Estes resultados são apresentados em Shiguemori *et al.* (2004). Assim como apresentado nos outros testes de generalização, os perfis estimados pela RFBR são próximos aos perfis de radiossondagem. Na Figura 6.31-(a) é apresentado o resultado do teste de generalização com a RFBR treinada com os dados sintéticos, sendo comparado com os métodos de regularização de Tikhonov de ordem 1 e Máxima Entropia de ordem 2 (CARVALHO, 1998). Na Figura 6.31-(b) são apresentados os erros em relação à radiossondagem. Nas Figuras 6.32 e 6.33 são comparadas, respectivamente, as inversões alcançadas pela RFBR treinada com os dados do TIGR-P e Sintético+TIGR-P.

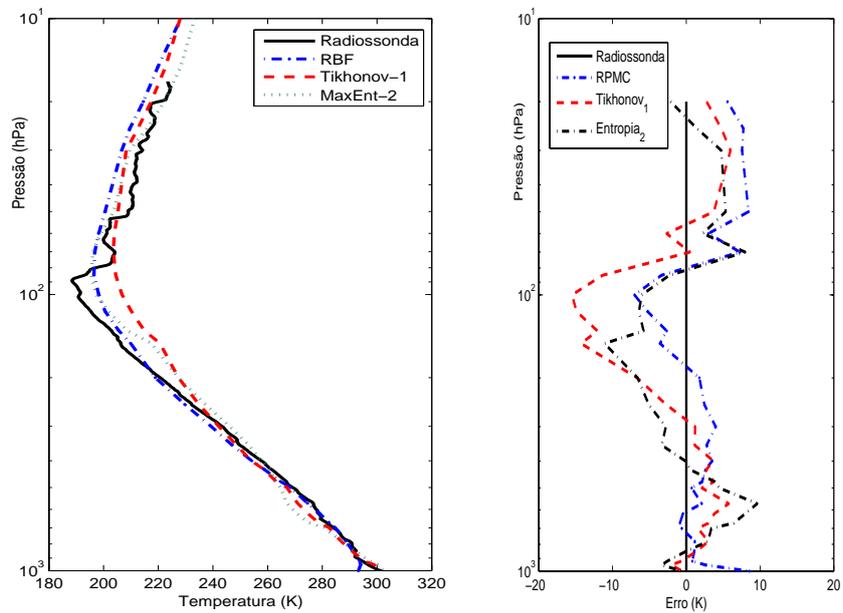


Figura 6.31 - (a) Perfil de temperatura obtido com a RFBR treinada com banco Sintético, (b) erro da recuperação em relação à radiossondagem.

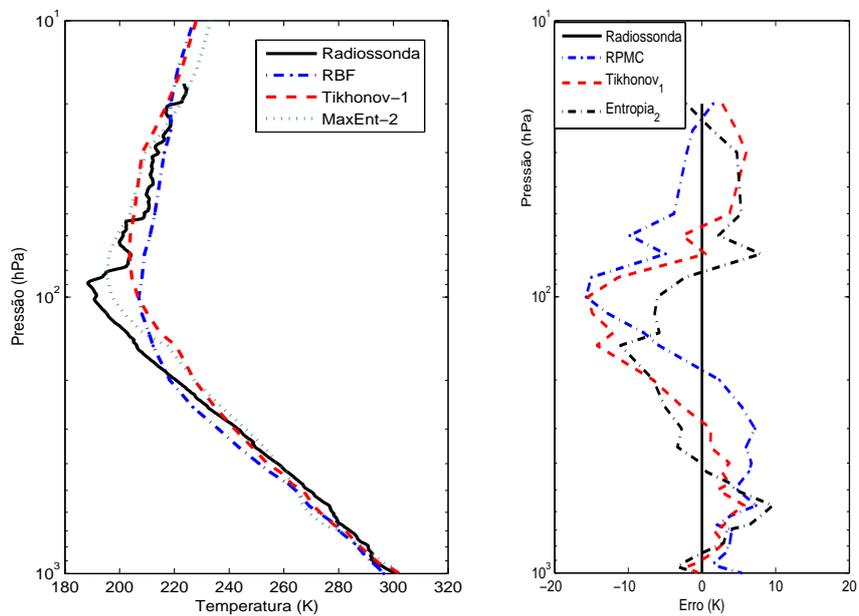


Figura 6.32 - (a) Perfil de temperatura obtido com a RFBR treinada com o banco TIGR-P, (b) erro da recuperação em relação à radiossondagem.

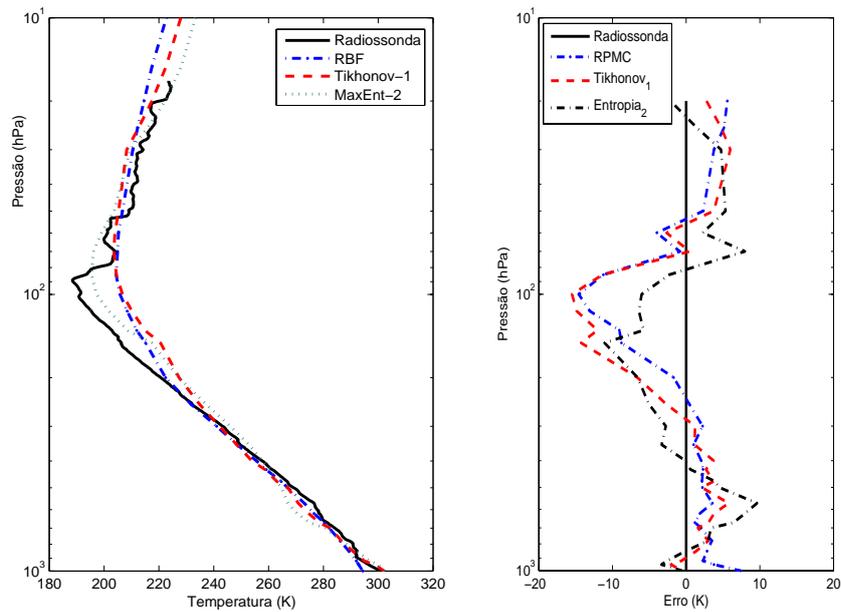


Figura 6.33 - (a) Perfil de temperatura obtido com a RFBR treinada com o banco Sintético+TIGR-P, (b) erro da recuperação em relação à radiossondagem.

As inversões são próximas, ou melhores, que os resultados obtidos pelos métodos de regularização. É importante ressaltar que a temperatura na superfície é um parâmetro conhecido para os modelos de regularização, o que não foi considerado pela rede neural. Comparando os resultados da RFBR com os da RPMC, verifica-se que a RPMC apresenta uma pequena vantagem na estimação dos perfis verticais de temperatura.

## 6.11 Recuperação de dados atmosféricos utilizando a rede Funções de Base Radial Não-Extensiva

Nos experimentos foram utilizados 5 valores de  $q$ : 0,5; 1,0; 1,5; 2,0 e 2,5. As distribuições são apresentadas na Figura 6.34.

Assim como na RFBR, utilizou-se o algoritmo de  $k$ -médias para localização dos centros das funções.

### 6.11.1 Resultados utilizando-se o banco de dados sintéticos

A RFBR-NE foi aplicada nas estimações dos dados do HIRS/NOAA-14 e nos dados reais. Para efeitos comparativos, foram usadas 21 funções de base radial, arquitetura que apresentou resultados melhores com o uso da RFBR com função gaussiana.

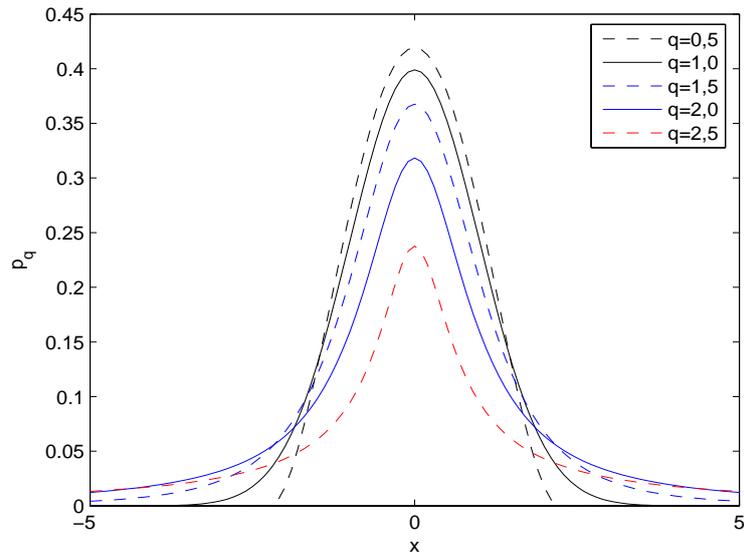


Figura 6.34 - Distribuições para diferentes valores de  $q$

Os resultados obtidos com a aplicação da RFBR-NE com os dados do sensor HIRS do satélite NOAA-14, utilizando-se os perfis do banco sintético são apresentados na Tabela 6.25, onde podem ser observados os erros médios dos 250 perfis de temperatura. Na coluna 1 são indicados os valores dos parâmetros  $q$ 's utilizados nas funções de base radial e as colunas 2 a 6 indicam os REMQ nas camadas atmosféricas correspondentes.

Tabela 6.25 - Generalização da RFBR-NE - banco Sintético - Camada 1

$q$	Camada 1	Camada 2	Camada 3	Camada 4	Camada 5
0,5	0,9080	0,9702	1,4511	<b>1,1228</b>	0,8088
1,0	<b>0,6867</b>	0,7992	1,0296	1,2185	0,7191
1,5	0,7728	<b>0,6911</b>	<b>0,9693</b>	1,3113	0,6978
2,0	0,7649	0,7269	1,0364	1,3539	0,6386
2,5	0,7603	0,7398	1,0873	1,3424	<b>0,6376</b>

Observa-se que resultados das inversões podem ser melhorados empregando-se diferentes valores de  $q$  considerando as 5 camadas atmosféricas analisadas. Os resultados destacados na Tabela 6.25 mostram que na camada 1 a função gaussiana apresenta o erro médio menor, nas camadas 2 e 3 as médias dos erros são menores quando utilizado  $q = 1, 5$ , na camada 4 com  $q = 0, 5$  e na camada 5 com  $q = 2, 5$ , mostrando que os resultados podem ser melhorados em relação à utilização da função gaussiana.

Nas Figuras 6.35 e 6.36 são apresentados os perfis de temperatura e os erros empregando-se valores de  $q$  adequados. A linha preta apresenta a medida da radiossonda, a azul obtida com a RFBR-NE utilizando  $q = 1,0$  e a vermelha utilizando  $q = 1,5$ .

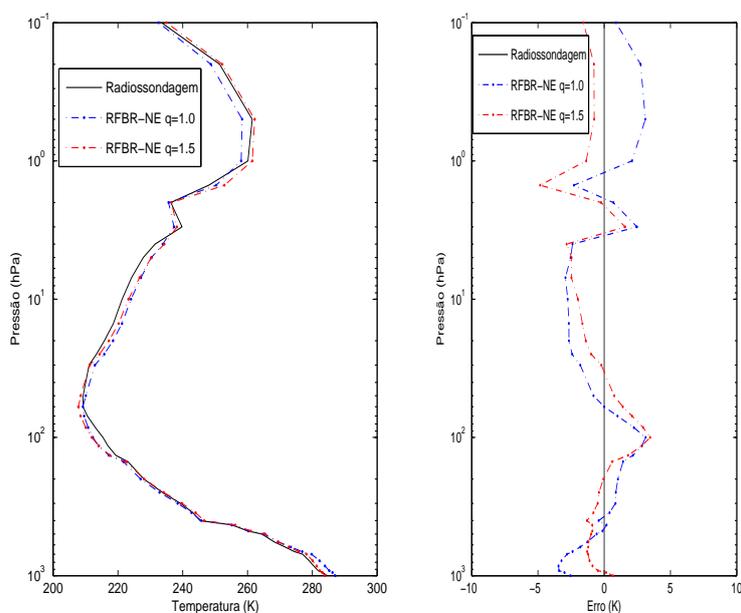


Figura 6.35 - Exemplo 1: (a) Perfil de temperatura obtido com a RFBR-NE e o banco TIGR-P, (b) erro da recuperação em relação à radiossondagem.

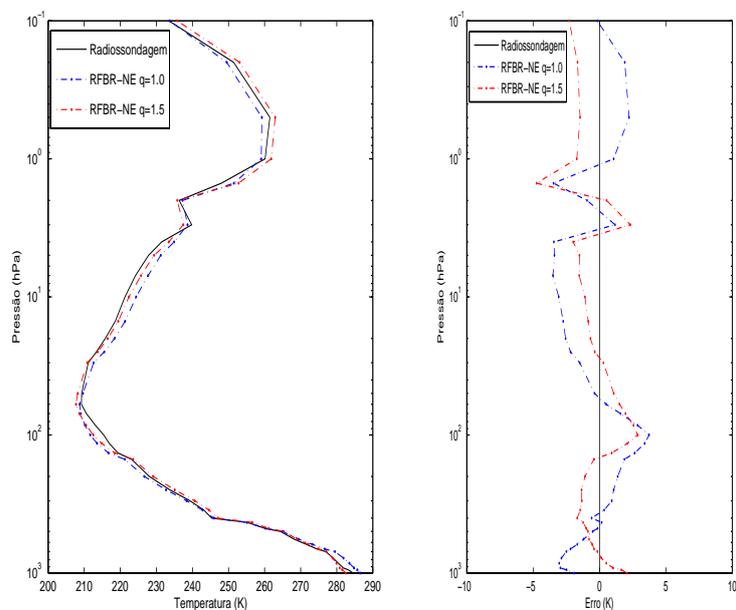


Figura 6.36 - Exemplo 2: (a) Perfil de temperatura obtido com a RFBR-NE e o banco TIGR-P, (b) erro da recuperação em relação à radiossondagem.

### 6.11.2 Resultados utilizando-se o banco TIGR-P

Em testes com o banco TIGR-P, o uso de diferentes valores de  $q$  na RFBR-NE também apresentou resultados melhores. Na Tabela 6.26 podem ser observados os erros médios de 323 perfis nas camadas atmosféricas, onde os menores são destacados em negrito.

Tabela 6.26 - Generalização da RFBR-NE - banco TIGR-P - Camada 1

$q$	Camada 1	Camada 2	Camada 3	Camada 4	Camada 5
0,5	1,1134	1,3122	1,9393	1,6463	1,9420
1,0	<b>1,1091</b>	1,3114	1,9560	1,5958	1,9553
1,5	1,1178	1,3121	1,9801	1,5814	1,9368
2,0	1,1158	1,3004	1,8942	1,5743	1,9314
2,5	1,1135	<b>1,2956</b>	<b>1,8940</b>	<b>1,5474</b>	<b>1,8928</b>

Para o banco TIGR-P, o menor erro para a camada atmosférica 1 foi obtido com  $q = 1$ , enquanto nas outras camadas com  $q = 2, 5$ . Dois exemplos de inversões do banco são ilustrados nas Figuras 6.37 e 6.38. As inversões em azul utilizando  $q = 1, 0$  e em vermelho  $q = 2, 5$  são comparadas com as medidas de radiossondagem.

