



Universidade do Estado do Rio de Janeiro
Instituto Politécnico

Mauro Cesar Cantarino Gil

**Aplicação de Redes Neuro-Fuzzy para a Solução de Problemas Inversos em
Transferência Radiativa**

Nova Friburgo
2010

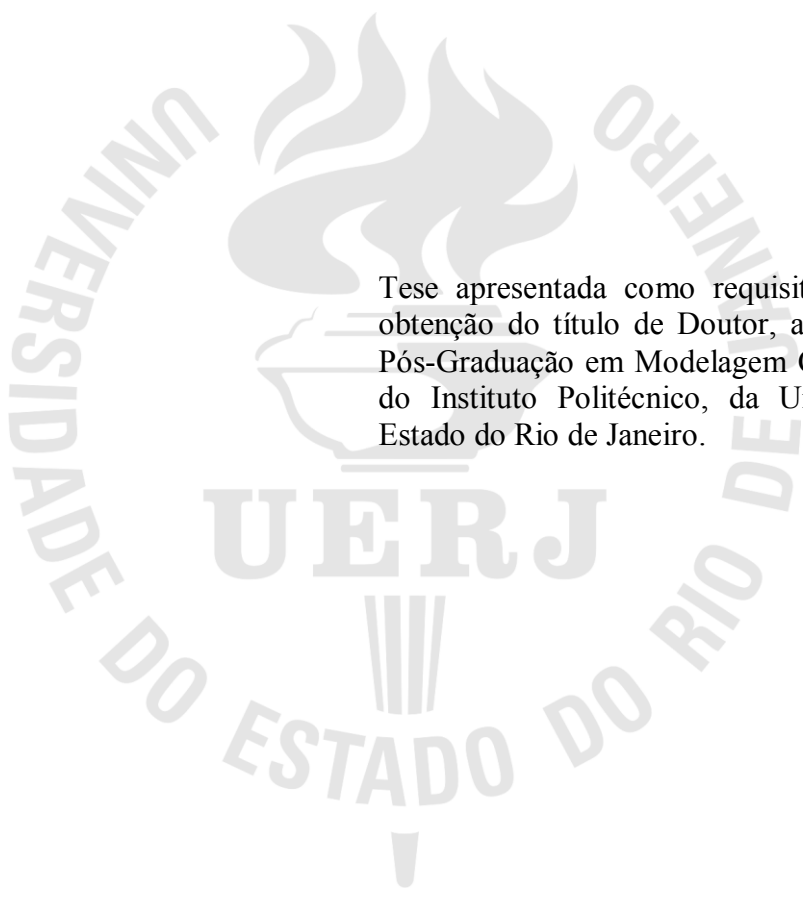
Livros Grátis

<http://www.livrosgratis.com.br>

Milhares de livros grátis para download.

Mauro Cesar Cantarino Gil

**Aplicação de Redes Neuro-Fuzzy para a Solução de Problemas Inversos em
Transferência Radiativa**



Tese apresentada como requisito parcial para obtenção do título de Doutor, ao Programa de Pós-Graduação em Modelagem Computacional, do Instituto Politécnico, da Universidade do Estado do Rio de Janeiro.

Orientadores:
Prof. Antônio José da Silva Neto
Prof. Luiz Biondi Neto

Nova Friburgo
2010

Mauro César Cantarino Gil

Aplicação de Redes Neuro-Fuzzy para a Solução
de Problemas Inversos em Transferência
Radiativa

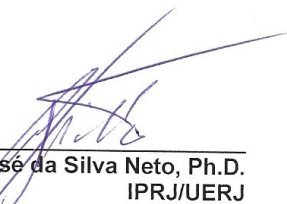
Tese submetida ao corpo docente do Programa de Pós-Graduação em Modelagem Computacional do Instituto Politécnico, Campus Regional da UERJ em Nova Friburgo, como parte dos requisitos necessários à obtenção do grau de Doutor em Modelagem Computacional. Linha de Pesquisa: Matemática Aplicada e Computação Científica.

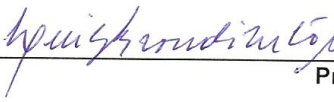
Orientadores: Prof. Antônio José da Silva Neto, Ph.D.


Prof. Luiz Biondi Neto, D.Sc.

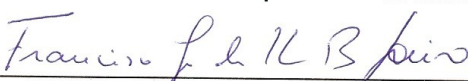
Aprovado em 09 de agosto de 2010

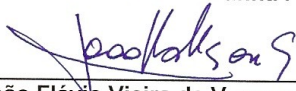
Banca Examinadora:


Prof. Antônio José da Silva Neto, Ph.D.
IPRJ/UERJ


Prof. Luiz Biondi Neto, D.Sc.
FEN/UERJ


Prof. João Carlos Correia Baptista Soares de Mello, D.Sc.
UFF


Prof. Francisco José da Cunha Pires Soeiro, Ph.D.
FEN/UERJ


Prof. João Flávio Vieira de Vasconcellos, D.Eng.Mec
IPRJ/UERJ


Profª Rosana da Paz Ferreira Pinheiro
UEZO

DEDICATÓRIA

À minha esposa Adriana, companheira de todas as horas; e aos meus filhos Rafael, Mariana e Carolina, pelo apoio, compreensão, encorajamento e ainda por compreenderem minha ausência em prol deste trabalho.

AGRADECIMENTOS

Agradeço aos meus orientadores Prof. Antônio José da Silva Neto e Prof. Luiz Biondi Neto, pela orientação recebida, pelas críticas e sugestões, pelo encorajamento ao longo do trabalho e pelo bom exemplo profissional, que em muito contribuíram para minha formação.

Agradeço também a todos os colegas do LEMA - Laboratório de Experimentação e Simulação Numérica em Transferência de Calor e Massa e a todos os amigos e colegas que de alguma forma, direta ou indiretamente proporcionaram o suporte necessário para que esta tese fosse realizada.

*“O valor das coisas não está no tempo em que elas duram,
mas na intensidade com que acontecem.
Por isso existem momentos inesquecíveis,
coisas inexplicáveis e pessoas incomparáveis”.*

Fernando Pessoa

RESUMO

GIL, Mauro Cesar Cantarino. Aplicação de Redes Neuro-Fuzzy para a Solução de Problemas Inversos em Transferência Radiativa. Tese (Doutorado em Modelagem Computacional) – Instituto Politécnico, Universidade do Estado do Rio de Janeiro, Nova Friburgo, 2010

Nesta tese é proposta uma implementação para a solução do problema inverso com as estimativas das propriedades radiativas (o albedo de espalhamento simples, a espessura ótica do meio e as reflectividades difusas) a partir dos valores das intensidades de radiação que deixam o meio participante utilizando uma abordagem híbrida de sistemas *neuro-fuzzy* (SNF), o qual combina a utilização de sistemas de inferência *fuzzy* com as redes neurais artificiais.

Busca-se com a utilização desse sistema híbrido integrar a habilidade dos sistemas fuzzy no tratamento de informações inexatas, imprecisas, e vagas, e a capacidade das redes neurais artificiais de tratar o aprendizado por experiência e a generalização do conhecimento. É proposta também uma metodologia de máquinas de comitês neuro-fuzzy na solução deste problema inverso em transferência radiativa.

Foi observado paralelamente que a solução dos sistemas neuro-fuzzy e dos sistemas híbridos de máquinas de comitê neuro-fuzzy, apresentam baixa qualidade nos resultados quando são utilizados os dados experimentais com os menores coeficientes de sensibilidade para os parâmetros que serão estimados. Por outro lado, quando são utilizados dados com maior sensibilidade, são obtidos melhores resultados. Esta abordagem procura evitar a possibilidade da não convergência desses métodos.

Palavras-chave: Problemas Inversos; Transferência Radiativa; Neuro-Fuzzy; Análise de Sensibilidade; Máquinas de Comitê.

ABSTRACT

In this thesis is proposed an implementation for solving the inverse problem with the estimates of radiative properties (the single scattering albedo, the optical thickness of the media and the diffuse reflectivities) by the values of the intensities of radiation that leaves the participant medium using a hybrid approach of neuro-fuzzy systems, which combines the use of fuzzy inference systems with artificial neural networks. The use of this hybrid system try to include the ability of fuzzy systems in the treatment of inaccurate, imprecise, and vague data, and the ability of artificial neural networks to deal with learning from experience and widespread knowledge. Also is proposed a methodology for machines committees in neuro-fuzzy solution of this inverse problem in radiative transfer.

It was observed in parallel that the solution of neuro-fuzzy systems and hybrid systems neuro-fuzzy committee machines, have a poor quality results when using the experimental data with the lowest sensitivity coefficients for the parameters that will be estimated. Moreover, when data are used with greater sensitivity, better results are obtained. This approach seeks to avoid the possibility of non-convergence in such methods.

Keywords: Inverse Problems; Radiative Transfer; Neuro-Fuzzy; Sensitivity Analysis, Committee Machines.

LISTA DE FIGURAS

Figura 2.1: Meio participante unidimensional sujeito à incidência de radiação isotrópica com intensidades f_1 (μ) e f_2 (μ).....	9
Figura 2.2: Discretização do domínio espacial para o meio homogêneo unidimensional, $0 \leq \tau \leq \tau_0$	11
Figura 2.3: Discretização do domínio angular com ordem N , $-1 \leq \mu \leq 1$	12
Figura 3.1: Representação esquemática do Problema Inverso (SILVA NETO, 2007).	16
Figura 3.2: Representação esquemática do dado experimental.	17
Figura 3.3: Representação gráfica do cálculo dos coeficientes de sensibilidade	19
Figura 4.1: Modelo de uma Rede Neural <i>MLP</i> com uma camada intermediária para o problema inverso de transferência radiativa.	22
Figura 4.2: Fluxograma do algoritmo BP.....	27
Figura 4.3: Exemplo curva da validação cruzada, comparando-se com as curvas de treinamento durante a fase de treinamento da RNA (GIL, 2005).	29
Figura 4.4: Diagrama em blocos de um Sistema Fuzzy.....	31
Figura 4.5: Rede Neuro-fuzzy.	34
Figura 4.6: Diagrama em blocos para a operação de uma regra Sugeno	36
Figura 4.7: Diagrama em blocos do algoritmo de treinamento da Rede Neuro-fuzzy	38
Figura 4.8: Função de pertinência sino-beta	39
Figura 4.9: Particionamento em grade com três funções de pertinência associadas a duas entradas com nove regras fuzzy.	40
Figura 4.10: Arquitetura de um SNF com quatro entradas, três funções de pertinência e particionamento em grade.....	41
Figura 4.11: Regras no formato texto de um SNF com quatro entradas, três funções de pertinência e particionamento em grade.	42
Figura 4.12: Regras no formato texto de um SNF com quatro entradas, três funções de pertinência e particionamento em grade.	42
Figura 4.13: Funções de pertinência de um SNF com quatro entradas, três funções de pertinência e particionamento em grade na fase inicial de treinamento.	43