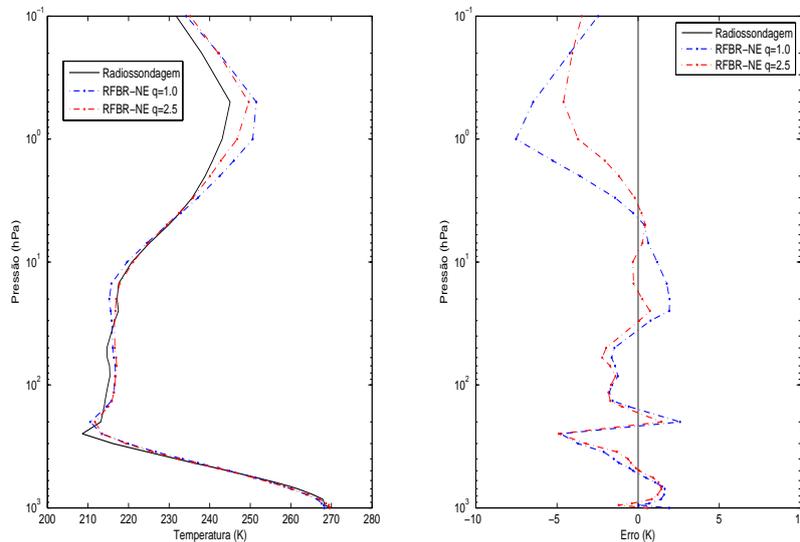


Figura 6.37 - Exemplo 1: (a) Perfil de temperatura obtido com a RFBR-NE e o banco TIGR-P, (b) erro da recuperação em relação à radiossondagem.

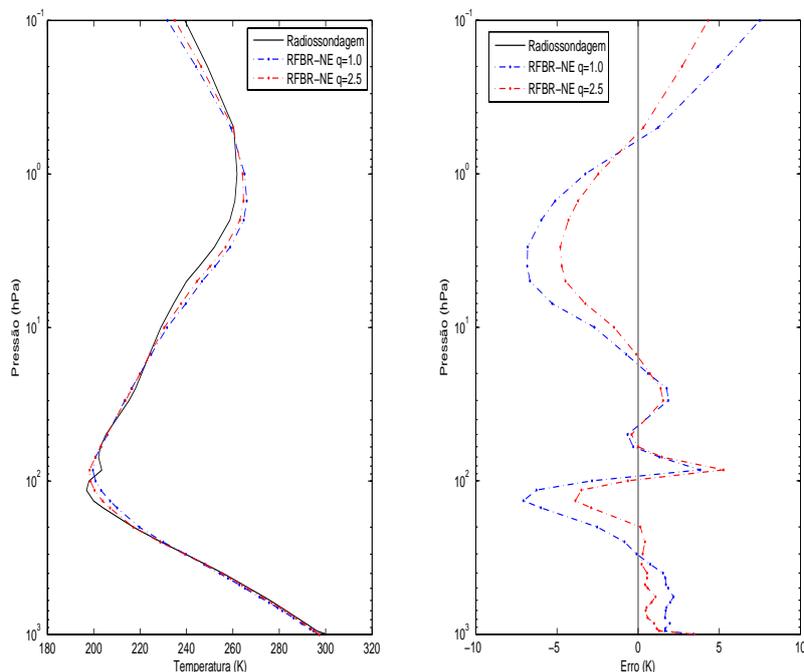


Figura 6.38 - Exemplo 2: (a) Perfil de temperatura obtido com a RFBR-NE e o banco TIGR-P, (b) erro da recuperação em relação à radiossondagem.

## 6.12 Resultados utilizando-se a RFBR-NE: conjuntos de dados Sintético e TIGR-P

Os testes com a junção do banco sintético e TIGR-P também foram realizados com a RFBR-NE. Os erros médios dos 348 perfis com a variação do parâmetro  $q$  são apresentados na Tabela 6.27. Os erros menores obtidos para cada camada atmosférica são destacados em negrito.

Tabela 6.27 - Generalização da RFBR-NE - banco Sintético + TIGR-P

$q$	Camada 1	Camada 2	Camada 3	Camada 4	Camada 5
0,5	0,7023	1,5797	2,8594	2,0310	1,3913
1,0	<b>0,4736</b>	1,2221	<b>2,4897</b>	1,5770	1,1683
1,5	0,5029	1,1977	2,6024	<b>1,3525</b>	1,1594
2,0	0,5323	1,1907	2,6065	1,3822	1,1424
2,5	0,5628	<b>1,1810</b>	2,6619	1,4636	<b>1,1271</b>

Dois exemplos de inversões com o uso da junção dos bancos são apresentados nas Figuras 6.39 e 6.40. Os perfis pertencentes ao banco contendo 348 não usados na fase de treinamento. Nas figuras, o perfil preto é a medida da radiossonda, o azul utilizando  $q = 1.0$  e o vermelho utilizando  $q = 1,5$

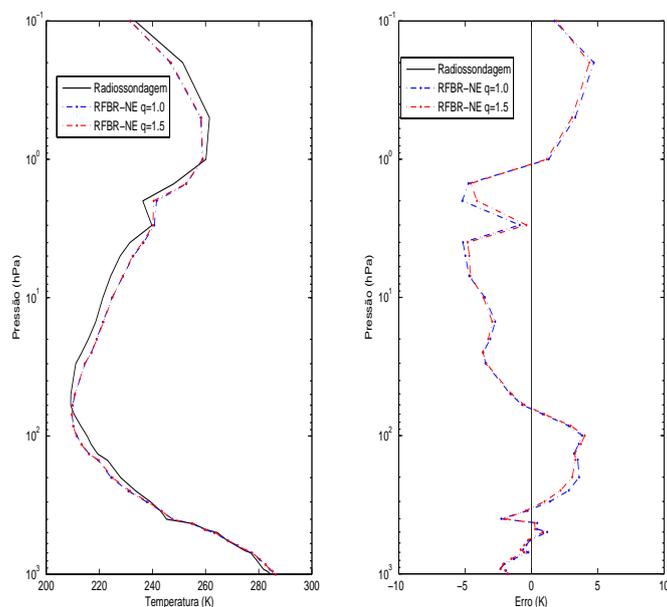


Figura 6.39 - Exemplo 1: (a) Perfil de temperatura obtido com a RFBR-NE, (b) erro da recuperação em relação à radiossondagem.

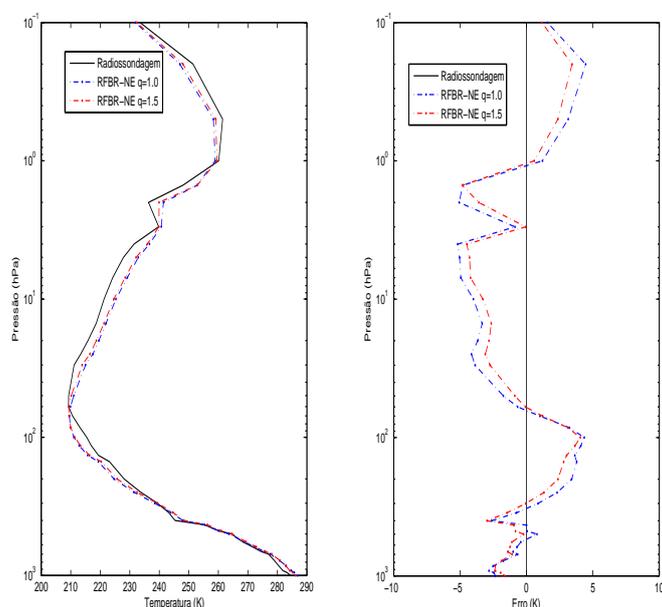


Figura 6.40 - Exemplo 2: (a) Perfil de temperatura obtido com a RFBR e o banco TIGR-P, (b) erro da recuperação em relação à radiossondagem.

Foram apresentadas estimações com a RFBR-NE em três bancos de dados diferentes, mostrando-se eficiente em todos. O emprego de um parâmetro  $q$  adequado resulta em estimações melhores.

### 6.13 Estimação de dados reais do HIRS/NOAA-14 com uso da RFBR-NE

Os dados reais medidos por satélites e comparados com medidas de radiossondagem também foram testados empregando-se a RFBR-NE. Assim como nos testes anteriores, foi efetuada a comparação entre o perfil de temperatura recuperado pela rede neural, pelos métodos de regularização (CARVALHO, 1998) e o perfil real da atmosfera medido por radiossondas. Os perfis estimados pela RFBR-NE são próximos aos perfis de radiossondagem. Inversões melhores que as obtidas com a rede neural Funções de Base Radial gaussiana são observadas variando-se os valores de  $q$ . Nas Figuras 6.41 e 6.42, as inversões obtidas com a RFBR-NE são apresentadas em azul, enquanto as inversões obtidas pelas regularizações de Tikhonov de ordem 1 em vermelho e Máxima Entropia de ordem 2 em preto-tracejado.

Para comparação das estimações obtidas pela RFBR e RFBR-NE utilizando-se o banco Sintético, a Figura 6.41 apresenta a comparação das inversões com  $q = 1, 0$ , enquanto a Figura 6.42 apresenta a comparação com  $q = 0, 5$ .

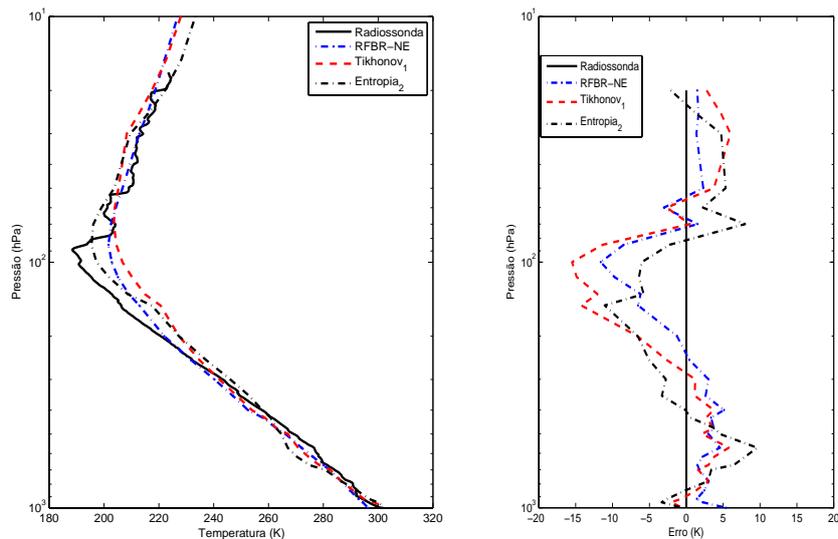


Figura 6.41 - (a) Perfil de temperatura obtido com a RFBR-NE com  $q = 1, 0$ , treinada com o banco sintético, (b) erro da recuperação em relação à radiossondagem.

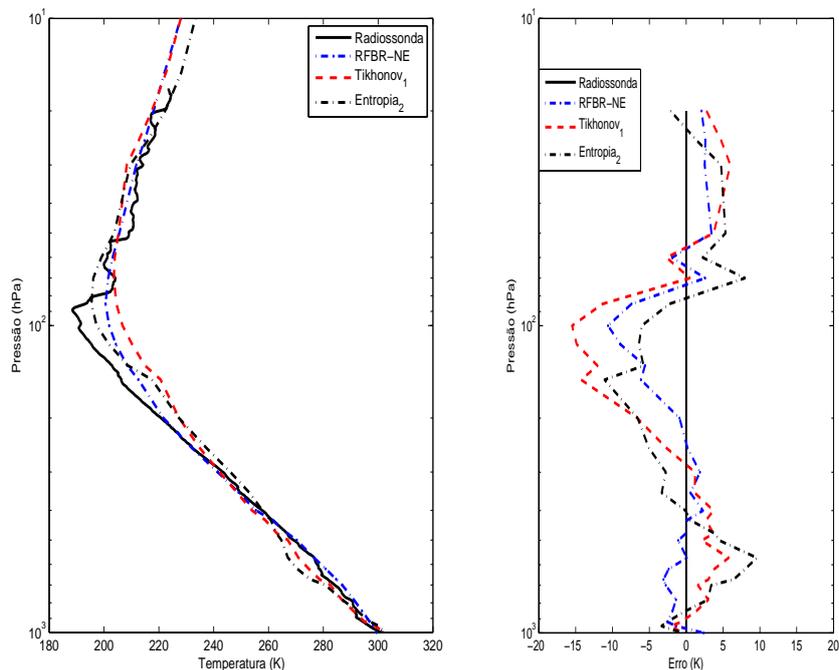


Figura 6.42 - (a) Perfil de temperatura obtido com a RFBR-NE com  $q = 0,5$ , treinada com o banco sintético, (b) erro da recuperação em relação à radiossondagem.

Pode-se observar que as inversões utilizando as redes neurais são melhores que as obtidas pelos métodos de regularização. O perfil de temperatura estimado com a RFBR-NE com  $q = 0,5$  é superior ao obtido com a RFBR gaussiana, principalmente nas camadas atmosféricas próximas à superfície terrestre.

Confirma-se o bom desempenho da RFBR-NE empregando-se o banco TIGR-P. Isto acontece na Figura 6.43 utilizando  $q = 1,0$  e na Figura utilizando 6.44 com  $q = 1,5$  (apresentadas em azul), que são comparados com a radiossondagem (preto), Tikhonov de ordem 1 (vermelho) e entropia de ordem 2 (preto-tracejado)

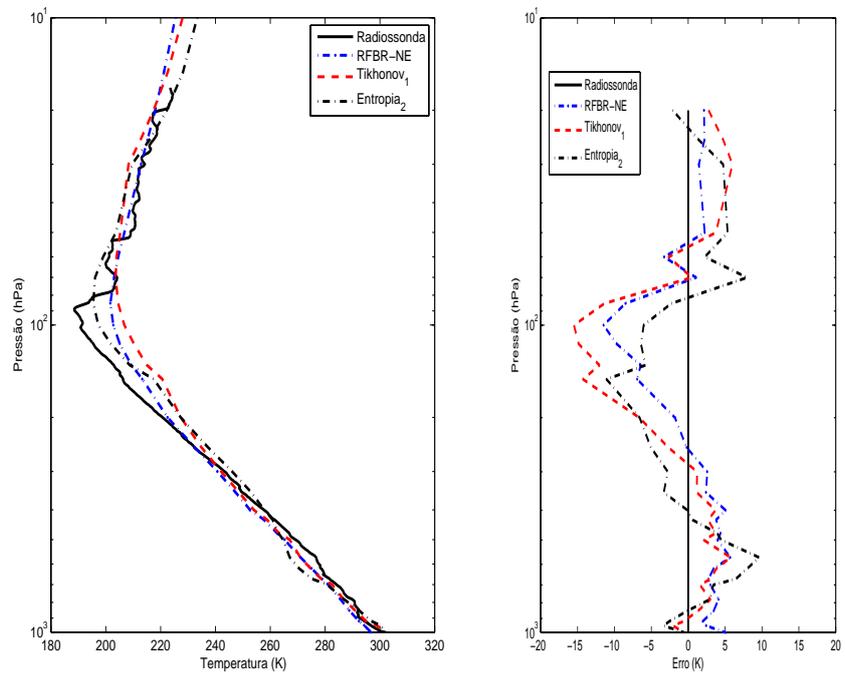


Figura 6.43 - (a) Perfil de temperatura obtido com a RFBR-NE com  $q = 1,0$ , treinada com o banco TIGR-P, (b) erro da recuperação em relação à radiossondagem.