Lista de Figuras

Figura 4.14: Funções de pertinência de um SNF com quatro entradas, três funções de pertinência e particionamento em grade com a fase de treinamento concluída. .	43
Figura 4.15: Arquitetura de um SNF com quatro entradas, seis funções de pertinência e clusterização.....	44
Figura 4.16: Regras no formato texto de um SNF com quatro entradas, seis funções de pertinência e clusterização.	44
Figura 4.17: Regras no formato texto de um SNF com quatro entradas, seis funções de pertinência e clusterização.	45
Figura 4.18: Funções de pertinência de um SNF com quatro entradas, seis funções de pertinência e clusterização na fase inicial de treinamento.....	45
Figura 4.19: Funções de pertinência de um SNF com quatro entradas, seis funções de pertinência e clusterização com a fase de treinamento concluída.....	46
Figura 4.20: Representação esquemática do comitê neuro-fuzzy para o problema inverso de transferência radiativa.....	47
Figura 4.21: Diagrama esquemático – Problema Direto e o Problema Inverso	48
Figura 4.22: Dados experimentais simulados (GAGLIARDI, 2010) (a) intensidades de radiação que deixam o meio - Y_i (b) variáveis radiativas - \vec{Z}	49
Figura 5.1: Função $f(x,y)$ a ser treinada pela rede Neuro-Fuzzy.....	51
Figura 5.2: Variáveis linguísticas x e y , inicial e final do treinamento.....	52
Figura 5.4: Representação esquemática do dado experimental.....	59
Figura 5.5: Sensibilidade para o albedo de espalhamento simples ω , a espessura ótica do meio τ_0 e as reflectividades difusas ρ_1 e ρ_2 (Caso Teste 3).....	60
Figura 5.6: Sensibilidade para o albedo de espalhamento simples ω , a espessura ótica do meio τ_0 e as reflectividades difusas ρ_1 e ρ_2 (Caso Teste 4).....	61
Figura 5.7: Sensibilidade para o albedo de espalhamento simples ω , a espessura ótica do meio τ_0 e as reflectividade difusa ρ_1 e ρ_2 (Caso Teste 5).....	62
Figura 5.8: Sensibilidade para o albedo de espalhamento simples ω , a espessura ótica do meio τ_0 e as reflectividade difusa ρ_1 e ρ_2 (Caso Teste 6).....	63
Figura 5.9: Diagrama esquemático – Solução do Problema Inverso com Redes NF	64
Figura 5.10: Diagrama esquemático – Solução do Problema Inverso com Comitês de Redes NF	66

Lista de Figuras

Figura B.1: Sensibilidade para o albedo de espalhamento simples ω (Caso Teste 3).....	89
Figura B.2: Sensibilidade para a espessura ótica do meio τ_0 (Caso Teste 3).....	89
Figura B.3: Sensibilidade para a reflectividade difusa ρ_1 (Caso Teste 3).	90
Figura B.4: Sensibilidade para a reflectividade difusa ρ_2 (Caso Teste 3).	90
Figura B.5: Sensibilidade para o albedo de espalhamento simples ω (Caso Teste 4).....	91
Figura B.6: Sensibilidade para a espessura ótica do meio τ_0 (Caso Teste 4).....	92
Figura B.7: Sensibilidade para a reflectividade difusa ρ_1 (Caso Teste 4).	92
Figura B.8: Sensibilidade para a reflectividade difusa ρ_2 (Caso Teste 4).	93
Figura B.9: Sensibilidade para o albedo de espalhamento simples ω (Caso Teste 5).....	93
Figura B.10: Sensibilidade para a espessura ótica do meio τ_0 (Caso Teste 5).....	94
Figura B.11: Sensibilidade para a reflectividade difusa ρ_1 (Caso Teste 5).	94
Figura B.12: Sensibilidade para a reflectividade difusa ρ_2 (Caso Teste 5).	95
Figura B.13: Sensibilidade para o albedo de espalhamento simples ω (Caso Teste 6).....	96
Figura B.14: Sensibilidade para a espessura ótica do meio τ_0 (Caso Teste 6).....	96
Figura B.15: Sensibilidade para a reflectividade difusa ρ_1 (Caso Teste 6).	97
Figura B.16: Sensibilidade para a reflectividade difusa ρ_2 (Caso Teste 6).	97
Figura I.1: Representação da variável, usando-se álgebra de Boole	99
Figura I.2 – Representação da variável, usando-se Conjuntos Fuzzy.....	100
Figura I.3 – Conjunto Singleton	101
Figura I.4 - Função de pertinência Sino-Beta.....	102
Figura I.7 – Funções de pertinência para a variável temperatura.	106

LISTA DE TABELAS

Tabela 2.1: Variáveis utilizadas na formulação matemática do problema de transferência radiativa.....	9
Tabela 2.2: Coeficientes de absorção k_a e de espalhamento σ_s para a água do mar (MOBLEY, 1994).....	10
Tabela 2.3: Coeficiente de extinção total β , espessura ótica τ_0 e albedo de espalhamento simples ω para a água do mar. Valores calculados a partir da Tabela 2.1 para uma lâmina de água com $L = 5$ m de espessura (SILVA NETO e BECCENERI, 2009)	11
Tabela 2.4: Propriedades médias de nuvens cirrus obtidas na Universidade Central Nacional de Taiwan no período de 1999 a 2006. β é o coeficiente de extinção e τ_0 a espessura ótica (DAS et al., 2009).....	11
Tabela 2.5: Pontos de colocação e pesos para a quadratura Gauss-Legendre (ABRAMOWITZ, 1970), com ordem $N = 20$	13
Tabela 5.1: Casos Testes realizados com os modelos neuro-fuzzy e comitê neuro-fuzzy.....	50
Tabela 5.2: Parâmetros utilizados na construção das Redes Neuro-Fuzzy – Caso Teste 2	53
Tabela 5.3: Parâmetros utilizados na construção das Redes Neurais Artificiais – Caso 2.	54
Tabela 5.4: Erro percentual dos SNF e RNA - albedo de espalhamento ω com os maiores coeficientes de sensibilidade – Caso Teste 2.....	55
Tabela 5.5: Erro percentual dos SNF e RNA - albedo de espalhamento ω com os menores coeficientes de sensibilidade – Caso Teste 2.....	55
Tabela 5.6: Erro percentual dos SNF e RNA - espessura ótica τ_0 com os maiores coeficientes de sensibilidade – Caso Teste 2.....	55
Tabela 5.6: Erro percentual dos SNF e RNA - espessura ótica τ_0 com os maiores coeficientes de sensibilidade – Caso Teste 2.....	55
Tabela 5.8: Erro percentual dos SNF e RNA – reflectividade difusa ρ_1 com os maiores coeficientes de sensibilidade – Caso Teste 2.....	56
Tabela 5.9: Erro percentual dos SNF e RNA – reflectividade difusa ρ_1 com os menores coeficientes de sensibilidade – Caso Teste 2.....	56
Tabela 5.10: Erro percentual dos SNF e RNA - reflectividade difusa ρ_2 com os maiores coeficientes de sensibilidade – Caso Teste 2.....	56
Tabela 5.11: Erro percentual dos SNF e RNA - reflectividade difusa ρ_2 com os menores coeficientes de sensibilidade – Caso Teste 2.....	56
Tabela 5.12: Parâmetros associados aos casos testes.....	58
Tabela 5.13: Direções (μ) das intensidades de radiação com os maiores coeficientes de sensibilidade.....	63
Tabela 5.14: Parâmetros utilizados na construção das Redes Neuro-Fuzzy – Casos Teste 3,4, 5 e 6.....	65

Lista de Tabelas

Tabela 5.15: Parâmetros utilizados na construção da RNA combinadora	66
Tabela 5.16: Parâmetros associados ao Caso Teste 3 (SOEIRO et al., 2004) e (PINHEIRO et al., 2005)	67
Tabela 5.17: Resultados obtidos pelo método RNA-LM – Caso Teste 3 (SOEIRO et al., 2004).....	67
Tabela 5.18: Resultados obtidos pelo método RT – Caso Teste 3 (PINHEIRO et al., 2005)	67
Tabela 5.19: Resultados obtidos pelo SNF – Caso Teste 3.....	68
Tabela 5.20: Resultados obtidos pelo Comitê NF com o combinador média– Caso Teste 3	68
Tabela 5.21: Resultados obtidos pelo Comitê NF com o combinador RNA – Caso Teste 3	69
Tabela 5.22: Parâmetros associados ao Caso Teste 4 (SACCO et al., 2009)	69
Tabela 5.23: Resultados obtidos pelos métodos: PCA, SNF e Comitê NF Caso Teste 4...	70
Tabela 5.24: Parâmetros associados ao Caso Teste 5 (SACCO et al., 2009)	70
Tabela 5.25: Resultados obtidos pelos métodos: PCA, SNF e Comitê NF Caso Teste 5 ..	71
Tabela 5.26: Parâmetros associados ao Caso Teste 6 (KNUPP et al., 2007)	71
Tabela 5.27: Resultados obtidos pelos métodos: PCA_{INI} - melhor resultado e média Caso Teste 6.....	72
Tabela 5.28: Resultados obtidos pelos métodos: PCA_{SA} - melhor resultado e média Caso Teste 6.....	72
Tabela 5.29: Resultados obtidos pelos métodos: PCA_{LM} - melhor resultado e média Caso Teste 6.....	72
Tabela 5.30: Resultados obtidos pelo método SNF Caso Teste 6	72
Tabela 5.31: Resultados obtidos pelo método Comitê NF Caso Teste 6	73
Tabela I.1: Operações compensatórias funcionais.....	105

LISTA DE SIGLAS

ACO	Otimização por Colônia de Formigas (<i>Ant Colony Optimization</i>)
ANFIS	<i>Adaptative Network-based Fuzzy Inference System</i>
BP	Algoritmo de Retropropagação (<i>Back Propagation algorithm</i>)
FRNN	<i>Fuzzy Relational Neural Network</i>
GD	Método do Gradiente Descendente
GDX	Algoritmo da Taxa de Aprendizagem Adaptativa
LF	Lógica <i>Fuzzy</i>
LSM	Métodos dos Mínimos Quadrados (<i>Least Square Method</i>)
LM	Método de Levenberg-Marquardt
MF	Função de Pertinência (<i>Membership Function</i>)
MSE	Erro Médio Quadrático (<i>Mean Square Error</i>)
MLP	Perceptron de Múltiplas Camadas (<i>Multilayer Perceptron</i>)
MPSO	<i>Multi-phase Particle Swarm Optimization</i>
NF	Neuro-fuzzy
PCA	Algoritmo de Colisão de Partículas (<i>Particle Collision Algorithm</i>)
PD	Problema Direto
PI	Problema Inverso
PSO	Otimização por Enxame de Partículas (<i>Particle Swarm Optimization</i>)
RBF	Redes de Funções de Base Radial (<i>Radial Basis Function Network</i>)
RNA	Redes Neurais Artificiais
RT	Funcional de Regularização de Tikhonov
RPROP	Algoritmo Resiliente de Retropropagação do Erro (<i>Resilient Backpropagation</i>)
RTE	Equação de Transferência radiativa (<i>Radiative Transfer Equation</i>)
SA	Recozimento Simulado (<i>Simulated Annealing</i>)
SNF	Sistemas <i>Neuro-Fuzzy</i>