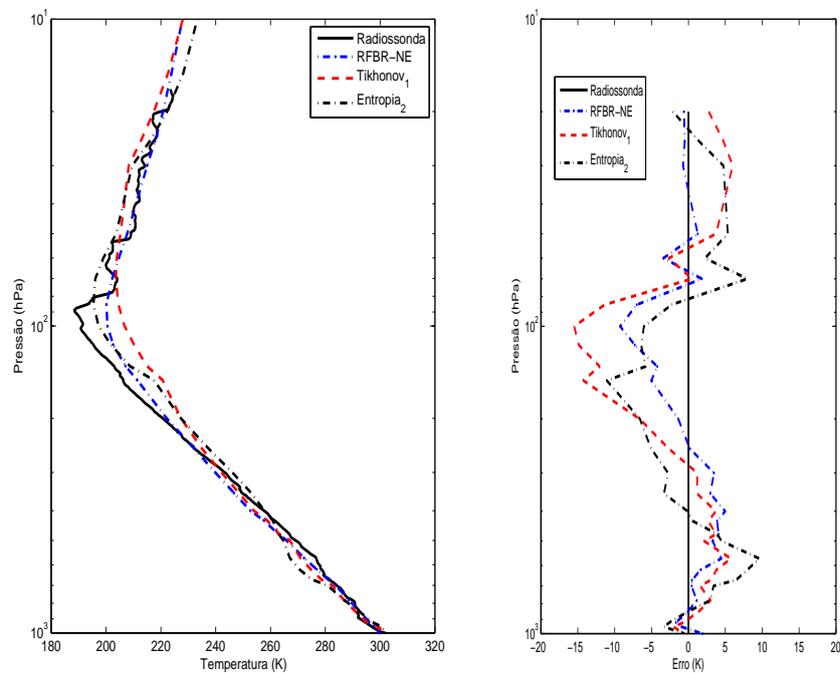


Figura 6.44 - (a) Perfil de temperatura obtido com a RFBR-NE com  $q = 1,5$ , treinada com o banco TIGR-P, (b) erro da recuperação em relação à radiossondagem.

A inversão com  $q = 0,5$  é superior aos perfis estimados pelas regularizações e ao obtido com  $q = 1,0$ , principalmente na camada 1, confirmando que um valor adequado de  $q$  pode melhorar o desempenho das inversões.

Concluindo-se os testes com a RFBR-NE, são apresentados os resultados com os dados reais obtidos com a rede treinada com o banco sintético+TIGR-P. Nas Figuras 6.45, 6.46 e 6.47 são mostradas, respectivamente, as inversões obtidas com  $q = 1,0$ ,  $q = 0,5$  e  $q = 1,5$ .

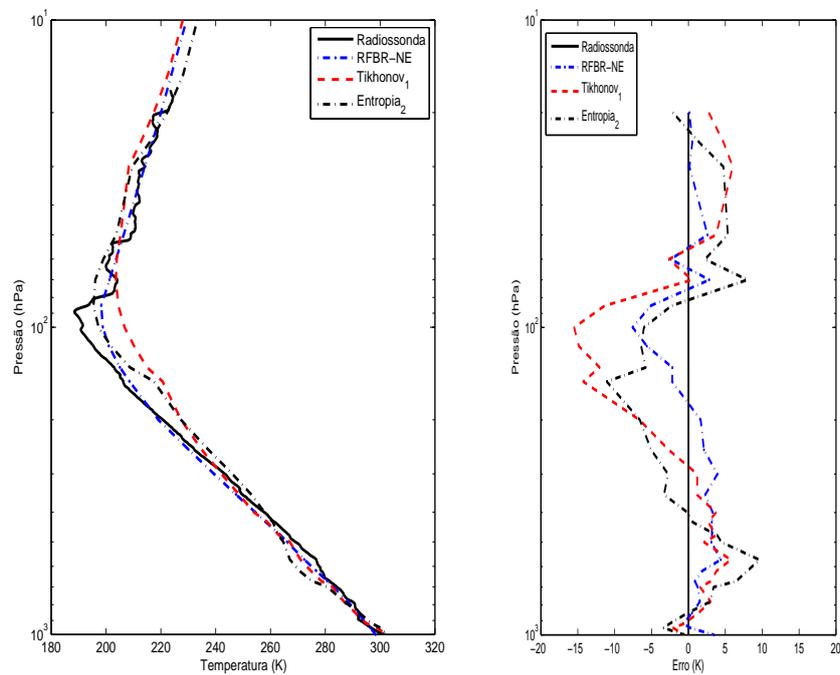


Figura 6.45 - (a) Perfil de temperatura obtido com a RFBR-NE com  $q = 0,5$ , treinada com o banco sintético+TIGR-P, (b) erro da recuperação em relação à radiossondagem.

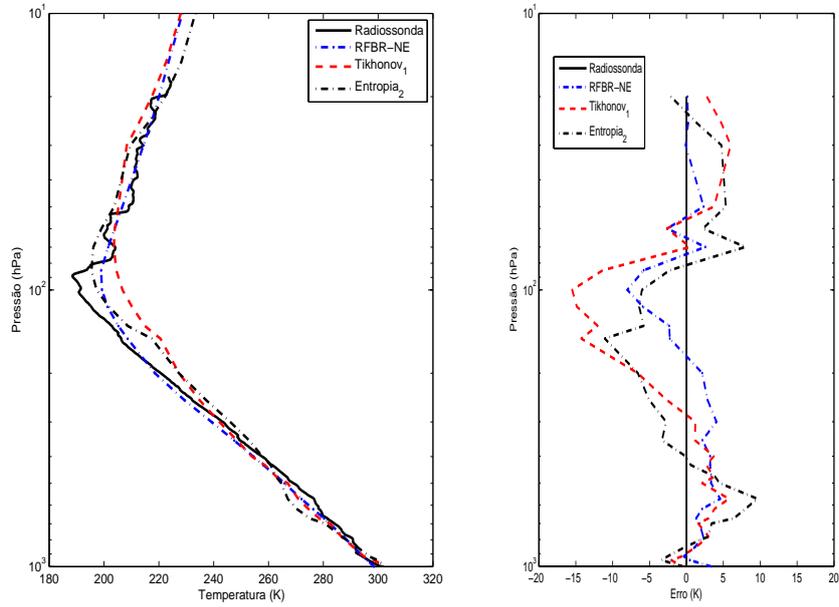


Figura 6.46 - (a) Perfil de temperatura obtido com a RFBR-NE com  $q = 1,0$ , treinada com o banco sintético+TIGR-P, (b) erro da recuperação em relação à radiossondagem.

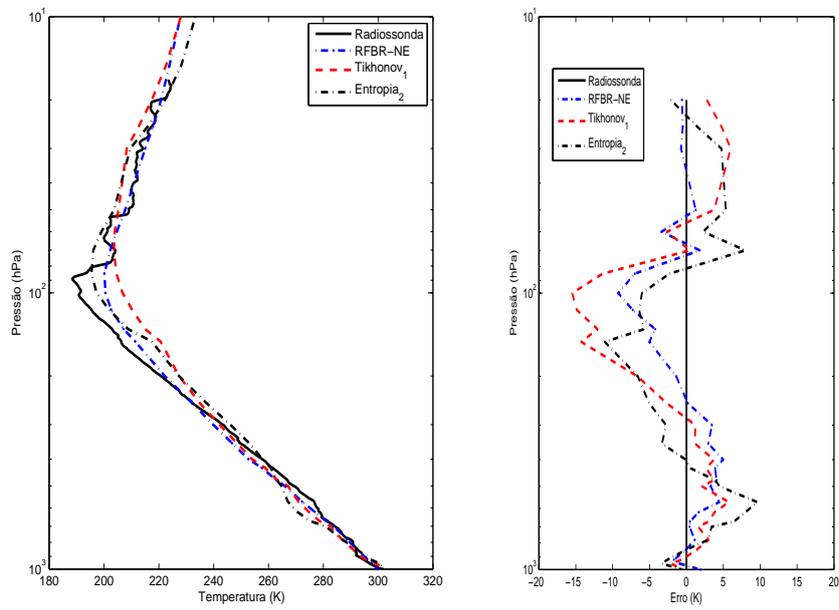


Figura 6.47 - (a) Perfil de temperatura obtido com a RFBR-NE com  $q = 1,5$ , treinada com o banco TIGR-P, (b) erro da recuperação em relação à radiossondagem.

Foram aplicados testes à RFBR-NE com 3 bancos de dados diferentes, cujas inversões comprovam sua eficiência. Nas três situações foi mostrado que um valor de  $q$  adequado pode melhorar a qualidade das inversões.

## 6.14 Emprego da Rede de Hopfield

Com um trabalho conjunto com a Universidade Federal de Minas Gerais (UFMG), onde aplicações prévias da rede de Hopfield foram realizadas em problemas inversos não-lineares (BRAGA *et al.*, 2000), (SEBASTIÃO *et al.*, 2003), a rede de Hopfield foi empregada na solução do problema inverso não-linear para estimar os perfis verticais de temperatura da atmosfera. Resultados preliminares foram apresentados em Viterbo *et al.* (2004). Uma vantagem da rede de Hopfield é que não é necessária a fase treinamento, por se tratar de uma rede neural não-supervisionada.

### 6.14.1 Estimação de dados reais do HIRS/NOAA-14 com uso da rede de Hopfield

A aplicação da rede de Hopfield nos dados reais obtidos pelo sensor HIRS-2 do satélite NOAA-14 foi efetuada. O perfil estimado é comparado com os métodos regularização (CARVALHO, 1998) e a temperatura medida por radiossondagem realizada durante a campanha de lançamento do VLS. As comparações das inversões são apresentadas na Figura 6.48. Na Figura 6.48-a) observa-se o perfil medido na radiossondagem em preto contínuo, em vermelho a inversão via Tikhonov de ordem 1, em preto-tracejado máxima entropia de ordem 2 e em azul a rede de Hopfield. Na Figura 6.48-b) o erro absoluto de cada perfil.

O problema inverso torna-se altamente indeterminado devido a limitações tecnológicas. O número de observações corresponde a uma fração do número de temperaturas estimadas nas camadas atmosféricas. Por exemplo, são estimados 40 valores de temperatura de 7 medidas de radiância. Na prática, o algoritmo de inversão operacional reduz o risco do erro cair num mínimo local iniciando o processo iterativo de busca com um valor inicial suficientemente próximo ao perfil verdadeiro. O perfil de temperatura estimado pela rede de Hopfield apresentado na Figura 6.48 foi obtido com um chute inicial constante em 302,30 K, a temperatura conhecida na superfície.

A evolução dos neurônios pode ser vista na Figura 6.49, que mostra a aprendizagem ao longo do tempo e a convergência. A boa performance da rede de Hopfield no

processo de inversão dos dados reais, que contém erros de medidas e ruídos, foi obtida após a aplicação de uma média móvel (VITERBO *et al.*, 2004).

O resultado final mostrou uma boa similaridade entre a recuperação da rede de Hopfield e as medidas de radiossondagem para o intervalo de 200 hPa a 100 hPa, como mostrado na Figura 6.48.

É mostrado em (CARVALHO, 1998), que a recuperação do modelo de inversão ITTP-5 depende do valor inicial. Reconstruções pobres são obtidas quando um perfil inicial homogêneo é apresentado (CARVALHO, 1998), (RAMOS *et al.*, 1999). Entretanto, a dependência da solução final na boa escolha de um chute inicial representa uma fragilidade nos algoritmos de inversão, particularmente nas regiões onde há menos informações a priori (CHEDIN *et al.*, 1985). Outra vantagem da rede de Hopfield aparece quando sua utilização é comparada com o uso de redes neurais com aprendizagem supervisionada, pois seu emprego não requer a fase de treinamento, que tem alto custo computacional e requer informações a priori, sendo estas as principais razões como algoritmo alternativo para o problema inverso.

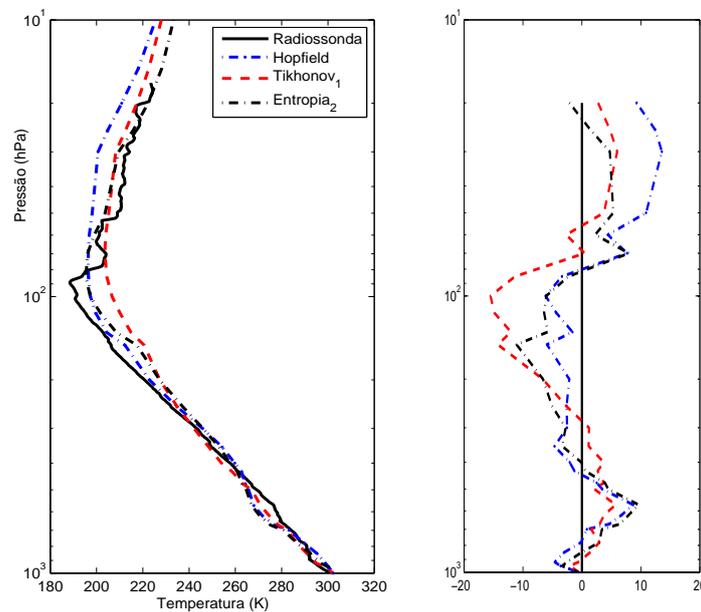


Figura 6.48 - (a) Perfil de temperatura obtido com a rede de Hopfield, (b) erro das recuperações em relação à radiossondagem.

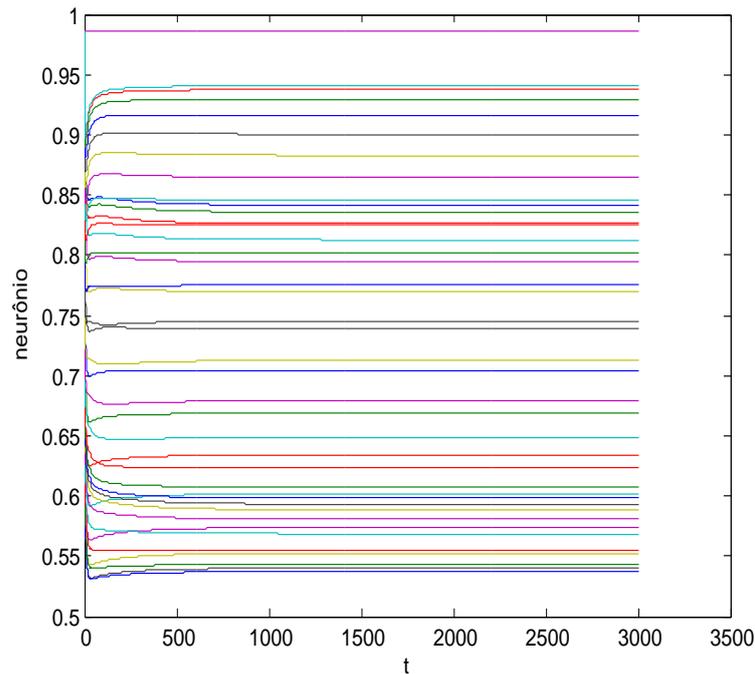


Figura 6.49 - Estados dos neurônios no tempo.