SUMÁRIO

1 INTRODUÇÃO E OBJETIVOS	1
1.1 Contextualização do tema: aplicações em transferência radiativa e inteligência computacional	2
1.2 Justificativa, relevância e objetivo	6
1.3 Divisão em capítulos	6
2 TRANSFERÊNCIA RADIATIVA: PROBLEMA DIRETO	8
2.1 - Modelagem matemática da transferência radiativa	8
2.2 - Solução numérica do problema de transferência radiativa em meios participantes	11
3 TRANSFERÊNCIA RADIATIVA: PROBLEMA INVERSO	15
3.1 O problema inverso	15
3.2 Modelagem matemática do problema inverso em transferência radiativa	16
3.3 Dados experimentais	17
3.4 Análise de sensibilidade	18
4 ESTRATÉGIAS PARA A SOLUÇÃO DO PROBLEMA INVERSO	20
4.1 Redes Neurais Artificiais	21
4.1.1 Formulação e solução do problema inverso com redes neurais artificiais	21
4.1.2 Treinamento das redes neurais	24
4.1.3 Treinamento das redes neurais com validação cruzada	27
4.2 Sistemas Fuzzy	29
4.3 Sistemas Neuro-Fuzzy	32
4.4 Máquinas de Comitê de Redes Neuro-Fuzzy	46
4.5 Formulação e solução do problema inverso com sistemas neuro-fuzzy e com comitês de redes neuro-fuzzy	48
5 ESTUDO DE CASOS	50
5.1 Validação das Redes Neuro-Fuzzy: Caso Teste 1	51
5.2 Validação das Redes Neuro-Fuzzy: Caso Teste 2	53
5.2.1 Resultados – Caso Teste 2	54

Sumário

5.3 Testes das Redes Neuro-Fuzzy e dos Comitês Neuro-Fuzzy	57
5.3.1 Casos Testes	57
5.3.2 Cálculo e análise dos coeficientes de sensibilidade	58
5.3.2.1 Análise de Sensibilidade - Caso Teste 3	59
5.3.2.2 Análise de Sensibilidade - Caso Teste 4	60
5.3.2.3 Análise de Sensibilidade - Caso Teste 5	61
5.3.2.4 Análise de Sensibilidade - Caso Teste 6	62
5.3.2.5 Análise de Sensibilidade - Resumo	63
5.3.3 Resultados dos casos teste com os Sistemas Neuro-Fuzzy, com os Comitês Neuro-Fuzzy e Análise de Sensibilidade	64
5.3.3.1 Caso Teste 3	67
5.3.3.2 Caso Teste 4	69
5.3.3.3 Caso Teste 5	70
5.3.3.4 Caso Teste 6	71
CONCLUSÕES E TRABALHOS FUTUROS	74
REFERÊNCIAS BIBLIOGRÁFICAS	76
APÊNDICE A - ARQUITETURAS NEURO-FUZZY	86
A.1. Neuro-Fuzzy Control (NEFCON)	86
A.2 Neuro Fuzzy Classification (NEFCLASS)	86
A.3 Neuro Fuzzy Function Approximation (NEFPROX)	87
A.4 Adaptive Neuro Fuzzy Inference System (ANFIS)	87
APÊNDICE B - ANÁLISE DE SENSIBILIDADE	88
B.1 Análise de Sensibilidade - Caso Teste 3	88
B.2 Análise de Sensibilidade - Caso Teste 4	91
B.3 Análise de Sensibilidade - Caso Teste 5	93
B.4 Análise de Sensibilidade - Caso Teste 6	95
ANEXO I - SISTEMAS FUZZY	98
I.1 Conjuntos Fuzzy	98

Sumário

I.2 Funções de pertinência	101
I.3 Fuzzyficação	106
I.4 Raciocínio Fuzzy	107
I.5 Defuzzyficação	109

1 INTRODUÇÃO E OBJETIVOS

Há muito tempo os pesquisadores das mais diversas áreas buscam o entendimento sobre o comportamento do meio ambiente e com a evolução da tecnologia, procura-se a cada instante a interpretação e a previsão deste comportamento, para isso, muitas dessas abordagens estão relacionadas com a utilização de modelos, i.e., a análise sobre as observações realizadas e os resultados dos modelos desenvolvidos, assim, a modelagem tem um papel de grande importância, pois está intimamente ligada às ferramentas matemáticas, que se apóiam na precisão e na descrição exata de cada variável relacionada. A utilização dessas ferramentas é adequada quando o problema tratado é simples ou bem definido. Entretanto, quando este contexto se torna maior ou mais complexo, essas ferramentas se tornam menos eficientes e em algumas situações, impróprias, podendo este fato estar relacionado às questões das expressões matemáticas envolvidas no problema se tornarem complexas, ou no caso de haver certas imprecisões nas variáveis do ambiente (incertezas).

Na busca pela solução dos problemas dos métodos convencionais de modelagem, surgem no último século propostas alternativas tais como a modelagem pelas técnicas de inteligência computacional, das quais temos as redes neurais artificiais (RNA), que são modelos inspirados na estrutura do cérebro e apresentam características humanas como o aprendizado por experiência e a generalização do conhecimento a partir de exemplos apresentados, e a lógica *fuzzy* (LF), que procura utilizar a experiência humana para modelar o modo impreciso (incerto) do raciocínio humano no tocante a habilidade de tomar decisões e para tal incorpora ao modelo graus de adequabilidade, confortabilidade, satisfação, entre outras.

Por outro lado, a solução de problemas diretos e inversos em transferência radiativa tem se apresentado como uma ferramenta eficiente para a estimativa de propriedades óticas em diferentes meios. A análise de problemas inversos envolvendo a interação de diversos tipos de partículas e radiação, tais como nêutrons, raios gama e fótons, com meios participantes, ou seja, meios absorvedores, emissores e espalhadores, tem sido bastante utilizada no desenvolvimento de técnicas para aplicações em Engenharia, Medicina, Geofísica, Astrofísica, bem como em outras áreas (ALVAREZ ACEVEDO et al., 2002).

Um exemplo clássico de meio participante é a atmosfera terrestre, a qual exerce um efeito atenuante sob a radiação solar. Outros exemplos de meios participantes são os produtos de combustão de motores - foguetes e proteções térmicas para veículos espaciais, entre outras (PESSOA FILHO, 1998).

Na modelagem matemática do problema direto de transferência radiativa em um meio participante, faz-se uso da equação linear de Boltzmann, ou Equação de Transferência Radiativa (*Radiative Transfer Equation - RTE*), a qual resulta da aplicação do princípio da conservação da energia em um meio. Os problemas inversos podem ser formulados matematicamente de modo explícito ou implícito (SILVA NETO, 2002), e diversas técnicas têm sido desenvolvidas para a solução dos mesmos (SILVA NETO e BECCENERI, 2009; CAMPOS VELHO, 2008; SILVA NETO e MOURA NETO, 2005; BECK et al., 1985).

1.1 Contextualização do tema: aplicações em transferência radiativa e inteligência computacional

O desenvolvimento de metodologias de inversão em transferência radiativa tem se estabelecido como um relevante tema de pesquisa em muitas áreas da ciência e engenharia, entre outras. Como exemplo:

Lii e Özisik (1973) determinaram as reflectividades e o termo fonte e em uma superfície de contorno a partir das medidas das intensidades da radiação emergente com dependência no ângulo polar.

Bakirov et al. (1986) propuseram uma metodologia para a determinação da concentração em massa de partículas de fuligem em chamas.

Fukshansky et al. (1991) estimaram o coeficiente de absorção e dispersão e o fator de assimetria do espalhamento de vida nas folhas das plantas.

Yi et al. (1992) estimaram a localização e a intensidade de uma fonte de radiação bioluminescente.

Silva Neto e Özisik (1993) a partir de medidas experimentais sintéticas das intensidades da radiação em função do ângulo polar e da temperatura no interior do meio,

estimaram as propriedades radiativas e a condutividade térmica em um problema de transferência de calor por condução e radiação térmica.

Silva Neto e Özisik (1995) a partir dos valores das intensidades da radiação que saem do meio para diferentes ângulos polares estimaram o albedo de espalhamento simples, a espessura ótica e os coeficientes de função de fase utilizando o método de Levenberg-Marquardt. De outra forma, Li e Yang (1997) usando um algoritmo genético resolveram o mesmo problema.

Fukshansky-Kazarinova et al. (1998) determinaram os coeficientes da função de fase de espalhamento e coeficiente de extinção total utilizando medidas do fluxo radiativo no interior do meio e a análise de sensibilidade.

Kauati et al. (1999) , utilizaram a técnica fonte-detector para a solução do problema inverso da estimativa do coeficiente de extinção total a partir do conhecimento das intensidades de radiação que deixam o meio participante unidimensional homogêneo. Os referidos autores estenderam a aplicação da técnica fonte-detector para meios espalhadores anisotrópicos.

Montero et al. (2001; 1999) estimaram o coeficiente de absorção em um meio heterogêneo bidimensional puramente absorvedor, utilizando um algoritmo com o funcional q-Discrepância baseada nas Distâncias de Bregman e com uma partição de domínio.

A estimação de propriedades do meio, como albedo simples e refletividade difusa das superfícies do contorno, podem ser realizadas através dos momentos da radiação emergente (SILVA NETO e MCCORMICK, 2002).

Silva Neto e Soeiro (2005; 2003; 2002; 2000) empregaram vários métodos híbridos para a solução de um problema inverso em transferência radiativa, entre estes, um método de otimização híbrida, como a combinação do método de otimização global *Simulated Annealing* e do método de Levenberg-Marquardt.

Vasconcellos et al. (2006) desenvolveram uma solução baseada no método de minimização de Levenberg-Marquardt para um problema inverso de estimativa do coeficiente de transferência de massa por difusão e da difusividade da proteína na partícula utilizando a análise de sensibilidade.

Stephany et al. (2010) apresentaram uma técnica de regularização aplicada a um problema inverso de transferência radiativa formulado como um problema de otimização de dimensão finita e resolvidos por uma hibridização de um método de otimização de colônia de formigas (*ACO*) com o método de Levenberg-Marquardt.

Nestas últimas décadas tem sido observado um interesse crescente na utilização de estruturas de inteligência computacional para a solução de diversos problemas, inclusive em problemas inversos, como:

Nauck e Kruse (1999b) que propuseram a criação de um sistema classificador *neuro-fuzzy* denominado NEFCLASS-J, baseado em uma estrutura NEFCLASS criado inicialmente por Nauck e implementado em uma linguagem orientada a objeto Java.

Em problema inverso com a determinação da função de energia potencial com o segundo coeficiente do virial por redes *Hopfield* (BRAGA et al., 2000);

Abraham (2001) realizou uma série de comparações em várias arquiteturas de sistemas *neuro-fuzzy* (SNF), apresentando as suas características e aplicações no estado da arte “*neuro-fuzzy*”.

Vieira et al. (2004) apresentaram um estudo comparativo entre as redes neurais e os sistemas *neuro-fuzzy* para a utilização em sistemas de controle.

Nauck e Nürnberg (2005) em um artigo de revisão, trataram da evolução dos sistemas *neuro-fuzzy* e sugeriram uma classificação para esses sistemas.

Em sistemas de controle, Quadrelli et al. (2003) utilizaram uma modelagem *neuro-fuzzy* para controle de sistemas dinâmicos não-lineares. Harber et al. (2005) implementaram redes *neuro-fuzzy* para controlar processos eletromecânicos complexos. Meza et al. (2006) utilizam redes *neuro-fuzzy* para o processamento de alarmes e localização de defeitos em sistemas de potência.

Castro et al. (2003) implementaram o conceito de máquinas de comitê com um grupo de redes neurais para a previsão de séries temporais não estacionárias. Silva Filho e Roisenberg (2006) trataram o conceito de máquinas de comitê para um aplicação na autenticação de usuários através de dinâmica de digitação em dispositivos de entrada de

dados. Rodrigues Silva e Thomé (2007) construíram um comitê de redes neurais para reconhecimento de letras manuscritas.

Ballini e Gomide (2005) implementaram um algoritmo de aprendizado com um índice igualdade como medida de desempenho em previsão de séries macroeconômicas em uma rede *neuro-fuzzy* recorrente. Castanho (2007) utilizou um sistema *neuro-fuzzy* para prognóstico de câncer de próstata.

Murat (2005) fez comparações em modelos de tráfego de veículos utilizando redes neurais e sistema de inferência *fuzzy* e propõe a utilização de SNF para a solução em destes problemas.

Ciaramella et al. (2006) desenvolveram um sistema *neuro-fuzzy*, intitulado FRNN (*Fuzzy Relational Neural Network*) com a utilização de diferentes normas-T e conormas-T.

Qi et al. (2008) utilizou um método baseado no PSO (otimização por enxame de partículas) para a solução de problemas inversos em transferência radiativa denominado MPPSO (*multi-phase particle swarm optimization*) com a estimação do albedo de espalhamento e a espessura ótica com diferentes funções de fase.

Abordagens híbridas com a combinação de métodos determinísticos e estocásticos estão tornando-se muito populares. Em particular, problemas inversos de estimação de parâmetros de transferência de massa utilizando um método combinado, utilizando *Simulated Annealing*, algoritmos genéticos e redes neurais artificiais com o método de Levenberg-Marquardt (LUGON et al., 2009).

Como classificadores e reconhecimento de padrões Bedregal et al. (2007) utilizaram um sistema *fuzzy* para reconhecimento de gestos; Cazes et al. (2007) implementaram um sistema *neuro-fuzzy* para a classificação de imagens de sensores remotos de alta resolução em conjunto com o classificador espectral estatístico.

Yazdi e Pourreza (2010) utilizam redes *neuro-fuzzy* para a solução de equações diferenciais.

Para a determinação das propriedades radiativas: Souto et al. (2005a, 2005b) determinam do albedo de espalhamento simples através esquemas de pré-regularização com o

sistema de colônia de formigas (*ACO*); com redes neurais artificiais (SOEIRO e SILVA NETO, 2006; SOEIRO et al., 2004, 2003; STUTZ et al., 2006); com máquinas de comitê de redes neurais artificiais (OLIVEIRA et al., 2008), com redes *neuro-fuzzy* (GIL et al., 2008a e 2008b) e com comitês *neuro-fuzzy* (GIL et al., 2009a, 2009b e 2008c).

1.2 Justificativa, relevância e objetivo

Após esta breve apresentação, cabe apontar a contribuição deste trabalho. A motivação inicial foi a de resolver um problema inverso em transferência radiativa para os casos nos quais não houve solução com os métodos de inteligência computacional. A originalidade desta tese está no uso de um sistema híbrido de redes neurais artificiais com sistemas de inferência *fuzzy*, intitulado sistema *neuro-fuzzy*, e a aplicação desse sistema ao conceito de máquinas de comitê, e também à análise de sensibilidade.

No problema inverso em questão, estamos interessados na determinação da espessura ótica τ_0 , do albedo de espalhamento simples ω e das reflectividades difusas ρ_1 e ρ_2 na parte interna das superfícies de contorno do meio. São empregadas nestas determinações medidas experimentais sintéticas das intensidades de radiação emergentes do meio participante em função do ângulo polar.

Para modelar matematicamente a equação de transferência radiativa, objetivo norteador desta pesquisa, foram usadas diferenças finitas para discretizar o domínio espacial e ordenadas discretas (CHANDRASEKHAR, 1950) com vistas à discretizar o domínio angular, conforme será especificado no capítulo 2.

1.3 Divisão em capítulos

Além desta introdução, esta tese está dividida em mais cinco capítulos. No próximo, capítulo 2, serão apresentadas a formulação matemática e a modelagem matemática para a solução do problema direto de transferência radiativa realizada com a versão linear da equação de Boltzmann.

No capítulo 3 será formulado o problema inverso para estimativa dos parâmetros que caracterizam as variáveis radiativas, sendo realizado um estudo da sensibilidade nas direções das intensidades de radiação que deixam o meio participante.

No capítulo 4 serão descritas as estratégias para a solução do problema inverso proposto com a aplicação das redes neurais artificiais, dos sistemas híbridos *neuro-fuzzy* e das máquinas de comitê. Uma análise comparativa desses métodos será realizada a partir dos resultados em duas situações distintas, de forma a validar os modelos propostos.

No capítulo 5 serão apresentados os quatro estudos de casos realizados e os resultados relativos à análise de sensibilidade das propriedades do problema em voga. Baseada nesta análise de sensibilidade, serão apresentados os resultados para o problema inverso proposto através dos modelos com redes *neuro-fuzzy* e máquinas de comitê para esses quatro casos. Apresentar-se-á, ainda, uma avaliação da precisão dos modelos híbridos propostos quando considerada a solução do mesmo problema através dos métodos de otimização.

Ainda, no capítulo 6 estarão descritas as conclusões específicas e gerais obtidas a partir dos resultados gerados pelo modelo híbrido proposto, bem como algumas sugestões de trabalhos futuros para continuidade e aperfeiçoamento desta pesquisa.

Finalmente, além dos capítulos acima citados, essa tese possui dois apêndices e um anexo:

Apêndice A - sobre as arquiteturas *neuro-fuzzy* avaliadas;

Apêndice B - uma complementação da análise de sensibilidade apresentada no capítulo 5 para os casos teste propostos, com a avaliação individual para cada uma das propriedades radiativas.

Anexo I - complementando o estudo sobre sistemas *fuzzy* apresentado no capítulo 4 serão apresentadas as principais características e funcionalidades desses sistemas.

2 TRANSFERÊNCIA RADIATIVA: PROBLEMA DIRETO

A modelagem dos fenômenos associados à interação de radiação eletromagnética com meios participantes (absorvedores, emissores e espalhadores) é feita com versão linear da *equação de Boltzmann*, também conhecida como equação de transporte ou equação de transferência radiativa (SIEGEL,1981; CHANDRASEKHAR, 1950).

O problema direto da transferência radiativa em meios participantes procura determinar os valores das intensidades de radiação em qualquer posição deste meio considerando a discretização do ângulo polar e a simetria azimutal a partir do conhecimento das informações relativas ao termo fonte, das condições de contorno e das propriedades radiativas do meio.

2.1 - Modelagem matemática da transferência radiativa

Inicialmente cabe considerar o problema de transporte de radiação em um meio participante unidimensional, homogêneo¹, sem fontes internas², com espalhador isotrópico, cinza³ e que está sujeito à incidência de radiação isotrópica.

Tal situação física está representada esquematicamente a seguir na Fig. 2.1, na qual L é a espessura do meio e τ_0 é a espessura ótica correspondente.

A formulação matemática da transferência radiativa no interior desse meio é dada pela versão linear da equação de Boltzmann, ou equação de transporte, que pode ser escrita para o caso de simetria azimutal, na forma adimensional (CHANDRASEKHAR, 1950), como a seguir:

$$\mu \frac{\partial I(\tau, \mu)}{\partial \tau} + I(\tau, \mu) = \frac{\omega}{2} \int_{-1}^1 p(\mu, \mu') I(\tau, \mu') d\mu' \quad \text{em } 0 < \tau < \tau_0, -1 \leq \mu \leq 1 \quad (2.1a)$$

Condições de contorno relacionadas:

$$I(0, \mu) = f_1(\mu) + 2\rho_1 \int_0^1 I(0, -\mu') \mu' d\mu', \mu > 0 \quad (2.1b)$$

$$I(\tau_0, \mu) = f_2(\mu) + 2\rho_2 \int_0^1 I(\tau_0, \mu') \mu' d\mu', \mu < 0 \quad (2.1c)$$

¹ Os coeficientes de absorção e de espalhamento não dependem da posição.

² O termo de emissão é considerado desprezível frente à radiação externa incidente no meio.

³ As propriedades radiativas do meio independem do comprimento de onda da radiação.




Figura 2.1: Meio participante unidimensional sujeito à incidência de radiação isotrópica com intensidades $f_1(\mu)$ e $f_2(\mu)$.

Observando as condições acima, com base na equação 2.1a, temos a seguinte correspondência detalhada na tabela abaixo:

Tabela 2.1: Variáveis utilizadas na formulação matemática do problema de transferência radiativa.