### 6.14.2 Estimação de perfis verticais de temperatura através da rede de Hopfield para o HIRS/NOAA-16

A rede de Hopfield foi testada utilizando os bancos TIGR e NESDISPR. Como não são necessárias as divisões dos conjuntos em subconjuntos de treinamento, validação e generalização, os erros das camadas apresentados nas Tabelas referentes à aplicação da rede HOP referem-se aos conjuntos completos.

### 6.14.3 Resultados utilizando-se o banco TIGR-C

Os erros apresentados na Tabela 6.28 referem-se à REMQ média dos 1761 perfis do banco TIGR-C. A condição de parada do processo de ativação foi a estabilização dos estados dos neurônios da rede neural. Dois exemplos de estimações dentre os 1761 perfis estimados do banco TIGR-C são apresentados com seus respectivos erros nas Figuras 6.50 e 6.51. A linha preta contínua mostra a medida da radiossonda e a tracejada o perfil estimado pela rede de Hopfield.

Tabela 6.28 - Generalização da Rede de Hopfield - banco TIGR-C

Camada 1	Camada 2	Camada 3	Camada 4	Camada 5
0,8438	2,7075	1,9718	2,9736	4,9279

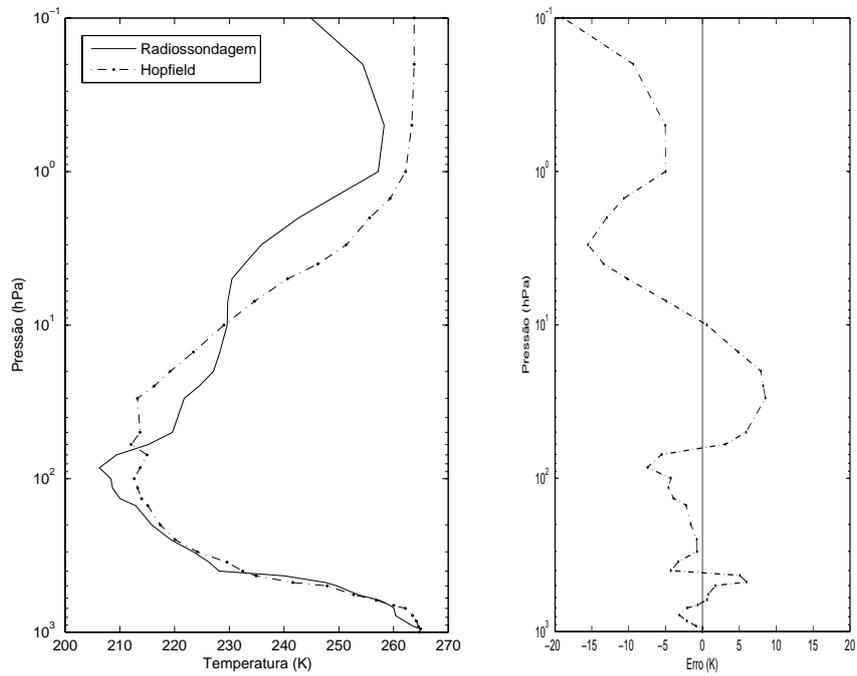


Figura 6.50 - Exemplo 1: (a) Perfil de temperatura obtido com a rede de Hopfield, (b) erro da recuperação em relação à radiosondagem.

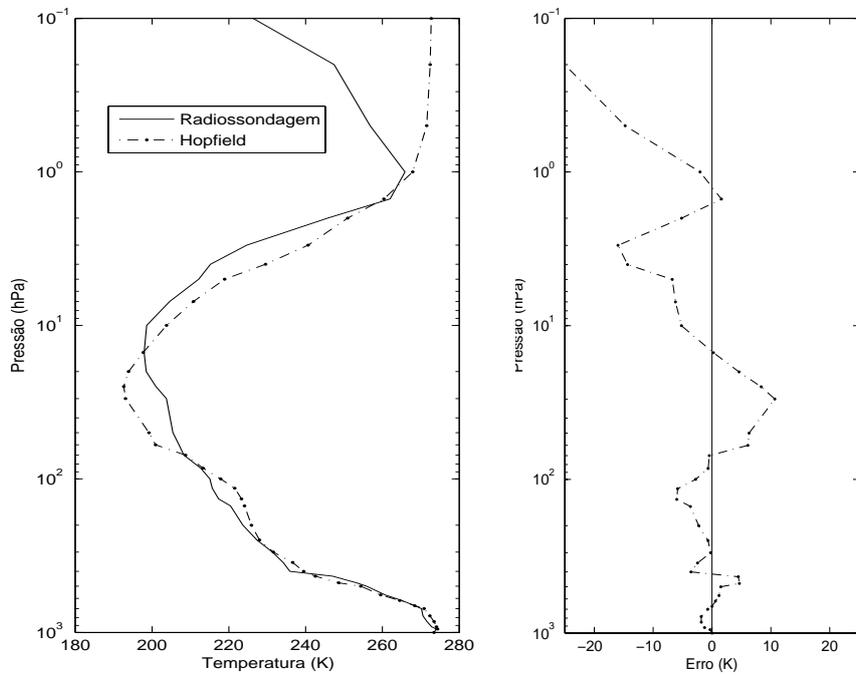


Figura 6.51 - Exemplo 2: (a) Perfil de temperatura obtido com a rede de Hopfield, (b) erro da recuperação em relação à radiosondagem.

A rede de Hopfield aplicada ao banco TIGR-C apresenta estimações melhores nas camadas próximas à superfície, região de maior importância para a meteorologia.

#### 6.14.4 Resultados utilizando o banco NESDISPR

Aplicando HOP nas estimações dos perfis de temperatura do banco NESDISPR, é observado que estimações com menor erro também são obtidas nas camadas próximas à superfície. A Tabela 6.29 contém as médias dos erros em cada camada das estimações dos perfis de temperatura do banco NESDISPR, com 1205 perfis. Dois exemplos das estimações e seus erros desse banco são apresentados nas Figuras 6.52 e 6.53.

Tabela 6.29 - Generalização da Rede de Hopfield - banco NESDISPR

Camada 1	Camada 2	Camada 3	Camada 4	Camada 5
0,8661	1,8457	4,2105	3,2149	4,6225

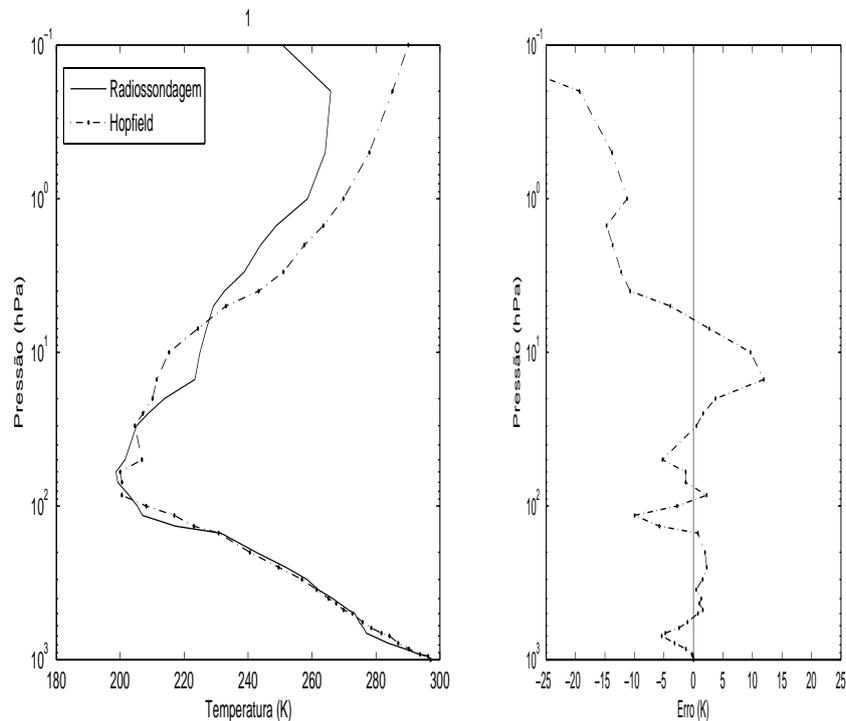


Figura 6.52 - Exemplo 1: (a) Perfil de temperatura obtido com a rede de Hopfield, (b) erro da recuperação em relação à radiossondagem.

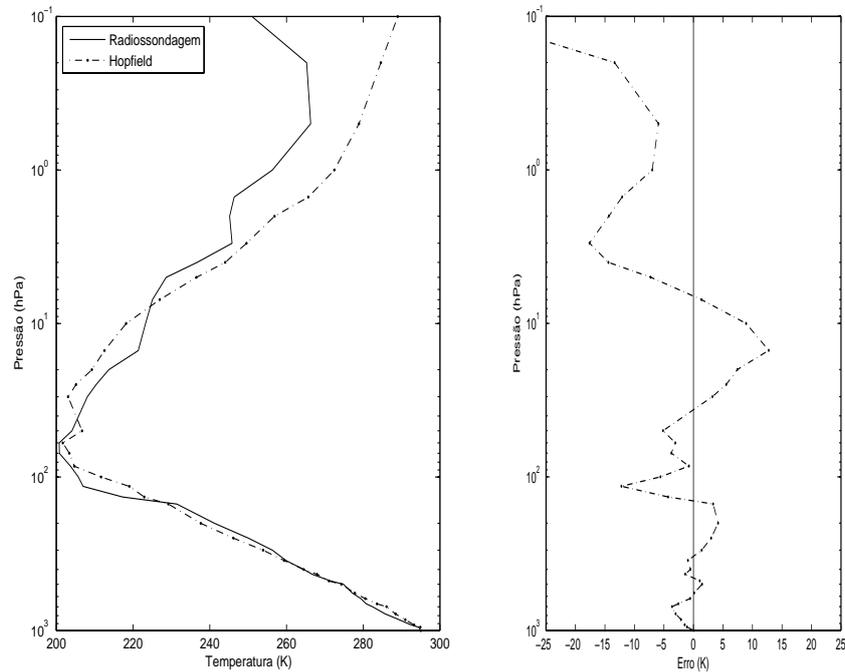


Figura 6.53 - Exemplo 2: (a) Perfil de temperatura obtido com a rede de Hopfield, (b) erro da recuperação em relação à radiosondagem.

A rede HOP foi submetida a testes com dados reais e com os dados globais, apresentando bons resultados principalmente nas camadas atmosféricas próximas à superfície terrestre. A não necessidade do treinamento da rede deve ser ressaltado, por estar livre de um conhecimento a priori das radiâncias e dados atmosféricos.

### 6.15 Estimação de perfis verticais de temperatura utilizando-se FPGA

A Rede Perceptron de Múltiplas Camadas que obteve melhores desempenhos nas inversões é configurada na FPGA. Somente a fase de ativação da RPMC é configurada, utilizando os pesos e limiares obtidos nas fases de treinamento, validação e testados na fase de generalização, uma vez que os treinamentos podem ser realizados numa estação de solo ou em algum computador que não seja embarcado, devido ao alto custo computacional.

Na Figura 6.54, o esquema de implementação da RNA em hardware é ilustrado. Neste trabalho os dois primeiros blocos são abordados.



Figura 6.54 - Passos para implementação

Na ativação, os sinais de entrada são multiplicados e somados, juntamente com os limiares, obtidos na fase de treinamento e passam pela função de ativação. Os resultados apresentados na seção 6.9. Foram obtidos numa arquitetura composta por uma única camada escondida e a camada de saída. A ativação da camada escondida é dada por:

$$y_{1j} = \varphi \left( \sum_{i=1}^p x_i w_{ij} + b_{1j} \right) \quad (6.4)$$

onde  $y_{1j}$  é a saída do neurônio  $j$ ,  $x_i$  a  $i$ -ésima entrada da rede neural e  $w_{ij}$  e  $b_j$  são, respectivamente, os pesos e limiares. A ativação da segunda camada é dada por:

$$y_{2j} = \varphi \left( \sum_{i=1}^p y_{1i} w_{ij} + b_{2j} \right). \quad (6.5)$$

A configuração em hardware requer modificações da arquitetura da rede neural, comparada com a solução em software, para que seja aplicada na FPGA. O primeiro passo é transformar os parâmetros da rede neural e as entradas do tipo real para o tipo inteiro. Essa abordagem é empregada em alguns trabalhos (KRIPS *et al.*, 2002), (ZHU; SUTTON, 2003), (CHEN; PLESSIS, 2002). Os valores são multiplicados por um fator constante e então é realizado o arredondamento.

A função de ativação  $\varphi$  utilizada em ambas as camadas foi a logística sigmoideal, (veja Equação 4.4). Esta função é não-linear e não é possível ser configurada diretamente da FPGA. Uma solução clássica para esse problema é o uso de uma tabela LUT ("Look-Up Table") (KRIPS *et al.*, 2002), (ZHU; SUTTON, 2003), que é uma estrutura de dados que substitui a execução de um cálculo através de relações. Na Figura

6.55 é apresentada a função logística sigmoidal, sendo destacados 15 pontos para implementação na LUT.

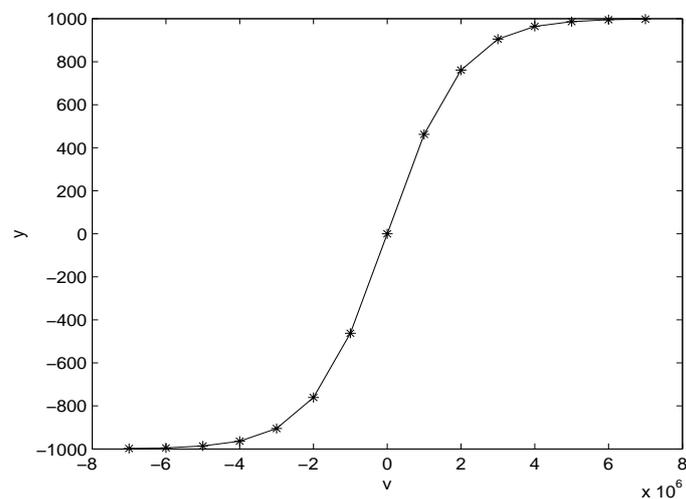


Figura 6.55 - Função de ativação

Um esquema da configuração da FPGA é apresentado na Figura 6.56. Os coeficientes adaptáveis obtidos na fase de treinamento são previamente armazenados no dispositivo, para serem utilizados na ativação da camada escondida e de saída assim que o vetor de entrada é apresentado. Estes coeficientes são destacados em cinza. Quando os sinais são recebidos, através da interface de entrada, são passados pelo dispositivo até que na interface de saída têm-se os dados atmosféricos.