$I(\tau, \mu)$	Intensidade da radiação
ω	Albedo de espalhamento simples
τ	Variável ótica
τ_0	Espessura ótica do meio
μ	Cosseno do ângulo formado entre o eixo τ positivo e a direção da radiação, ou seja, o cosseno do ângulo polar θ ($\mu = \cos\theta$)
$f_1(\mu)$ e $f_2(\mu)$	Intensidades de radiação incidente, respectivamente, em $\tau = 0$ e $\tau = \tau_0$
ρ_1 e ρ_2	Reflectividades difusas nas superfícies, em $\tau = 0$ e $\tau = \tau_0$ (na parede interna ao meio)
$p(\mu, \mu')$	Função de fase usualmente escrita como a expansão em polinômios de Legendre (ÖZISIK, 1973).

$$p(\mu, \mu') = \sum_{n=0}^M (2n + 1) f_n P_n(\mu) P_n(\mu') \quad (2.2)$$

Com $f_0 = 1$, sendo f_n os coeficientes da expansão.

Como neste trabalho é considerado apenas o caso de espalhamento isotrópico, i.e., $M = 0$, da equação 2.2 resulta

$$p(\mu, \mu') = P_0(\mu)P_0(\mu') = 1 \quad (2.3)$$

considerando

$$d\tau \cong \beta dy \quad (2.4a)$$

e integrando até o ponto y no interior do meio, com $0 \leq y \leq L$, obtém-se a variável ótica τ ,

$$\tau = \int_0^y \beta dy' \quad (2.4b)$$

Integrando então até $y = L$, obtém-se a espessura ótica do meio

$$\tau_0 = \beta L \quad (2.5)$$

O albedo de espalhamento simples corresponde à razão entre o coeficiente de espalhamento σ_s e o coeficiente de extinção total β , sendo

$$\omega = \frac{\sigma_s}{\beta} \quad (2.6)$$

com

$$\beta = k_a + \sigma_s \quad (2.7)$$

no qual k_a é o coeficiente de absorção.

Apenas para citar alguns exemplos, na Tabela 2.2, são fornecidos os valores dos coeficientes de absorção e de espalhamento para a água do mar.

Tabela 2.2: Coeficientes de absorção k_a e de espalhamento σ_s para a água do mar (MOBLEY, 1994).

Tipo	$k_a (m^{-1})$	$\sigma_s (m^{-1})$
água do mar pura	0,0405	0,0025
oceano longe da costa	0,114	0,037
oceano junto à costa	0,179	0,219
água turva	0,366	1,824

Um segundo exemplo, na Tabela 2.3 são apresentados os valores do coeficiente de extinção total, da espessura ótica e do albedo de espalhamento simples considerando uma lâmina de água do mar com 5 m de espessura.

Tabela 2.3: Coeficiente de extinção total β , espessura ótica τ_0 e albedo de espalhamento simples ω para a água do mar. Valores calculados a partir da Tabela 2.1 para uma lâmina de água com $L = 5$ m de espessura (SILVA NETO e BECCENERI, 2009).

Tipo	$\beta = k_a + \sigma_s \text{ (m}^{-1}\text{)}$	$\tau_0 = \beta L$	$\omega = \frac{\sigma_s}{\beta} = \frac{\sigma_s}{k_a + \sigma_s}$
água do mar pura	0,043	0,215	0,058
oceano longe da costa	0,151	0,755	0,245
oceano junto à costa	0,398	1,990	0,550
água turva	2,190	10,95	0,833

Para citar um último exemplo, na Tabela 2.4 são fornecidos os valores do coeficiente de extinção β e da espessura ótica para nuvens cirrus.

Tabela 2.4: Propriedades médias de nuvens cirrus obtidas na Universidade Central Nacional de Taiwan no período de 1999 a 2006. β é o coeficiente de extinção e τ_0 a espessura ótica (DAS et al., 2009).

Tipo de nuvem cirrus	Propriedade	Média anual
Sub-visível ($\tau_0 < 0,03$)	$\beta \text{ (m}^{-1}\text{)}$	$0,013 \pm 0,008$
	τ_0	$0,012 \pm 0,008$
Fina ($0,03 < \tau_0 < 0,3$)	$\beta \text{ (m}^{-1}\text{)}$	$0,118 \pm 0,15$
	τ_0	$0,114 \pm 0,071$
Espessa ($\tau_0 > 0,3$)	$\beta \text{ (m}^{-1}\text{)}$	$0,42 \pm 0,33$
	τ_0	$0,67 \pm 0,4$

2.2 - Solução numérica do problema de transferência radiativa em meios participantes

Diversos métodos têm sido utilizados para solucionar este problema direto em transferência radiativa. Nesta seção, é apresentada uma solução numérica utilizando o método de ordenadas discretas (CHANDRASEKHAR, 1950), com quadratura Gauss-Legendre e com uma aproximação por diferenças finitas para a discretização do domínio espacial para o meio participante unidimensional (Fig. 2.2) e do domínio angular (Fig. 2.3) para a versão linear da equação de Boltzmann com as condições de contorno definidas na Eq. (2.1).




Figura 2.2: Discretização do domínio espacial para o meio homogêneo unidimensional, $0 \leq \tau \leq \tau_0$.




Figura 2.3: Discretização do domínio angular com ordem N , $-1 \leq \mu \leq 1$.

As intensidades da radiação nos domínios angular e espacial discretizados são representadas por

$$I_m^i = I(\tau_i, \mu_m) \quad (2.8)$$

com

$$\tau = (i - 1)\Delta\tau, \quad i = 1, 2, \dots, N_x \quad \text{e} \quad m = 1, 2, \dots, N \quad (2.9)$$

onde

$$\Delta\tau = \frac{\tau_0}{N_x - 1} \quad (2.10)$$

O termo integral o lado direito da Eq. (2.1) é substituído por uma quadratura de Gauss-Legendre

$$q^i = \frac{\omega}{2} \int_{-1}^1 I(\tau, \mu') d\mu' \cong \frac{\omega}{2} \sum_{n=1}^N a_n I_n^i \quad (2.11)$$

onde a_n , $n = 1, 2, \dots, N$, são os pesos da quadratura correspondentes aos os pontos de colocação, μ_n . Como um exemplo, na tabela 2.5 são apresentados os pontos de colocação e os pesos para o caso com $N = 20$.

Podem ser observado que

$$\mu_{N-i+1} = -\mu_i, \quad \text{com } \mu_i > 0, \quad i = 1, 2, \dots, \frac{N}{2} \quad (2.12)$$

e

$$a_{N-i+1} = a_i, \quad i = 1, 2, \dots, \frac{N}{2} \quad (2.13)$$

Tabela 2.5: Pontos de colocação e pesos para a quadratura Gauss-Legendre (ABRAMOWITZ, 1970), com ordem $N = 20$.

μ	a
$\mu_1 = -\mu_{20} = 0,07652$	0,15275
$\mu_2 = -\mu_{19} = 0,22778$	0,14917
$\mu_3 = -\mu_{18} = 0,37370$	0,14209
$\mu_4 = -\mu_{17} = 0,51086$	0,13168
$\mu_5 = -\mu_{16} = 0,63605$	0,11819
$\mu_6 = -\mu_{15} = 0,74633$	0,10193
$\mu_7 = -\mu_{14} = 0,83911$	0,08327
$\mu_8 = -\mu_{13} = 0,91223$	0,06267
$\mu_9 = -\mu_{12} = 0,96397$	0,04060
$\mu_{10} = -\mu_{11} = 0,98940$	0,01761

Considerando aproximações por diferenças finitas avançadas e atrasadas para o primeiro termo do lado esquerdo da equação (2.1a) obtém-se

$$\left(\frac{\partial I(\tau, \mu)}{\partial \tau} \right) \Big|_{(\tau_i, \mu_m)} = \frac{I_m^{i+1} - I_m^i}{\Delta \tau}, \quad \text{e} \quad (2.14a)$$

$$\left(\frac{\partial I(\tau, \mu)}{\partial \tau} \right) \Big|_{(\tau_i, \mu_m)} = \frac{I_m^i - I_m^{i-1}}{\Delta \tau} \quad (2.14b)$$

Das Eqs. (2.1a), (2.11) e (2.14) obtém-se então

A Eq. (2.1b) na superfície de contorno $\tau = 0$ é aproximada por

$$I_m^1 = f_1(\mu_m) + 2\rho_1 \sum_{n=\frac{N}{2}+1}^N a_n |\mu_n| I_n^1, \quad \text{com } m = 1, 2, \dots, \frac{N}{2} \quad (2.15a)$$

A Eq. (2.1c) na superfície de contorno $\tau = \tau_0$ é aproximada por

$$I_m^{N_x} = f_2(\mu_m) + 2\rho_2 \sum_{n=1}^{N/2} a_n |\mu_n| I_n^{N_x}, \quad m = \frac{N}{2} + 1, \frac{N}{2} + 2, \dots, N \quad (2.15b)$$

A partir da equação (2.15a) é realizada então uma marcha para frente sendo calculados os valores de I_m^{i+1} com a equação (2.14a), para $m = 1, 2, \dots, \frac{N}{2}$, e $i = 1, 2, \dots, N_x - 1$.

A partir da equação (2.15b) é realizada então uma marcha para trás sendo calculados os valores de I_m^{i-1} com a equação (2.14b), para $m = \frac{N}{2} + 1, \frac{N}{2} + 2, \dots, N$, e $i = N_x, N_x - 1, \dots, 2$.

As marchas para frente e para trás são repetidas até que um critério de parada seja atendido, como por exemplo a convergência nos valores da intensidade da radiação.

As intensidades da radiação que efetivamente emergem em $\tau = 0$ e $\tau = \tau_0$ são dadas por

$${}^{ef}I_m^1 = (1 - \rho_1)I_m^1, \quad \text{para } m = \frac{N}{2} + 1, \frac{N}{2} + 2, \dots, N \quad (2.16a)$$

$${}^{ef}I_m^{N_x} = (1 - \rho_2)I_m^{N_x}, \quad \text{para } m = 1, 2, \dots, \frac{N}{2} \quad (2.16b)$$

3 TRANSFERÊNCIA RADIATIVA: PROBLEMA INVERSO

Existem diversas metodologias para se formular e resolver os problemas inversos (PI), e conseqüentemente existem diversas classificações para os mesmos (CAMPOS VELHO, 2008). Segundo Engl et al. (1996), “a solução do problema inverso consiste na determinação do estado atual do sistema a partir de observações futuras ou na identificação de parâmetros físicos a partir de observações da evolução do sistema”.

Em relação às classificações, ressaltam-se duas correntes: a) Beck (1985) classifica os problemas inversos em dois grupos: estimativa de parâmetros e estimativa de funções; Silva Neto e Moura Neto (2005) classificam os problemas inversos quanto à natureza e dimensão do problema.