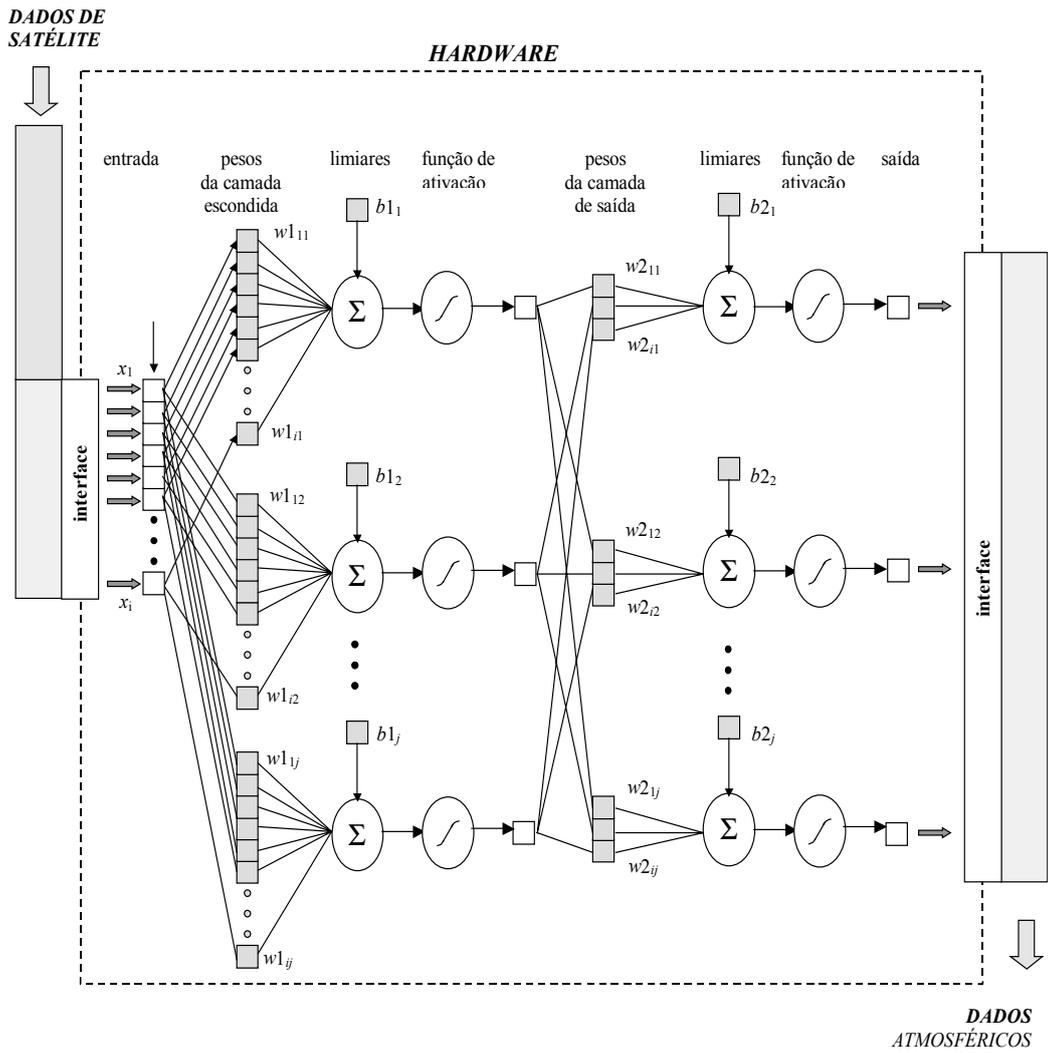


Figura 6.56 - Esquema de ativação

Como exemplo, é apresentada a ativação do primeiro neurônio da camada escondida da rede neural (Figura 6.57), com o somatório dos sinais de entrada multiplicados pelos pesos sinápticos mais o limiar. Em seguida, este sinal passa pela função de ativação. Este processo é realizado por todos neurônios da rede neural até serem apresentados os perfis verticais de temperatura em diferentes camadas da atmosfera.

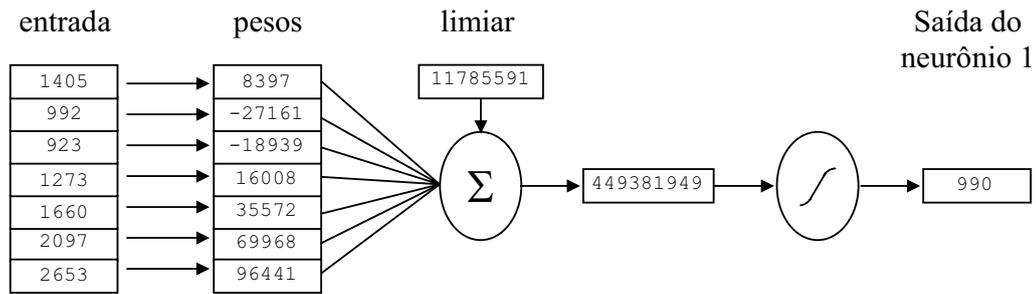


Figura 6.57 - Ativação do neurônio 1 da camada escondida da RPMC

Para configuração foram utilizadas 4 máquinas de estados: uma para o carregamento dos dados no buffer (Figura 6.58); uma para ativação da rede (6.59); uma para escrita das respostas no buffer (Figura 6.60) e uma para escrita dos dados na porta de saída (Figura 6.61).

Na máquina de estados-1, as entradas são armazenadas no buffer. Quando um sinal de entrada é recebido, se o número de canais não for igual ao número de canais total a ser utilizado pela rede neural, a entrada é armazenada no buffer. Este processo se repete até que o buffer esteja completo.

Na máquina de estados-2, quando o buffer está completo, o processo de ativação da rede neural é realizado. Como as redes neurais implementadas têm duas camadas, os estados 7 e 8 são necessários.

Na máquina de estados-3, as respostas da rede neural ( $y_2$ ) são escritas no buffer de saída.

A máquina de estados-4 é aplicada para escrever os resultados na interface de saída. Quando o buffer de saída está cheio, com o número de camadas da atmosfera com dados da rede neural, esse resultado é escrito na interface de saída.

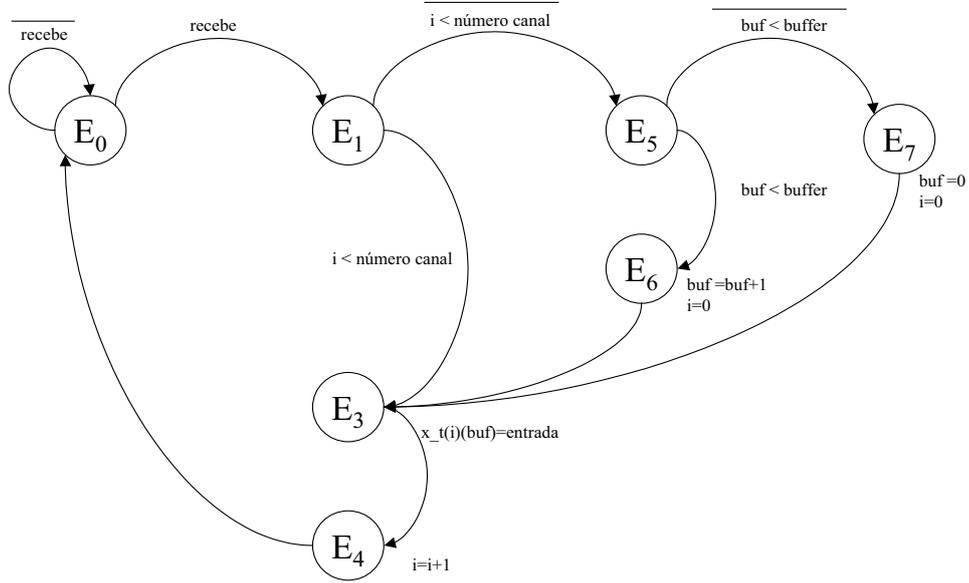


Figura 6.58 - Máquina de estados 1

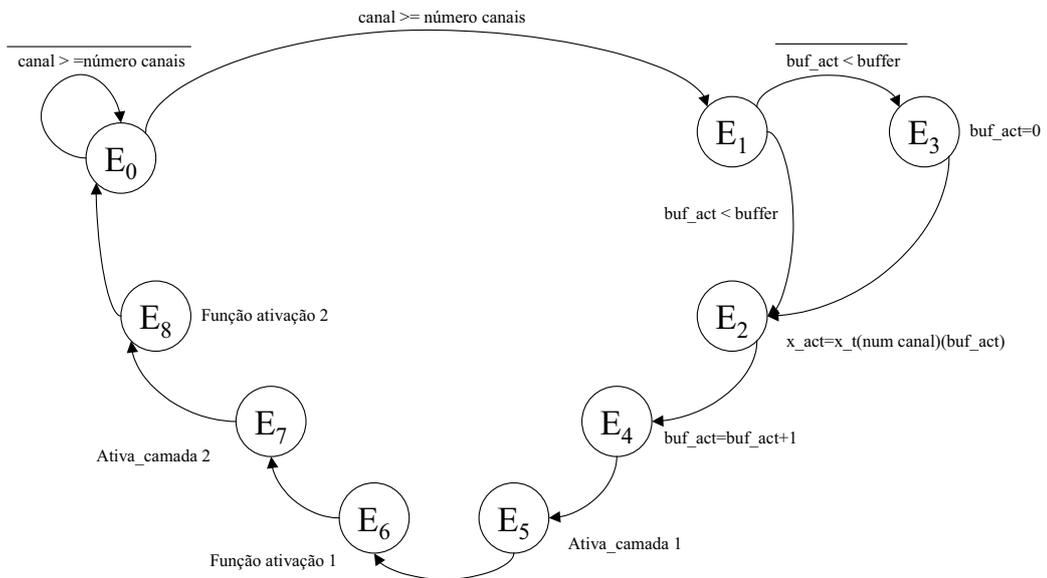


Figura 6.59 - Máquina de Estados 2

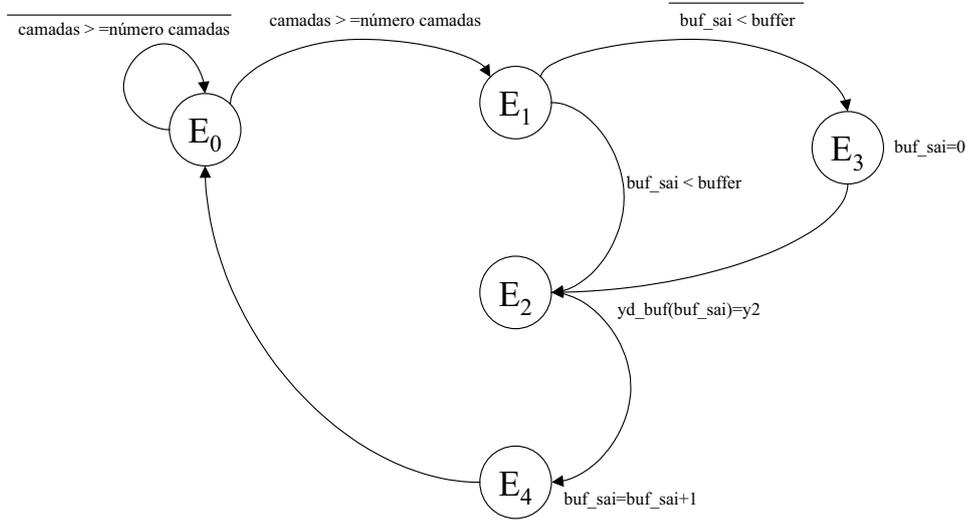


Figura 6.60 - Máquina de estados 3

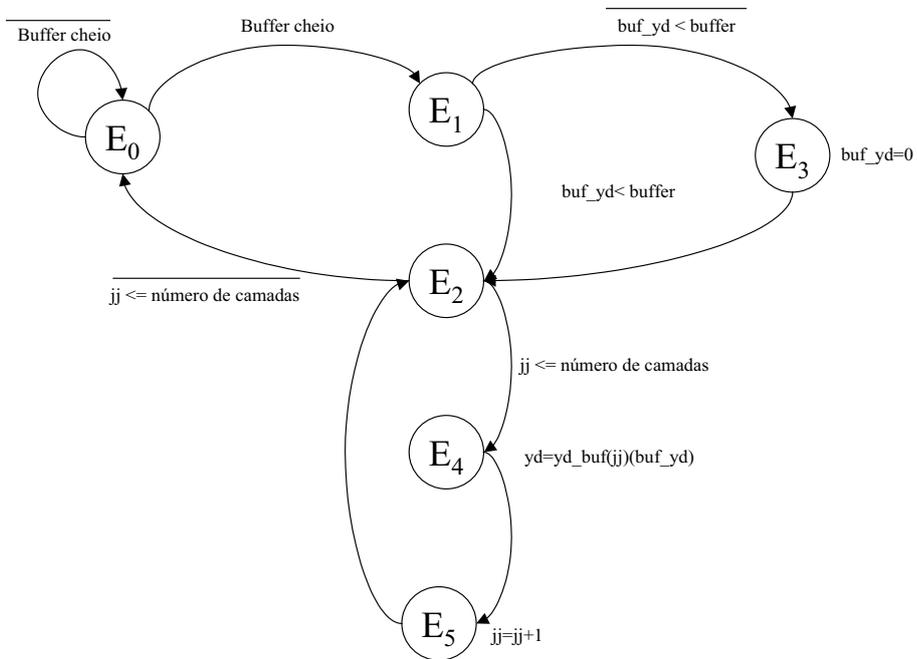


Figura 6.61 - Máquina de estados 4

## 6.16 Estimação de dados reais do HIRS/NOAA-14 utilizando-se FPGA

A configuração em FPGA é realizada empregando-se a arquitetura da RPMC com os pesos e limiares obtidos na fase de treinamento apresentados na seção 6.9.2. São utilizadas as radiâncias medidas pelo satélite NOAA-14 e o perfil de temperatura estimado é comparado com o perfil medido durante a campanha de lançamento do VLS. Resultados preliminares foram apresentados em Campos Velho *et al.* (2007b).

A configuração foi simulada utilizando-se o Simulador ModelSim, programa que executa simulações da configuração em hardware, considerando-se a FPGA XC3S200 do kit Spartan 3 da Xilinx (XILINX, 2004), apresentado na Figura 6.62.