Nesta pesquisa, utilizaremos como base conceitual a segunda metodologia de classificação, de acordo com os tipos que a integram tal, a saber:

- a) Tipo I: Estimação de um número finito de parâmetros em um modelo de dimensão finita;
- b) Tipo II: Estimação de um número finito de parâmetros em um modelo de dimensão infinita;
- c) Tipo III: Estimação de um número infinito de parâmetros ou de uma função em um modelo de dimensão infinita.

Com base nessa tipologia, focaremos em um problema do tipo II, relacionado à estimativa de quatro parâmetros (constantes) em um problema modelado por uma equação íntegro-diferencial.

3.1 O problema inverso

Considerando que a condição de contorno, o termo fonte e as propriedades radiativas do meio são desconhecidos, mas as informações sobre os valores experimentais das intensidades da radiação I que saem do meio participante possam ser medidas.

A questão é: podem-se determinar as grandezas desconhecidas a partir destes dados experimentais? Isto é, a partir dos valores das intensidades da radiação medidos experimentalmente que deixam o meio participante, é possível determinar as propriedades radiativas? Este é o problema inverso (PI) modelado, conforme a representação esquemática na Fig. 3.1.




Figura 3.1: Representação esquemática do Problema Inverso (SILVA NETO, 2007).

Para uma análise mais eficiente da solução deste problema inverso, algumas questões deverão ser levadas em consideração, como a existência da unicidade da solução, a sensibilidade dos dados experimentais às incógnitas que se deseja determinar e a possibilidade de amplificação de ruídos (SILVA NETO e BECCENERI, 2009).

Neste capítulo, portanto, será tratado o problema inverso de transferência radiativa para a estimativa da espessura ótica τ_0 , do albedo de espalhamento simples ω e das reflectividades difusas ρ_1 e ρ_2 nas superfícies internas de contorno em um meio participante unidimensional homogêneo, utilizando medidas de intensidade de radiação que deixam o meio participante em $\tau = 0$ e $\tau = \tau_0$.

3.2 Modelagem matemática do problema inverso em transferência radiativa

Várias formulações podem ser utilizadas para resolver o problema inverso em transferência radiativa. Como exemplo, os métodos de otimização e uma combinação desses com métodos de inteligência computacional vêm sendo utilizados nessas últimas duas décadas. Estes últimos, têm sido objeto de interesse de vários pesquisadores na aplicação da solução de problemas complexos.

Neste contexto, esta tese abordará a utilização de alguns dos métodos de inteligência computacional e uma hibridização desses, buscando com este procedimento a determinação das propriedades radiativas do meio requeridas a partir das medidas da radiação que deixam o meio.

Desta forma, conhecendo-se as medidas da intensidade da radiação que deixam o meio participante para os diferentes ângulos polares (θ_i , i.e. $Y_i, i = 1, 2, \dots, N_e$), onde N_e é o número total de medidas experimentais, e as propriedades radiativas do meio ($\omega, \tau_0, \rho_1, \rho_2$) sendo desconhecidas, procura-se a solução do problema inverso a partir dos valores das intensidades da radiação que deixa o meio em estudo.

Por conveniência na formulação do problema inverso é aqui considerado que o número de dados experimentais coincide com o número de direções usado na discretização do domínio angular, e, além disso, Y_i é medido no ângulo polar correspondente a μ_i , onde $\mu_i = \cos\theta$, conforme Fig. 3.2.




Figura 3.2: Representação esquemática do dado experimental.

Assim, o vetor de incógnitas

$$Z = \{\omega, \tau_0, \rho_1, \rho_2\}^T \quad (3.1)$$

é determinado a partir das intensidades de radiação que emergem do meio participante.

3.3 Dados experimentais

Neste problema inverso, os dados experimentais são as próprias intensidades de radiação que apresentam dependência com o ângulo polar. Como não é possível obter as propriedades radiativas diretamente, mede-se a intensidade de radiação que sai do meio para diferentes ângulos polares, e a partir dessa informação busca-se a solução do problema inverso.

Na solução do problema inverso deve-se buscar a utilização de dados experimentais reais. Entretanto, como nem sempre estes dados estão disponíveis em uma aplicação real, é uma prática usual a geração de dados experimentais sintéticos I_{exp} com a adição de ruídos pseudo-aleatórios aos valores calculados das intensidades de radiação através de um método que modele o problema direto, conforme a seguir:

$$Y_i = I_{exp_i} = I_{calc_i}(Z_{exato}) + \sigma r_i, i = 1, 2, \dots, N_e \quad (3.2)$$

onde, I_{calc_i} representa os valores calculados da intensidade de radiação usando os valores exatos dos parâmetros, os quais queremos determinar com a solução do problema inverso. σ simula o desvio padrão dos erros dos dados experimentais, e r_i é um número pseudo-aleatório gerado no intervalo $[-1, 1]$.

Para a geração dos dados sem inserção de ruído pode-se utilizar uma interface web desenvolvida por pesquisadores em problemas inversos em transferência radiativa, disponível em www.transferenciaraadiativa.com.br (GAGLIARDI, 2010).

3.4 Análise de sensibilidade

A análise de sensibilidade desempenha um papel importante em vários aspectos relacionados com a formulação e solução de problemas inversos (BECK et al., 1985; MILANDRI et al., 2002).

Quando se estuda um problema direto, deseja-se que o mesmo seja pouco sensível aos parâmetros de entrada. Assim, caso ocorra um erro de avaliação nos dados, o fenômeno ainda será bem representado. Na solução de um problema inverso, necessita-se justamente o contrário, pois a maior sensibilidade permitirá a estimativa do parâmetro estudado (LUGON et al., 2002).

O estudo de sensibilidade consiste em avaliar, numérica ou analiticamente, as derivadas do valor calculado para a grandeza que pode ser observada (medida experimentalmente) com relação aos parâmetros que se deseja estudar. Essas derivadas correspondem à sensibilidade do fenômeno a pequenas variações nos parâmetros de entrada.

Quando se busca estimar diversos parâmetros, os efeitos de cada um deles na intensidade de radiação devem ser diferentes, ou seja, independentes. Se os coeficientes de sensibilidade relativos a dois parâmetros diferentes têm a mesma forma, significa que eles afetam a intensidade de radiação da mesma maneira, sendo difícil distinguir suas influências e consequentemente estimá-los.

Para complementar o estudo para a solução deste problema inverso, foi inserida a análise da sensibilidade dos dados experimentais às incógnitas que se deseja determinar ω , τ_0 ,

ρ_1 e ρ_2 , por uma aproximação por diferenças finitas (MDF), procurando distinguir a influência destes parâmetros no fenômeno estudado, conforme é apresentado na Fig. 3.3.

Os coeficientes de sensibilidade X_{Z_j} são dados por

$$X_{Z_j} = Z_j \frac{\partial I_{exp_i}(Z)}{\partial Z_j}, i = 1, 2, \dots, N_d \text{ e } j = 1, 2, \dots, N \quad (3.3)$$

onde Z_j representa uma variável específica, N_d é o número total direções usado na discretização do domínio angular e N é o número total de variáveis ($N = 4$).




Figura 3.3: Representação gráfica do cálculo dos coeficientes de sensibilidade

A fim de se obter boas estimativas, ou seja, a confiança dentro de limites razoáveis, é necessário que os coeficientes de sensibilidade sejam elevados. Além disso, quando duas ou mais variáveis são estimados simultaneamente, os coeficientes de sensibilidade devem ser correlacionados. Isso significa que eles não devem apresentar a mesma forma; caso contrário, dois ou mais parâmetros podem afetar da mesma maneira a quantidade observada, I_{exp_i} , que na verdade é medido experimentalmente.

Nesta tese a análise de sensibilidade foi baseada em um método onde os parâmetros são estimados separadamente e apenas os dados com maior sensibilidade serão usados na estimativa de cada variável.

No capítulo 5, seção 5.3.2, são apresentados os resultados obtidos na análise de sensibilidade dos casos testes propostos.

4 ESTRATÉGIAS PARA A SOLUÇÃO DO PROBLEMA INVERSO

Neste capítulo serão apresentadas as estratégias metodológicas para a solução do problema inverso de transferência radiativa empregando redes neurais artificiais, redes *neuro-fuzzy* e máquinas de comitê *neuro-fuzzy*.

Inicialmente, busca-se apresentar as características e arquitetura das redes neurais artificiais, que são modelos computacionais não lineares, inspirados na estrutura e operação do cérebro humano, que procuram reproduzir características humanas. Será abordada a questão da aquisição do conhecimento numérico através dos ajustes dos pesos sinápticos na fase de treinamento dessas redes e as particularidades e a importância desta fase.

Em seguida, procura-se introduzir conceitos sobre a Lógica *Fuzzy* que tem por objetivo modelar o modo aproximado de raciocínio humano, visando desenvolver sistemas computacionais capazes de tomar decisões racionais em um ambiente de incerteza e imprecisão. Fornecendo uma resposta aproximada para uma questão atrelado a um conhecimento que é inexato, incompleto ou não totalmente confiável. Com base no uso de variáveis linguísticas e o raciocínio dedutivo, instituído através de regras de inferência.

A partir dos conceitos das redes neurais e da lógica *fuzzy*, é apresentada uma estrutura que incorpora em um único sistema o conhecimento explícito de especialistas e o conhecimento implícito inerente a um conjunto de dados, gerando um sistema híbrido *neuro-fuzzy*.

Por último é abordado o conceito de máquinas de comitê, que é formado por um grupo de especialistas, usados para resolver tarefas complexas. Os membros deste comitê serão estruturas *neuro-fuzzy*.

4.1 Redes Neurais Artificiais

As Redes Neurais Artificiais (RNAs) vêm sendo estudadas por várias décadas desde a primeira aplicação do aprendizado para a classificação de padrões dos perceptrons com uma camada simples (ROSENBLATT, 1962). Entretanto, devido às críticas realizadas por Marvin Minsky e Seymour Papert (1969), que postularam sobre a limitação das propriedades matemáticas que o perceptron de uma camada possuía, i.e., somente poderia ser utilizado na solução de problemas linearmente separáveis, fato este que desencadeou o desinteresse pelo apoio financeiro às pesquisas voltadas para este assunto.

Somente em meados dos anos 80 a partir da publicação do excelente artigo de Hopfield (1982) sobre arquitetura de redes recorrentes não supervisionadas, e com o desenvolvimento dos métodos de treinamento com retropropagação para o perceptron multicamadas – *MLP* (RUMELHART, 1986), foi retomado o apoio às pesquisas com as redes neurais artificiais, possibilitando o desenvolvimento de diversas aplicações através das RNAs, inclusive para a solução de problemas inversos (WOODBURY, 1998; KREJSA et al., 1999; ISSAMOTO et al., 1999; BRAGA et al., 2000).

4.1.1 Formulação e solução do problema inverso com redes neurais artificiais

Na Fig. 4.1 é representada a rede neural *MLP* (*Multilayer Perceptron*) com as camadas de entrada e de saída, e uma ou mais camadas intermediárias, estruturada para a solução do problema inverso de transferência radiativa. Nesta RNA existem N_e nós na entrada, N_z neurônios na camada de saída, N_h neurônios na camada intermediária.

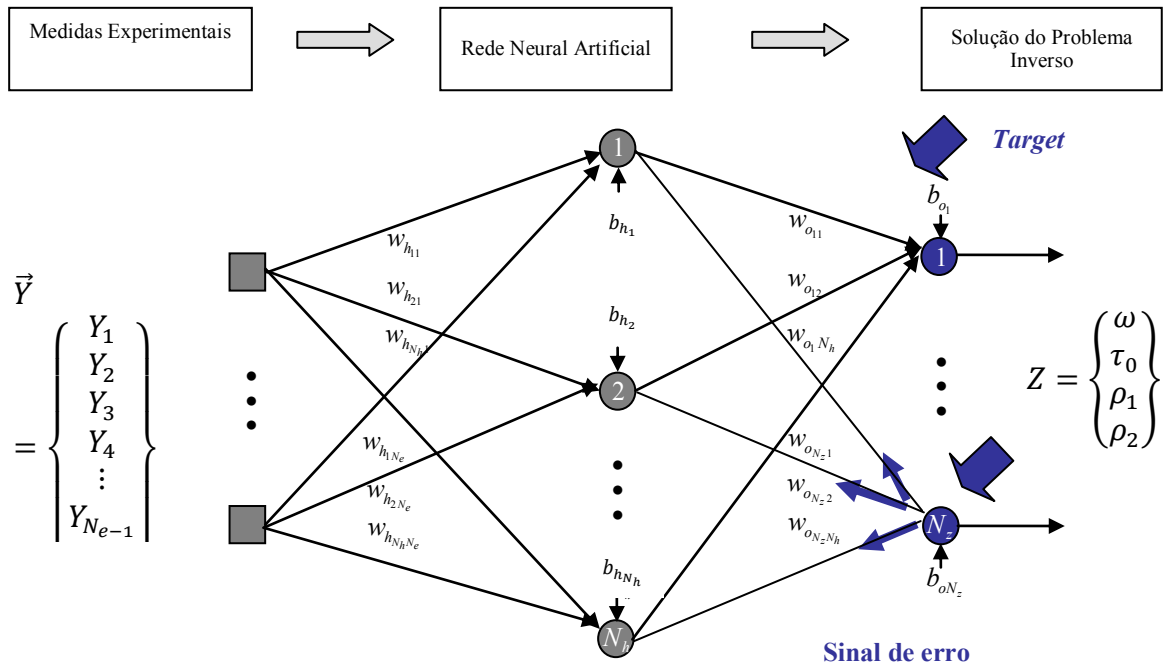


Figura 4.1: Modelo de uma Rede Neural *MLP* com uma camada intermediária para o problema inverso de transferência radiativa.

Conforme é apresentada na Fig. 4.1, são identificadas as intensidades de radiação deixam o meio, Y_i , $i = 1, 2, \dots, N_e$, fornecidos pelo vetor Y na camada de entrada da RNA. Assim, é esperado que a RNA produza na camada de saída uma aproximação para a solução do problema inverso, em um vetor Z . Cada neurônio j na camada intermediária, com $j = 1, 2, \dots, N_h$, realiza a combinação linear com os valores fornecidos pela camada de entrada e os seus respectivos pesos sinápticos,

$$p_j = \sum_{i=1}^{N_e} w_{hji} Y_i + b_{hj}, \quad j = 1, 2, \dots, N_h, i = 1, 2, \dots, N_e \quad (4.1)$$

onde, w_{hji} , $j = 1, 2, \dots, N_h, i = 1, 2, \dots, N_e$, são os pesos das conexões entre os nós da camada de entrada e os neurônios da camada oculta, e b_{hj} representa os *bias* da camada oculta.

O somatório dos sinais de entrada multiplicados pelos seus respectivos pesos é determinado pela Eq. (4.1), sendo visto como a excitação do neurônio j na camada intermediária, o qual resulta na resposta

$$v_j = f(p_j), j = 1, 2, \dots, N_h \quad (4.2)$$

onde f é a função de ativação da camada oculta. As funções de ativação utilizadas nesta tese foram: tangente hiperbólica e sigmóide.

Em cada neurônio z na camada de saída, com $z = 1, 2, \dots, N_z$ é realizada a combinação linear das respostas v_j multiplicadas pelos respectivos pesos dos neurônios da camada oculta $j = 1, 2, \dots, N_h$,

$$s_z = \sum_{j=1}^{N_h} w_{ozj} v_j + b_{oz}, z = 1, 2, \dots, N_z \quad (4.3)$$

onde w_{ozj} , $z = 1, 2, \dots, N_z$, $j = 1, 2, \dots, N_h$, são os pesos das conexões entre os neurônios da camada intermediária e os neurônios da camada de saída, b_{oz} são os *bias* da camada de saída e N_z é o número de neurônios na camada de saída.

O somatório das informações oriundas da camada intermediária multiplicados pelos respectivos pesos é determinado pela Eq. (4.3), sendo visto como a excitação do neurônio z na camada de saída, o qual resulta na resposta

$$t_z = g(s_z), z = 1, 2, \dots, N_z \quad (4.4)$$

onde g é a função de ativação da camada de saída.

Das Eqs. (4.1) e (4.4), escreve-se, para caso de uma RNA com uma camada intermediária

$$t_z = g \left(\sum_{j=1}^{N_h} w_{ozj} f \left(\sum_{i=1}^{N_e} w_{hji} Y_i + b_{h_j} \right) + b_{oz} \right), z = 1, 2, \dots, N_z \quad (4.5)$$

A partir então do conhecimento dos dados experimentais Y_i , $i = 1, 2, \dots, N_e$, obtém-se a estimativa para as incógnitas Z a partir da Eq. (4.5). Porém, é necessário que primeiro sejam determinados os pesos sinápticos. Este é o objetivo da próxima seção.

4.1.2 Treinamento das redes neurais

A fase de treinamento é um processo iterativo e contínuo de ajuste dos pesos das conexões entre os neurônios. Nesta etapa é realizado o processo de atualização dos pesos sinápticos e bias. O objetivo principal é adquirir a informação e expressá-la sob a forma de uma matriz de pesos w e bias b . Essa fase é a mais demorada e o processo de atualização dos pesos e bias envolve algoritmos de minimização de erro que em certas circunstâncias, pode ter convergência lenta, paralisada ou até mesmo oscilar indefinidamente.

Encontrar a arquitetura ideal, definir o conjunto de parâmetros usados no treinamento e estabelecer o método mais adequado pode não ser uma tarefa simples e rápida, já que tal tarefa não é determinística e, portanto não existe - pelo menos de forma eficaz e eficiente - um conjunto de métricas que permitam constituir esses parâmetros (HAYKIN, 2001; GIL, 2005).

Vale ressaltar que há diversas classificações e técnicas de treinamento para RNAs. A aprendizagem supervisionada é a mais popular de todas, e caracteriza-se pela existência de um "supervisor", que indica à rede a resposta desejada para cada padrão de entrada apresentado.

No início do processo de treinamento, a RNA não tem nenhum conhecimento do ambiente a ser representado. Durante o treinamento, os parâmetros da rede são ajustados, em função do estímulo recebido na entrada e do sinal de erro definido pela diferença entre a resposta corrente fornecida pela rede e a resposta desejada, informada pelo processo de supervisão.

No aprendizado supervisionado, a RNA é treinada através do fornecimento dos valores de entrada e seus respectivos valores de saída desejados ou, simplesmente, alvos formando pares de treinamento. Na verdade, esses pares de treinamento definem o mapeamento o qual se deseja que a RNA aprenda. Assim, o processo de treinamento da RNA tenta minimizar ou corrigir o erro entre o sinal de saída e a resposta desejada. Os parâmetros são alterados iterativamente até que o erro atinja certo valor mínimo pré-estabelecido. A partir deste instante, supõe-se que a RNA tenha adquirido o conhecimento transmitido pelo "supervisor", encerrando-se o processo de aprendizagem.

Em relação a tal procedimento, é importante ressaltar que o treinamento supervisionado é usado em vários tipos de RNAs, dentre elas o Perceptron de Múltiplas Camadas - *MLP* (HAYKIN, 2001; HASSOUN, 1995; ZURADA, 1992).

O algoritmo de treinamento do *MLP*, chamado de retropropagação - ou, no original *backpropagation* (BP)-, baseia-se no modelo de aprendizado supervisionado, retropropagando-se os erros da camada de saída para o treinamento dos pesos das camadas intermediárias. Tal algoritmo foi proposto por Paul Werbos (1974) e difundido por Rumelhart, Hinton e Williams (1986).

O treinamento da rede *MLP* é dividido em duas fases principais: *forward* e *backward*. A primeira consiste na propagação dos estímulos apresentados à entrada para a saída. Esses estímulos fluem por toda a rede, recebendo a computação neural, camada por camada, até gerarem a saída (O). A partir do resultado desejado (*target*), calcula-se o erro na camada de saída.

A segunda etapa ocorre em sentido contrário. O erro calculado é então retropropagado pelas camadas antecessoras (*error-back-propagation*), atualizando os pesos das conexões pelo uso de regras específicas. O algoritmo BP (BISHOP, 1995; UNBEHAUEN e REI, 2000) é baseado no método do gradiente descendente, que computa as derivadas parciais de uma função de erro E_z , com relação ao vetor peso w de certo vetor de entrada Y . A atualização do peso e do *bias* é realizada conforme as Eqs. (4.9) e (4.10).

Considerando o dado experimental $Y_i, i = 1, 2, \dots, N_e$, pode ser observado na Eq. (4.5), que $t_z, z = 1, 2, \dots, N_z$, são as estimativas obtidas pela RNA para o alvo, i.e., uma aproximação para o $Z_z, z = 1, 2, \dots, N_z$.

Entretanto, até que se possa chegar ao resultado final de \vec{Z} , é necessária a determinação dos pesos w_h e w_o , sendo mandatório o ajuste destes parâmetros, a partir do treinamento da RNA com padrões conhecidos (entrada $Y_{experimental}$ e as variáveis radiativas Z_{alvo}). O cálculo destes pesos resulta na melhor aproximação entre os valores t_z calculados e o alvo Z_{alvo} .