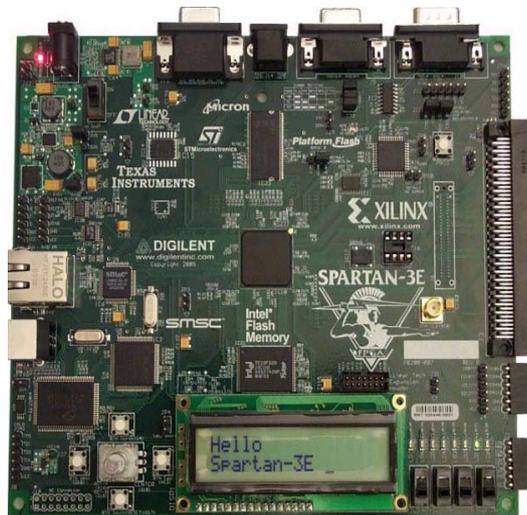


Figura 6.62 - Kit Spartan III

Um exemplo da simulação utilizando o ModelSim é apresentado na Figura 6.63.

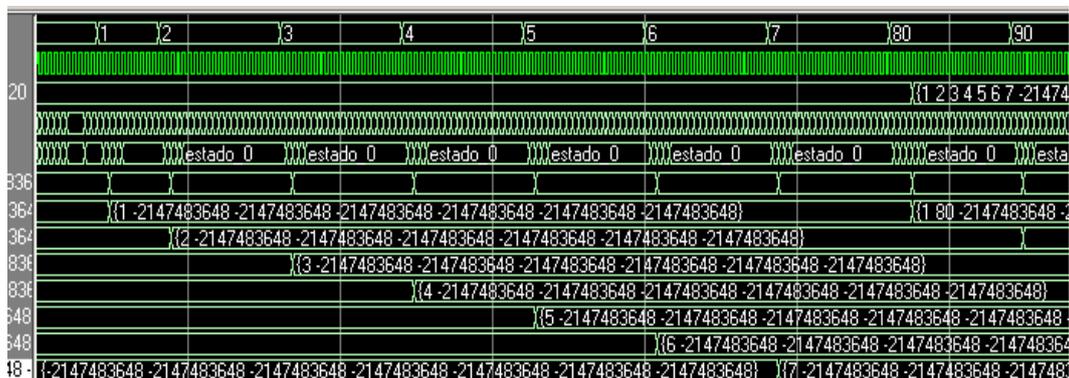


Figura 6.63 - Simulação com ModelSim

A estimação da FPGA é comparada com a implementação em software Fortran. Na Figura 6.64 são apresentadas as inversões estimadas com Fortran, em vermelho, com a configuração da FPGA, em azul, e da radiossondagem, em preto.

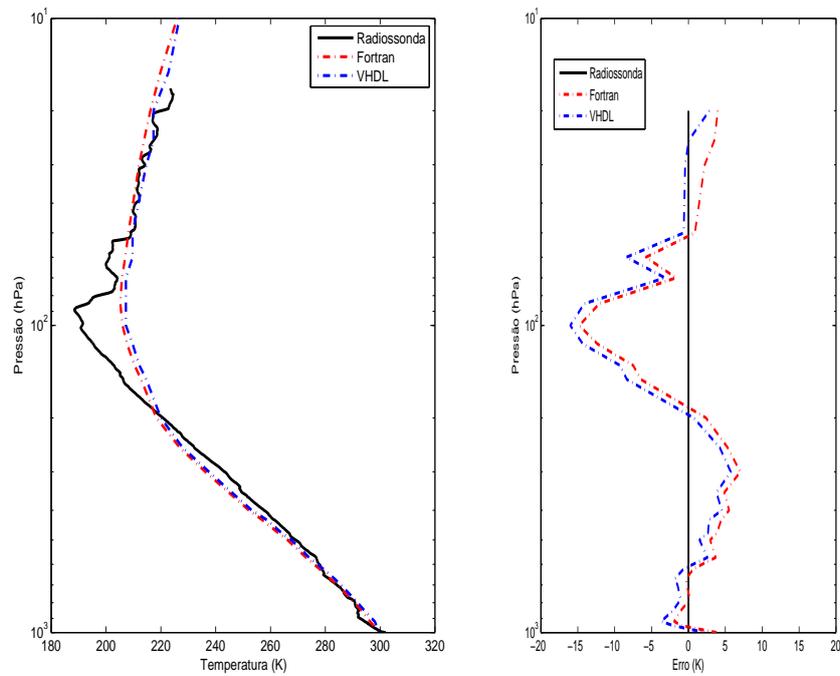


Figura 6.64 - (a) Comparação das estimções em Fortran e VHDL com a radiossondagem, (b) erros das estimções.

Como é observado, não há diferença significativa entre as duas estimções. O pequeno deslocamento entre os perfis se dá pela utilização de ponto-fixe e amostragem da função de ativação. Esta configuração possibilita a solução do problema inverso na estimação de dados atmosféricos em tempo-real e embarcada. A metodologia pode ser facilmente migrada para soluções de outros problemas inversos que empregam RNA em suas soluções, requerendo somente treinamentos relacionados às inversões.



## CAPÍTULO 7

### CONCLUSÕES

Através do sensoriamento remoto, as informações de áreas ou fenômenos podem ser coletadas e utilizadas para previsão numérica do tempo e clima, contribuindo para melhorar a qualidade de vida da sociedade.

Com o número crescente de informações disponibilizadas por satélites, são desejados modelos com baixo custo computacional para processar grandes quantidades de dados. As informações obtidas são importantes, principalmente em países como o Brasil, com grandes extensões territoriais, com acesso difícil em áreas remotas e devido ao alto custo para obtenção de medidas de radiossondagens.

O emprego das redes neurais na solução do problema inverso para recuperar dados atmosféricos a partir de dados de satélites vem ao encontro das tais necessidades, principalmente com a implementação em hardware, que pode resolver o problema inverso em tempo-real. As vantagens no emprego das técnicas de redes neurais estão no baixo custo computacional, tolerância a falhas e adaptabilidade. O funcionamento simples das redes neurais as tornam apropriadas para implementação em hardware.

Neste trabalho foram testados alguns modelos de redes neurais, dentre os vários apresentados na literatura, com características de modelos simples, rápidos, precisos e que generalizam de maneira abrangente. Foram utilizadas as redes RPMC, RFBR, RFBR-NE e rede de Hopfield, sendo a RPMC implementada em dispositivos lógicos programáveis.

O processo de inversão da ETR é altamente indeterminado e instável com relação aos ruídos inerentes aos instrumentos de medidas. Todos os modelos de redes neurais empregados neste trabalho mostraram-se robustos mesmo com a adição de 5% de ruído nas radiâncias e nos testes com dados medidos por satélite e comparados com radiossondagem.

A recuperação dos dados atmosféricos utilizando-se redes neurais com aprendizagem supervisionada demandou a solução do modelo direto para formar os conjuntos de treinamento, validação e generalização. Duas fontes de dados da solução do modelo direto foram utilizadas: a solução da Equação de Transferência Radiativa resolvida por diferenças finitas e o modelo RTTOV, modelo utilizado no CPTEC/INPE. Foi

mostrado que as redes neurais apresentam bom desempenho no processo de inversão para estes dados, o que disponibiliza a metodologia para ser implementada de forma operacional.

A rede de Hopfield com aprendizagem não-supervisionada foi empregada na solução do problema inverso não-linear, apresentando boa performance principalmente nas camadas próximas à superfície terrestre. As redes com aprendizagem não-supervisionada não necessitam das causas e efeitos conhecidos ou observados, utilizados na fase de treinamento das redes supervisionadas.

Os perfis verticais de temperatura estimados pelas redes neurais foram comparados com os resultados obtidos com o método clássico de solução de problemas inversos (técnica de regularização), utilizando radiâncias reais medidas pelo satélite NOAA-14 e comparado com perfil medido por radiossondagem. Sistemáticamente, os resultados das RNAs foram superiores aos obtidos pelos métodos clássicos de inversão.

A análise dos erros foi feita em 5 subcamadas da atmosfera, sempre aplicando uma atenção maior às camadas próximas à superfície, 1 e 2, regiões de maior interesse para os modelos meteorológicos.

Foram realizados testes com dados globais empregando-se dois grandes bancos de perfis meteorológicos TIGR e NESDISPR. Nestes testes as RNAs mostraram bom desempenho também com dados ruidosos. Dados específicos do Brasil foram testados com utilização do banco CLASS1 que demandou um número menor de neurônios na camada escondida, quando comparada com a estimação de dados globais. Uma arquitetura menor, mas que apresente boa capacidade de generalização é desejada para implementação em hardware por consumir menos recursos. Além disso, um banco com perfis sintéticos de temperatura também foi utilizado. Muitos casos mostraram resultados melhores com a junção dos bancos de dados atmosféricos.

Em razão dos pesos e limiares das redes neurais, da seleção dos perfis que formam o conjunto de treinamento na divisão dos dados para treinamento e generalização e dos ruídos adicionados às radiâncias serem aleatórios, na utilização da RPMC foram realizados 5 experimentos utilizando diferentes sementes geradoras destes dados aleatórios. Como pode ser observado através dos desvios padrão dos experimentos da RPMC, não houve variações significativas entre os experimentos, mostrando a dependência dos valores aleatórios utilizados. Foi proposta uma nova abordagem

para a RFBR baseada na estatística não-extensiva de Tsallis, que apresentou resultados melhores que os obtidos com a RFBR com funções gaussianas nas diferentes camadas atmosféricas. Com o emprego de diferentes valores para os parâmetros da RFBR-NE houve melhora nas inversões, principalmente nas camadas atmosféricas 1 e 2.

A rede com melhor desempenho no processo de inversão foi configurada em FPGA utilizando-se linguagem de descrição de hardware VHDL. Com a configuração em hardware não houve diferenças significativas no perfil de temperatura estimado, viabilizando recuperação de dados atmosféricos em tempo-real e embarcado.

As principais contribuições do trabalho são:

- a aplicação de redes neurais num problema importante para meteorologia, onde as redes neurais supervisionadas configuradas (após treinamento), constituem-se em soluções de custo computacional mais baixo do que os métodos de otimização para análise inversa;
- a estimação de perfis de temperatura por RNA obteve o melhor resultado de inversão em relação ao ITPP-5 e métodos de regularização;
- a implementação das redes neurais em dispositivos de hardware reduz de forma dramática o tempo de processamento, permitindo seu emprego como um novo componente para sensores embarcados e produzindo resultados de inversão quase em tempo real.
- a proposta de uma nova rede de base radial: a RFBR não-extensiva, que trouxe uma melhoria na solução inversa para o problema de estimação do perfil de temperatura atmosférica, em relação a RFBR padrão;
- o uso da rede de Hopfield em mais um problema não-linear;
- para a área de problemas inversos, a apresentação de uma metodologia capaz de inverter em tempo-real e embarcado, aplicada em muitos problemas inversos como restauração de imagens médicas, problemas de condução de calor, detecção de danos, estimação de dados atmosféricos e que não requer solução de um modelo direto.

Com o bom desempenho das estimações dos dados atmosféricos e sendo um dos primeiros trabalhos no Brasil para disponibilizar tais dados em tempo-real e

embarcado, o método da rede neural em FPGA como um dispositivo para sensor de satélite meteorológico encontra-se em fase de solicitação de patente.

Durante a realização do doutorado, foi firmado um projeto de cooperação entre o LAC e a DSA/CPTEC, do qual destacam-se as etapas realizadas:

- a) utilização de bancos de dados (perfis atmosféricos de temperatura e de umidade construídos a partir dos dados de radiossondagens disponíveis na DSA-CPTEC);
- b) utilização do Modelo direto RTTOV-7 para gerar as radiâncias dos canais do HIRS/NOAA-16 e AIRS/AQUA para cada uma das radiossondagens desse banco de dados;
- c) criação de um segundo banco de dados (perfis e radiâncias) com um ruído gaussiano de 5%.

Como trabalhos futuros da pesquisa abordada na tese destaca-se:

- aplicação das abordagens de redes neurais artificiais e implementação em hardware para estimar outros dados atmosféricos da atmosfera, além da temperatura e umidade, como por exemplo CO<sub>2</sub> (trabalho preliminar ver (CARVALHO *et al.*, 2007));
- aplicação de outros tipos de ruídos no treinamento das redes neurais com distribuições diferentes à gaussiana para simular os dados ruidosos medidos pelos satélites;
- estudo da aplicação da metodologia com a presença de nuvens utilizando-se outros canais dos sensores à bordo dos satélites;
- aplicação da metodologia com os dados de novos sensores que são construídos com calibração em faixas e subfaixas específicas do espectro eletromagnético para captura de novos fenômenos, que geram um grande aumento no volume de dados envolvidos nos processos de inversão matemática e exigem, portanto, muito mais recursos computacionais e mais tempo para o processamento;
- avaliação do desempenho dos modelos numéricos de assimilação de dados com a utilização dos dados atmosféricos obtidos pela metodologia para avaliar possíveis melhoras na previsão fornecida por estes modelos;

- emprego de diferentes métodos para ajuste do parâmetro livre  $q$  na rede neural Funções de Base Radial Não-Extensiva, como por exemplo algoritmos genéticos, além de estudar os outros fatores da construção da RFBR-NE combinada com outros algoritmos de seleção dos centros das funções e algoritmos de determinação dos pesos da camada de saída da rede neural;
- emprego de escalas de tempos diferentes para os neurônios da rede de Hopfield, além de avaliar o desempenho da rede neural apresentando as condições iniciais utilizadas pelos sistemas de estimação de dados atmosféricos ITPP-5 e ICI.
- implementação na FPGA outras arquiteturas de redes neurais, avaliando-se o desempenho ds inversões em tempo-real e embarcadas.



## REFERÊNCIAS BIBLIOGRÁFICAS

- AIRES, F.; CHEDIN, A.; SCOTT, N.; ROSSOW, W. A regularized neural net approach for retrieval of atmospheric and surface temperatures with the iasi instrument. **Journal of Applied Meteorology**, v. 2, n. 41, p. 144–159, 2002. [31](#)
- ALIFANOV, O. Solution of an inverse problem of heat conduction by iteration methods. **Journal of Engineering Physics**, v. 26, n. 11, p. 471–476, 1974. [49](#), [56](#)
- ALMEIDA, M. B.; BRAGA, A. P.; BRAGA, J.; BELCHIOR, J. C.; YARED, G. F. Radial basis function network for obtaining long range dispersion coefficients from second virial data. **Physical Chemistry Chemical Physics**, v. 2, p. 103–107, 1999. [57](#)
- ATALLA, M.; INMAN, D. On model updating using neural networks. **Mechanical Systems and Signal Processing**, v. 12, n. 1, p. 135–161, 1998. [57](#)
- AZOUAOU, O.; CHOHRRA, A. Soft computing based pattern classifiers for the obstacle avoidance behavior of intelligent autonomous vehicles (iav). **Applied Intelligence**, v. 3, n. 16, p. 249–272, 2002. [87](#)
- BERTERO, M.; BOCCACCI, P. **Introduction to Inverse Problems in Imaging**. Bristol: Taylor & Francis, 1998. 351 p. ISBN-13: 978-0750304351. [49](#), [50](#), [51](#), [55](#), [56](#)
- BLACKWELL, W. J. Neural network retrieval of atmospheric temperature and moisture profiles from cloud-cleared airs/amsu radiances. **IEEE Transactions on Geoscience and Remote Sensing**, v. 42, n. 5, p. 985–990, 2004. [31](#)
- \_\_\_\_\_. A neural-network technique for the retrieval of atmospheric temperature and moisture profiles from high spectral resolution sounding data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 11, n. 43, p. 2535–2546, 2005. [31](#)
- BOLUDA, J. A.; PARDO, F. A reconfigurable architecture for autonomous visual-navigation. **Machine Vision And Applications**, v. 5-6, n. 13, p. 322–331, 2003. [87](#)
- BRAGA, A.; CARVALHO, A.; LUDERMIR, T. B. **Redes Neurais Artificiais Teorias e aplicações**. Rio de Janeiro: LTC, 2000. 262 p. [60](#), [65](#), [66](#), [67](#), [79](#)

BRAGA, J. P. Numerical comparison between tikhonov regularization and singular value decomposition methods using the l curve criterion. **Journal of Mathematical Chemistry**, v. 29, p. 151–156, 2001. [56](#)

BRAGA, J. P.; ALMEIDA, M. B. de; BRAGA, A. P.; BELCHIOR, J. C. Hopfield neural network model for calculating the potential energy function from second virial data. **Chemical Physics**, n. 260, p. 347, 2000. [57](#), [83](#), [84](#), [146](#)

BROOMHEAD, D. S.; LOWE, D. Multivariable functional interpolation and adaptive networks. **Complex Systems**, v. 2, p. 321–355, 1988. [76](#)

Campos Velho, H. de; RAMOS, F.; SHIGUEMORI, E.; CARVALHO, J. A unified regularization theory: The maximum non-extensive entropy principle. **Computational and Applied Mathematics**, v. 25, p. 307–330, 2007. [56](#), [77](#)

Campos Velho, H. de; SILVA, J. da; SHIGUEMORI, E. Hardware implementation for the atmospheric temperature retrieval from satellite data. In: IPDO, II., 2007, Florida, USA. **Inverse Problems, Design and Optimization Symposium**. Miami Beach: Florida, 2007. p. 082. [158](#)

CARVALHO, A. R.; CARVALHO, J. C.; SHIGUEMORI, E. H.; SILVA, J.; RAMOS, F. M. Neural network based models for the retrieval of methane concentration vertical profiles from remote sensing data. In: SOCIEDADE BRASILEIRA DE METEOROLOGIA, 2007, Florianópolis - Brasil. **Anais do XIV Congresso Brasileiro de Meteorologia**. [S.l.], 2007. [58](#), [164](#)

CARVALHO, J. C. **Inferência de perfis verticais de temperatura utilizando uma técnica iterativa implícita de inversão**. 102 p. (INPE-7228/TDI/682). Dissertação (Mestrado em Meteorologia) — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 1998. [30](#), [35](#), [41](#), [43](#), [45](#), [46](#), [47](#), [51](#), [101](#), [102](#), [104](#), [106](#), [108](#), [114](#), [115](#), [128](#), [133](#), [141](#), [146](#), [147](#)

CASTRO, A. P. A.; SILVA, J. D. S. Multiscale image restoration: Neural network based approach. In: IPDO, 2007, Miami-USA. **Inverse Problems, Design and Optimization Symposium**. [S.l.], 2007. [58](#)

\_\_\_\_\_. Neural network based multiscale image restoration approach. In: SPIE, 2007, CA-USA. **Proceedings of SPIE - Image Processing: Algorithms and Systems**. [S.l.], 2007. [58](#)

CHAHINE, M. T. Determination of the temperature profile in an atmosphere from its outgoing radiance. **Journal of the Optical Society of America**, p. 1634–1637, 1968. [29](#)

CHEDIN, A.; SCOTT, C. W. N.; MOULINIER, P. The improved initialization inversion method : a high resolution physical method for temperature retrievals from satellites of the tiros-n series. **J. Climate Appl. Meteor.**, v. 24, p. 128–143, 1985. [47](#), [99](#), [128](#), [147](#)

CHEN, S.; COWAN, C. F. N.; GRANT, P. M. Orthogonal least squares learning algorithm for radial basis function networks. **IEEE Transaction on Neural Networks**, v. 2, p. 302–309, 1991. [76](#), [79](#)

CHEN, Y.; PLESSIS, W. Neural network implementation on a fpga. In: AFRICON, 2002. **Africon Conference in Africa**. [S.l.]: IEEE, 2002. p. 337– 342. [152](#)

CHIWIACOWSKY, L.; CAMPOS VELHO, H. Different approaches for the solution of a backward heat conduction problem. **Inverse Problems in Engineering**, v. 11, n. 6, p. 417–494, 2006. [56](#)

CINTRA, R.; SILVA, J. da; CAMPOS VELHO, H. de. Aplicação de redes neurais artificiais para estimação se perfis se temperatura utilizando dados se ocultação gps. In: CONGRESSO BRASILEIRO DE METEOROLOGIA, 2006, Brasil. **Congresso Brasileiro de Meteorologia**. Florianópolis, 2006. [58](#)

\_\_\_\_\_. Retrieval of humidity profiles with radio occultation measuerements using an artifial neural networks. In: IPDO-2007, 2007, Miami-USA. **Inverse Problems, Desing and Optimization Symposium**. Miami, 2007. [58](#)

D'AMORE, R. **VHDL - Descrição e síntese de circuitos digitais**. Rio de Janeiro: LCT, 2005. 260 p. [95](#)

DIAZ, J.; ROS, E.; CARRILLO, R.; PRETO, A. Real-time system for high-image resolution disparity estimation. **IEEE Trans. on Image Processing**, v. 1, n. 16, p. 280–285, 2007. [87](#)

DIEGO, G.; LOYOLA, R. Applications of neural network methods to the processing of earth observation satellite data. **Neural Networks**, v. 19, p. 168–177, 2006. [31](#)

DILLINGER, P.; VOGELBRUCH, J. F.; LEINEN, J.; SUSLOV, S.; PATZAK, R. Fpga-based real-time image segmentation for medical systems and data processing. **IEEE Trans. on Nuclear Science**, v. 4, n. 53, p. 2097–2101, 2006. 87

DUDA, R. O.; HART, P. E. **Pattern Classification and Scene Analysis**. New York: Wiley, 1973. 680 p. 75

DULIKRAVICH, G.; MARTIN, J. T.; DENNIS, B. H. Multidisciplinary inverse problems. In: INTERNATIONAL CONFERENCE ON INVERSE PROBLEMS IN ENGINEERING, 3., 1999, WA, USA. **Proceedings of Inverse Problems in Engineering: Theory and Practice**. Port Ludlow, 1999. p. 13–18. 49

ELSHAFIEY, I.; UDPA, L.; UDPA, S. Application of neural networks to inverse problems in electromagnetics elshafiey. **IEEE Transactions on Magnetics**, v. 30, n. 5, p. 3629 – 3632, 1994. 57

ENGL, H.; HANKE, M.; NEUBAUER, A. **Regularization of Inverse Problems: Mathematics and its Applications**. Dordrecht: Kluwer Academic Publishers, 1996. 336 p. 49, 55

ERCEGOVAC, M. D.; LANG, T.; MORENO, J. H. **Introdução aos Sistemas Digitais**. Porto Alegre: Bookman, 2000. 453 p. 94

FERREIRA, N. J. **Aplicações Ambientais Brasileiras dos Satélites NOAA e TIROS-N**. São Paulo, Brasil: Oficina de Textos, 2004. 272 p. ISBN 858623835X. 15, 35, 36, 44, 45, 46, 47

FLEMING, H. E.; MCMILLIN, L. M. Atmospheric transmittance of an absorbing gas 2: computationally fast and accurate transmittance model for slant paths at different zenith angles. **Applied Optics**, v. 16, n. 5, p. 1366–1370, 1977. 29

FONSECA, I. , 2006. Disponível em: <[http://www.aeb.gov.br/area/PDF/aebescola/AEBNucleo\\_de\\_Satelites\\_2.pdf](http://www.aeb.gov.br/area/PDF/aebescola/AEBNucleo_de_Satelites_2.pdf)>. Acesso em: 11 Setembro de 2006. 45

GOTTUMUKKAL, R.; NGO, H. T.; ASARI, V. K. Multilane architecture for eigenface based real-time face recognition. **Microprocessors and Microsystems**, v. 4, n. 30, p. 216– 224, 2006. 87

HAYKIN, S. **Neural Networks: A Comprehensive Foundation**. New York: Mcmillan, 1994. 842 p. 32, 60, 65, 66, 67, 68, 74, 78, 79, 80, 83, 84, 98

HIDALGO, H.; GÓMEZ-TREVIÑO, E. Application of constructive learning algorithms to the inverse problem. **IEEE T. Geosci. Remote**, v. 34, n. 1, p. 874–885, 1996. [57](#)

HOPFIELD, J. J. Neural networks and physical systems with emergent collective computational abilities. **Proceedings of the National Academy of Sciences of the United States of America-Biological Science**, v. 8, n. 79, p. 2554–2558, 1982. [60](#), [79](#), [81](#)

HÄRTER, F. P.; CAMPOS VELHO, H. F. Recurrent and feedforward neural networks trained with cross validation scheme applied to the data assimilation in chaotic dynamics. **Revista Brasileira de Meteorologia**, v. 20, n. 1, p. 411–420, 2005. [58](#)

HSIAO, P. Y.; CHEN, C. H.; WEN, H.; CHEN, S. J. Realtime realisation of noise-immune gradient-based edge detector. **IEE Proceedings-Computers and Digital Techniques**, v. 4, n. 153, p. 261–269, 2006. [87](#)

ICI. , 2006. Disponível em: <[http://www.meteorologie.eu.org/ici/articles/architecture/doc\\_1\\_ici/ici\\_architecture.htm](http://www.meteorologie.eu.org/ici/articles/architecture/doc_1_ici/ici_architecture.htm)>. Acesso em: 11 Fevereiro de 2006. [100](#)

ISSAMOTO, E.; MIKKI, F.; LUZ, J.; SILVA, J.; OLIVEIRA, P.; CAMPOS VELHO, H. An inverse initial condition problem in heat conductions: A neural network approach. In: **Brazilian Congress on Mechanical Engineering**. Campinas: COBEM, 1999. p. 22–26. [57](#)

JARNY, Y.; ÖZISIK, M.; BARDON, J. A general optimization method using adjoint equation for solving multidimensional inverse heat conduction. **International Journal of Heat and Mass Transfer**, v. 34, n. 11, p. 2911–2919, 1991. [56](#)

KARAYIANNIS, N. B.; MI, W. Growing radial basis neural networks: Merging supervised and unsupervised learning with network growth techniques. **IEEE Transaction Neural Networks**, v. 8, p. 1492–1506, 1997. [76](#)

KIDDER, S.; HAAR, T. **Satellite meteorology : an introduction**. San Diego: Academic Press, 1995. 466 p. [27](#), [45](#)

KING, J. I. F. The radiative heat transfer of planet earth. In: SCIENTIFIC USES OF EARTH SATELLITES, 1956. **Scientific Uses of Earth Satellites**. Ann Arbor, Michigan: University of Michigan Press, 1956. p. 133–136. [28](#)

KOVÁCS, Z. **Redes Neurais Artificiais - Fundamentos e Aplicações**. Rio de Janeiro: Ed. Acadêmica, 1996. 174 p. [61](#)

KREJSA, J.; WOODBURY, K.; RATLIFF, J.; RAUDENSKY, M. Assessment of strategies and potential for neural networks in the inverse heat conduction problem. **Inverse Problems in Engineering**, v. 7, n. 3, p. 197–213, 1999. [57](#)

KRIPS, M.; LAMMERT, T.; KUMMERT, A. Fpga implementation of a neural network for a real-time hand tracking system. **Proceedings of the The First IEEE International Workshop on Electronic Design, Test and Applications**, v. 1, n. 1, p. 313, 2002. [152](#)

KUMAR, P. R.; SRLDHARAN, K.; SRINIVASAN, S. A parallel algorithm, architecture and fpga realization for landmark determination and map construction in a planar unknown environment. **Parallel Computing**, v. 3, n. 32, p. 205–221, 2006. [87](#)

LAVANT, L.; BRUNEL, P.; ROCHARD, G. Tows sounding products at cms the ici model. **Tech. Proceedings of the eight I IS**, p. 319–326, 1995. [47](#)

LEESER, M.; CORIC, S.; MILLER, E.; YU, H. Q.; TREPANIER, M. Parallel-beam backprojection: An fpga implementation optimized for medical imaging. **Journal of VLSI Signal Proc. Systems for Signal Image And Video Technology**, v. 3, n. 39, p. 295–311, 2005. [87](#)

LEMES, N. H. T.; BRAGA, J.; BELCHIOR, J. C. Spherical potential energy function from second virial coefficient using tikhonov regularization and truncated singular value decomposition. **Chemical Physics Letters**, v. 296, p. 233, 1998. [56](#)

\_\_\_\_\_. Uso da regularização de tikhonov e da decomposição em valores singulares para a inversão de dados termodinâmicos. In: SOCIEDADE BRASILEIRA DE MATEMÁTICA APLICADA E COMPUTACIONAL, XXI., 1998, Caxambu. **XXI Congresso Brasileiro de Matemática Aplicada e Computacional**. Caxambú, 1998. p. 94. [56](#)

LEONG, C.; BENTO, P.; LOUSA, P.; NOBRE, J.; REGO, J.; RODRIGUES, P.; SILVA, J. C.; TEIXEIRA, I. C.; TEIXEIRA, J. P.; TRINDADE, A.; VARELA, J. Design and test issues of an fpga based data acquisition system for medical imaging using pem. **IEEE Transactions on Nuclear Science**, v. 3, n. 53, p. 761–769, 2006. [87](#)

LI, T. H. S.; CHANG, S. J.; X., C. Y. Implementation of human-like driving skills by autonomous fuzzy behavior control on an fpga-based car-like mobile robot. **IEEE Transactions on Industrial Electronics**, v. 5, n. 50, p. 867–880, 2003. [87](#)

LIOU, K. N. **An introduction to atmospheric radiation**. Orlando: Academic Press, 1982. 583 p. [37](#), [38](#), [39](#), [41](#), [43](#), [44](#), [84](#), [101](#)

LIU, G.; HAN, X. **Computational Inverse Techniques in Nondestructive Evaluation**. Florida: CRC Press, 2003. 592 p. [56](#), [57](#)

MACEDO, S. R.; CEBALLOS, J. C. Desempenho de sondagens ici (inversion coupled imager): Comparação entre o uso do tigr e um banco de radiossondagens brasileiras. In: SOCIEDADE BRASILEIRA DE METEOROLOGIA, 13., 2004, Fortaleza. **Anais XIII Congresso Brasileiro de Meteorologia**. São José dos Campos: INPE, 2004. [47](#), [99](#), [100](#)

MAXFIELD, C. M. **The Design Warrior's Guide to FPGAs**. New York: Elsevier, 2004. 542 p. [89](#), [90](#), [92](#)

MCMILLIN, L. M.; PHILLIPS, M.; GRUBER, A.; WARK, D. An evaluation of early operational temperature sounding from tiros-n. **Bulletin of the American Meteorological Society**, v. 60, n. 10, p. 1167–1187, 1979. [29](#)

MIKKI, F.; ISSAMOTO, E.; LUZ, J.; OLIVEIRA, P.; CAMPOS VELHO, H.; SILVA, J. Neural network approach in a backward heat conduction problem. In: **Congresso Brasileiro de Redes Neurais**. São José dos Campos: INPE, 1999. p. 19–24. [57](#)

MINSKY, M. L.; PAPERT, S. **Perceptrons: An Introduction to Computational Geometry**. Cambridge: MIT Press, 1969. 292 p. [60](#)

MOODY, J. E.; DARKEN, C. J. Fast learning in networks of locally-tuned processing units. **Neural Computing**, v. 1, p. 281–294, 1989. [76](#)

MOROZOV, V. A. On the solution of functional equations by the method of regularization. **Soviet Math. Dokl.**, v. 7, p. 414–417, 1966. 56

\_\_\_\_\_. **Regularization Methods for Ill-Posed Problems**. Florida: CRC Press, 1992. 257 p. 55

MUNIZ, W. B.; CAMPOS VELHO, H. F.; RAMOS, F. M. A comparison of some inverse methods for estimating the initial condition of the heat equation. **Journal of Computational and Applied Mathematics**, v. 103, n. 1, p. 145–163, 1999. 49, 52, 54, 55, 56

MUNIZ, W. B.; RAMOS, F. M.; CAMPOS VELHO, H. F. Entropy- and tikhonov-based regularization techniques applied to the backwards heat equation. **Computers & Mathematics with Applications**, v. 40, n. 8-9, p. 1071–1084, 2000. 54, 56

NEVES, J.; BRAGA, J.; BRAGA, A. P.; ALMEIDA, M. B. Recurrent neural network model to retrieve the long range spherical potential energy function from second virial coefficient. **Inverse Problems in Engineering**, v. 10, n. 2, p. 153–162, 2002. 57

NIEMAN, S.; ACHTOR, T. **ITPP-5.0 user guide**. Madison: University of Wisconsin, 1995. 29

NOAA. , 2004. Disponível em: <[http://www.osdpd.noaa.gov/PSB/PPP/notices/notice\\_files/dec3004.html](http://www.osdpd.noaa.gov/PSB/PPP/notices/notice_files/dec3004.html)>. Acesso em: 11 Fevereiro de 2005. 105

NOGUEIRA, J. L. M. **Impacto das imagens AVHRR na classificação de padrões de nebulosidade utilizando o modelo ITPP5.0**. 117 p. (INPE-7118-TDI/670). Mestrado em Sensoriamento Remoto — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 1998. 30

PARKER, D. B. Optimal algorithms for adaptive networks: second order back-propagation, second order direct propagation, and second order hebbian learning. **IEEE International Conference on Neural Network**, v. 2, p. 593–600, 1987. 67

PATTERSON, D. A.; HENNESSY, J. L. **Organização e Projeto de Computadores - A Interface Hardware**. Rio de Janeiro: LCT Editora, 2000. 554 p. 87

- POGGIO, T.; GIROSI, F. Regularization algorithms for learning that are equivalent to multilayer networks. **Science**, v. 247, p. 978–982, 1990. [76](#)
- POWELL, M. J. D. Radial basis functions for multivariable interpolation: A review. **IMA Conference on Algorithms for the Approximation of Functions and Data**, p. 143–167, 1985. [73](#), [75](#)
- PRECHELT, L. **Proben1: A Set of Neural Network Benchmark Problems and Benchmarking Rules**. Fakultät für Informatik, Universität Karlsruhe, Germany: Technical Report 345, 1994. [98](#)
- RAMOS, F.; CAMPOS VELHO, H.; CARVALHO, J.; FERREIRA, N. Novel approaches on entropic regularization. **Inverse Problems**, v. 15, n. 5, p. 1139–1148, 1999. [30](#), [55](#), [147](#)
- RAMOS, F.; Campos Velho, H. de. Reconstruction of geoelectric conductivity distributions using a minimum first-order entropy technique. In: **2nd International Conference on Inverse Problems on Engineering**. [S.l.: s.n.], 1996. p. 199–206. [55](#)
- ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain. **Psychological Review**, v. 65, p. 386–408, 1958. [59](#)
- RUMELHART, D.; HINTON, G.; WILLIAMS, R. Learning representations by back-propagation errors. **Nature**, v. 323, n. 6088, p. 533–536, 1986. [67](#)
- SAKURAGI, J. **Impacto na análise sinótica entre 18 e 19 de março de 1991 na região sul e sudeste do Brasil**. 126 p. (INPE-5497-TDI/512). Dissertação (Mestrado em Meteorologia) — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 1992. [29](#)
- Sebastião, R. C. O.; BRAGA, J. Retrieval of transverse relaxation time distribution from spin-echo data by recurrent neural network. **Journal of Magnetic Resonance**, v. 177, p. 146–151, 2005. [84](#)
- \_\_\_\_\_. Transverse relaxation time distribution from spin-echo experiments using hopfield neural network. In: **IBEROAMERICAN NMR MEETING, I.**, 2005. **Iberoamerican NMR meeting**. [S.l.], 2005. [84](#)
- SEBASTIÃO, R. C. O.; LEMES, N. H. T.; VIRTUOSO, L. S.; BRAGA, J. P. Nonlinear global inversion of potential energy surfaces from the experimentally

determined second virial coefficients. **Chemical Physics Letters**, v. 378, n. 3-4, p. 406, 2003. [57](#), [83](#), [84](#), [85](#), [146](#)

Sebastião, R. C. O.; PACHECO, C. N.; BRAGA, J.; VELOSO, D. P. Diffusion coefficient distribution from nmr-dosy experiments using hopfield neural network. **Journal of Magnetic Resonance**, v. 182, p. 22–28, 2006. [84](#)

SHIGUEMORI, E.; Campos Velho, H.; SILVA, J. Redes neurais artificiais em problema inverso de condução de calor: Recuperação da condição de contorno. In: **I Workshop dos Cursos de Computação Aplicada do INPE**. São José dos Campos: INPE, 2001. p. 54–56. [57](#)

\_\_\_\_\_. Generalized morozov's principle. In: **Inverse Problems, Design and Optimization Symposium**. Angra dos Reis: IPDO, 2004. [55](#)

SHIGUEMORI, E. H.; Campos Velho, H. F.; SILVA, J. S. Inferência de perfis verticais de umidade da atmosfera a partir de dados de satélites utilizando redes neurais artificiais. In: **Congresso Brasileiro de Meteorologia**. [S.l.: s.n.], 2006. [125](#)

SHIGUEMORI, E. H.; Campos Velho, H. F.; SILVA, J. S.; CARVALHO, J. C. Neural networks based models in the inversion of temperature vertical profiles from satellite data. In: **Inverse Problems, Design and Optimization Symposium (IPDO)**. [S.l.: s.n.], 2004. [108](#)

\_\_\_\_\_. Neural network based models in the inversion of temperature vertical profiles from satellite data. **Inverse Problems in Engineering**, v. 14, n. 5, p. 543–556, 2006. [108](#)

SHIGUEMORI, E. H.; CHIWIACOWSKY, L. D.; Campos Velho, H. F.; SILVA, J. Comparison of two different approaches for the damage identification problem. In: **International Conference on Inverse Problems in Engineering**. Cambridge: ICIPE, 2005. [58](#)

\_\_\_\_\_. An inverse vibration problem solved by an artificial neural network. **Tema Tendências Em Matemática Aplicada e Computacional**, v. 6, n. 1, p. 163–175, 2005. [58](#)

SHIGUEMORI, E. H.; HARTER, F.; Campos Velho, H. F.; SILVA, J. S. Estimation of boundary conditions in heat transfer by neural networks. **Tema**

**Tendências Em Matemática Aplicada e Computacional**, v. 3, n. 24, p. 189–195, 2003. [57](#)

SHIGUEMORI, E. H.; SILVA, J. S.; Campos Velho, H. F.; CARVALHO, J. C. Radial basis function neural network in the inversion of temperature vertical profiles from satellite radiance data. In: **Brazilian Symposium on Neural Networks**. [S.l.: s.n.], 2004. [128](#), [133](#)

\_\_\_\_\_. A multilayer perceptron approach for the retrieval of vertical temperature profiles from satellite radiation data. In: **Proceedings of International Joint Conference on Neural Networks**. [S.l.: s.n.], 2005. p. 2689–2693. [108](#)

SHIGUEMORI, E. H.; SOUZA, R. A. F.; Campos Velho, H. F.; SILVA, J. D. S. Investigation of methodologies for atmospheric retrieval for the cptec operational system. In: **Proceedings of The Fourteenth International TOVS Study Conference**. [S.l.: s.n.], 2005. [117](#)

SMITH, W.; H.M.WOOLF; JACOB, W. A regression method for obtaining realtime temperature and geopotential height profiles from satellite spectrometer measurements and its application to nimbus 3 sirs observations. **Monthly Weather Review**, v. 98, n. 2, p. 582–603, 1970. [29](#)

SMITH, W.; WOOLF, H.; HAYDEN, C.; WARK, D. Q.; M.MCMILLIN, L. The tiros-n operational vertical sounder. **Bulletin of the American Meteorological Society**, v. 60, n. 5, p. 1177–1187, 12 1979. [29](#)

SMITH, W. L.; WOOLF, H. M.; NIEMAN, S. J.; ACTHOR, T. H. Itp-5- the use of avhrr and tigr in tovs data processing. In: **International TOVS Study Conference**. Austria: Incls, 1993. p. 2471 – 2476. [29](#)

SOUZA, R. **Análise de sondagens AQUA sobre o Brasil e simulação da temperatura de brilho dos canais HSB a partir de informações do sensor AIRS**. 201 p. (INPE-12282-TDI/985). Tese (Doutorado em Geofísica) — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2004. [30](#)

SOUZA, R.; CEBALLOS, J. C.; CARVALHO, J. Inferência de perfis atmosféricos utilizando o ici com emulação dos canais amsu-b a partir de dados airs-aqua. In: SOCIEDADE BRASILEIRA DE METEOROLOGIA, 13., 2004, Fortaleza. **Anais XIII Congresso Brasileiro de Meteorologia**. São José dos Campos: INPE, 2004. [99](#)

SOUZA, R. A. F.; SHIGUEMORI, E. H.; BOTTINO, M. J.; SILVA, J. S.; Campos Velho, H. F. Utilização da técnica de redes neurais artificiais na inferência de perfis verticais de temperatura a partir de informações do sensor airs/aqua: Resultados preliminares. In: **Congresso Brasileiro de Meteorologia**. [S.l.: s.n.], 2006. 106, 123

SPARTAN-3 Starter Kit Board User Guide. [S.l.], 2004. 158

TARANTOLA, A. **Inverse Problem Theory. Methods for Data Fitting and Model Parameter Estimation**. Amsterdam: Elsevier Science Publishers B.V., 1987. xvi+613 p. ISBN 0-444-42765-1. 51

TEIXEIRA, R. F. Algumas comparações preliminares de sondagem tovs com radiossondagens do experimento emas-i. In: SOCIEDADE BRASILEIRA DE METEOROLOGIA, IX., 1996, Campos do Jordão. **Anais do IX Congresso Brasileiro de Meteorologia**. Campos do Jordão, 1996. 29

\_\_\_\_\_. Algumas intercomparações: sondagens tovs e radiossondagem convencional sobre fortaleza-ce, e pelas versões 4 e 5 do itpp. In: **Anais do IX Congresso Brasileiro de Meteorologia**. Campos do Jordã: Sociedade Brasileira de Meteorologia, 1996. 29

TIGR. , 2006. Disponível em: <<http://ara.lmd.polytechnique.fr/htdocs-public/products/TIGR/TIGR.html>>. Acesso em: 13 Fevereiro de 2006. 99, 126

TIKHONOV, A. N.; ARSENIN, V. Y. **Solutions of Ill-Posed Problems**. New York: Winston & Sons, 1977. 258 p. 51, 53, 54

TSALLIS, C. Possible generalization of boltzmann-gibbs statistics. **Journal Statistical Physics**, v. 52, p. 479, 1988. 32, 76, 77

\_\_\_\_\_. Nonextensive statistics: theoretical, experimental and computational evidences and connections. **Brazilian Journal of Physics**, v. 29, n. 1, 1999. 15, 32, 76, 77, 78

TWOMEY, S. **Introduction to the mathematics of inversion in remote sensing and indirect measurements**. Amsterdam: Elsevier Scientific, 1977. 237 p. 35

VASUDEVAN, B. G.; GOHIL, B. S.; AGARWAL, V. K. Backpropagation neural-network-based retrieval of atmospheric water vapor and cloud liquid water from irs-p4 msr. **IEEE Transactions on Geoscience and Remote Sensing**, v. 42, n. 5, p. 985–990, 2004. [31](#)

VITERBO, V. de; BRAGA, J.; SHIGUEMORI, E.; SILVA, J. da; CAMPOS VELHO, H. de. Atmospheric temperature retrieval using non-linear hopfield neural network. In: **Inverse Problems, Design and Optimization Symposium**. [s.n.], 2004. Disponível em: <[Proc.inCD-Rom:papercodeIPD0-119](#)>. [57](#), [84](#), [146](#), [147](#)

WERBOS, P. Backpropagation and neurocontrol: A review and prospectus. **A review and prospectus. International Join Conference on Neural Networks**, v. 1, p. 209–216, 1989. [67](#)

WIDROW, B.; HOFF, M. Adaptative switching circuits. **IRE WESCON Convention Records**, p. 96–104, 1960. [59](#)

WOODBURY, K. Neural networks and genetic algorithms in the solution of inverse problems. **Bulletim of the Braz. Soc. for Comp. Appl. Math. (SBMAC)**, 2000. Disponível em: <[www.sbmac.org.br/publicacoes](#)>. Acesso em: 3 maio 2004. [57](#)

ZHANG, Y.; PAULSON, K. V. Magnetotelluric inversion using regularized hopfield neural networks geophysical prospecting. **Geophysical Prospecting**, v. 45, p. 725–743, 1997. [57](#)

ZHU, J.; SUTTON, P. Fpga implementations of neural networks - a survey of a decade of progress. **Field-Programmable Logic and Applications, Proceedings Lecture Notes In Computer Science**, BERLIN, GERMANY, n. 2778, p. 1062–1066, 2003. [152](#)

ÖZISIK, M. N.; ORLANDE, H. R. B. **Inverse Heat Transfer: Fundamentals and Applications**. New York: Taylor & Francis, 2000. 160 p. [52](#)