Os pesos sinápticos e *bias* são gerados aleatoriamente no início desta fase de aprendizagem da RNA e os valores de conjunto de dados de entrada $Y_{experimental}$ são

alimentados adiante através da RNA, chegando a um valor de saída t , o qual é comparado com Z_{alvo} , resultando no erro

$$Z_{rede} = t_z \quad (4.6)$$

$$e_z = Z_{alvo} - Z_{rede}, \quad z = 1, 2, \dots, N_z \quad (4.7)$$

calculando então

$$E_z = \frac{1}{2} \|e_z\|^2, \quad (4.8)$$

ou seja,

$$E_z = \frac{1}{2} \sum_{i=1}^N (Z_{alvo} - Z_{rede})^2, \quad (4.9)$$

a variação dos pesos é realizada conforme fluxograma na Fig. 4.2

$$\Delta w = -\eta \frac{\partial E_z}{\partial w} \quad (4.10)$$

onde η é a taxa de aprendizagem, nas camadas intermediária e de saída.

O aprendizado de uma RNA resulta das muitas apresentações de um determinado conjunto de exemplos de treinamento para o perceptron de múltiplas camadas. Uma apresentação completa de um conjunto de treinamento inteiro é denominada uma *época*.

Os passos adiante e para trás são realizados sucessivamente até o que o critério de convergência relativo ao erro médio quadrático (*MSE*) Eq. (4.9) seja satisfeito, ou caso contrário, o número máximo de épocas seja atingido.

Para a realização do treinamento supervisionado das RNAs torna-se necessário definir os dados padrões na camada de entrada e os respectivos alvos (*target*) na camada de saída.

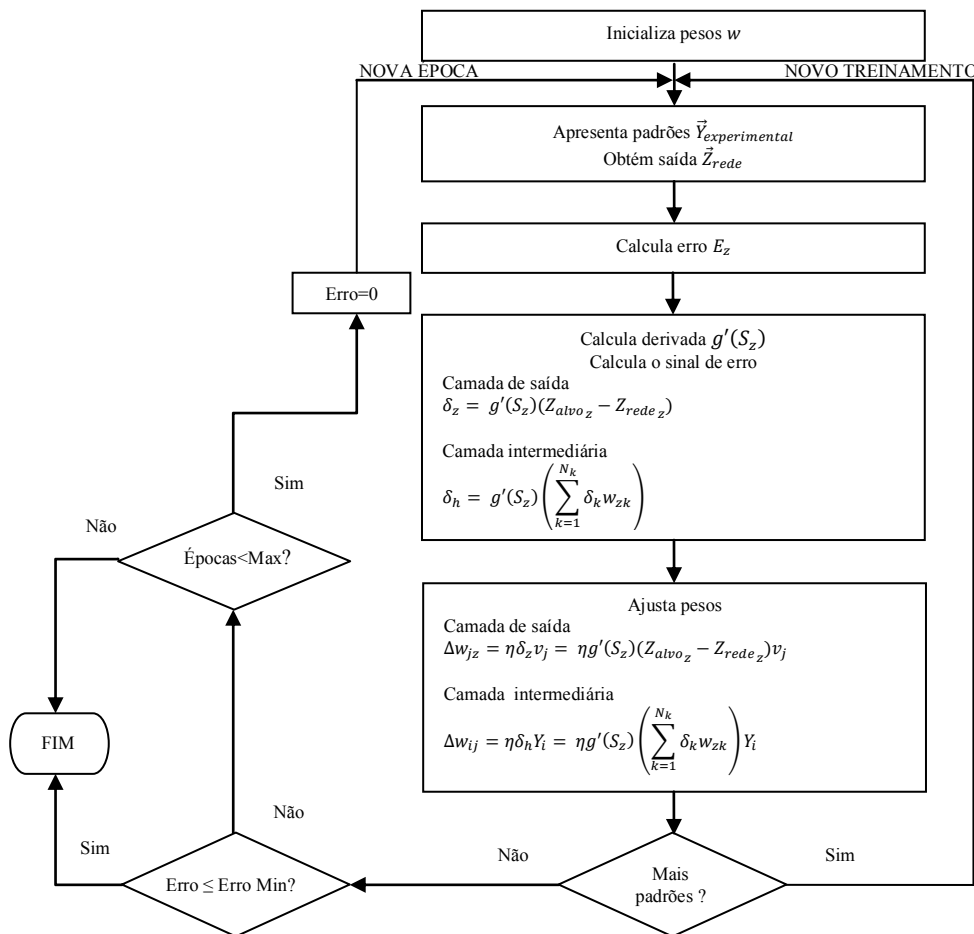


Figura 4.2: Fluxograma do algoritmo BP

Para o treinamento da rede neural, foram utilizados vários conjuntos de dados experimentais, gerados a partir da solução exata do problema direto, ou seja, assumindo-se conhecidos os parâmetros em $Z = \{\omega, \tau_0, \rho_1, \rho_2\}^T$, foram geradas as diferentes medidas de radiação Y , com o procedimento descrito no capítulo 2. Estes valores serão apresentados como informações (*input*) nos nós de entrada da rede neural e os respectivos parâmetros Z na camada de saída da rede como alvo (*target*) para a rede neural.

4.1.3 Treinamento das redes neurais com validação cruzada

Procurando alcançar o objetivo de uma boa generalização, i.e., a aquisição do conhecimento e a condição de responder eficientemente para um ambiente próximo, mas, não

idêntico a aquele no qual foi treinado, as redes neurais *MLP* são treinadas com o algoritmo de retropropagação aprendendo em estágios, partindo da realização de funções de mapeamento para funções cada vez mais complexas, conforme a seção de treinamento avança. Isto é exemplificado pelo fato de que, em uma situação típica, o erro médio quadrático dado pela Eq. (4.9) decresce com o aumento do número de épocas durante o treinamento: inicialmente é esperado que valor do erro seja alto e decresça em direção a um mínimo local na superfície de erro.

Entretanto, dada certa arquitetura para se alcançar uma condição ótima para a generalização da rede, é necessário identificar quando é o melhor momento para encerrar o treinamento, procurando evitar abortar o processo antes que a rede tenha de fato absorvido adequadamente o conhecimento necessário, ou continuar o treinamento indefinidamente, levando a rede a um super treinamento, fato que levará a RNA a memorizar os padrões de treinamento. Isto é, o aprendizado da rede além do ponto mínimo da curva de validação (Fig. 4.3).

Para alcançar esse ponto de mínimo, há a alternativa da utilização da curva da validação como um critério ótimo para encerrar a sessão de treinamento (HAYKIN, 2001; GIL, 2005).

Assim, a utilização da validação cruzada na fase de treinamento da rede demonstra a sua importância: o conjunto de dados de treinamento (*input* e *target*) é dividido em duas partes; um subconjunto de treinamento que é usado para treinar a RNA de maneira usual, e um subconjunto que será utilizado para a avaliação da validação cruzada e teste.

A sessão de treinamento é interrompida periodicamente, e a RNA é testada com o subconjunto de validação. O erro obtido com a validação cruzada é monitorado durante o processo de treinamento, e este normalmente decresce durante a fase inicial da fase de treinamento da rede. Entretanto, quando a rede inicia um processo de super aprendizado, o erro da validação geralmente tende a aumentar (DEMUTH e BEALE, 2002). Quando isso ocorre seguidamente, após um número de iterações previamente definido, o treinamento da RNA é interrompido e os valores dos pesos e *bias* obtidos serão retornados quando o valor do erro da validação cruzada foi tido como mínimo.

Na Fig. 4.3 é apresentado um exemplo das curvas: do erro médio quadrático, da validação cruzada e de teste na fase de treinamento da RNA.




Figura 4.3: Exemplo curva da validação cruzada, comparando-se com as curvas de treinamento durante a fase de treinamento da RNA (HAYKIN, 2001; GIL, 2005).

Como pode ser observado na mesma figura, foi utilizado o ponto mínimo da curva da validação como um critério para encerrar a sessão de treinamento, ou seja, a 40ª época. Observe que a curva de treinamento volta a cair próxima à 50ª época, o que sugere um melhor resultado, mas o que está realmente acontecendo é uma memorização dos padrões de treinamento por parte da rede, o que diminuirá sua capacidade de generalização, além de um esforço computacional desnecessário.

4.2 Sistemas *Fuzzy*

A Teoria dos Conjuntos *Fuzzy*, desenvolvida por Zadeh (1984, 1973, 1968, 1965) durante a década de 60, executa o tratamento de informações incertas, imprecisas e vagas comumente encontradas nos problemas cotidianos, além de fornecer a base matemática que permite o manuseio destas incertezas por intermédio da linguística e cognição humanas.

Quando utilizada em um contexto lógico, como o de sistemas baseados em conhecimento, é conhecido como lógica "*Fuzzy*", lógica nebulosa ou lógica difusa (SANDRI e CORREA, 1999).

A Lógica *Fuzzy* (LF) é uma lógica multivalorada capaz de absorver informações vagas, normalmente descritas em uma linguagem natural (línguas faladas ou escritas) e convertê-las para um formato numérico, de fácil manipulação computacional (SANGALLI, 1998; KRUSE et al., 1994). Ela procura modelar os modos imprecisos do raciocínio humano simulando a habilidade humana de tomar decisões. Preocupa-se com os “princípios formais do raciocínio aproximado”, tratando adequadamente duas características intrínsecas da informação: A imprecisão e a incerteza. Assim, a representação não fica dependente apenas do conceito, mas também do contexto a qual que está sendo utilizada (ZADEH, 1973, 1968, 1965).

Vale apontar que a maior parte das informações com as quais se lida no mundo real está na forma de modelos complexos e que muitas vezes não retratam todas as variáveis envolvidas no processo ou não as levam em consideração no momento em que se faz necessário tomar uma decisão, exigindo por parte de quem toma decisões fazê-lo sob um leque de incertezas.

Torna-se necessário, portanto, um sistema de inferência que associe uma medida dessa ambiguidade, e que seja compreensível e apropriadamente interpretado pelo usuário. Nesse contexto, a Lógica *Fuzzy* (LF) que é baseada na habilidade que o ser humano tem em tratar informações inexatas, imprecisas, incertas, vagas, fornece aos profissionais das mais diferentes áreas uma ferramenta poderosa para resolver esse problema.

Entre a certeza de ser e a certeza de não ser (lógica binária), existem infinitos graus de incerteza (Lógica *Fuzzy*). Como tratar essa imperfeição intrínseca à informação representada numa linguagem natural, usando-se a tradicional teoria das Probabilidades ou teoria dos conjuntos *Fuzzy* (difusos ou nebulosos). Na lógica *Fuzzy*, o raciocínio exato - verdadeiro e falso (V, F) - corresponde a um caso limite do raciocínio aproximado, sendo interpretado como um processo de composição *Fuzzy* (COX, 1995; YEN et al., 1994; KAUFMANN e GUPTA, 1988).

O ser humano em seu mecanismo de raciocínio, impreciso, faz uso de expressões que de alguma forma adjetivam as variáveis envolvidas no problema e que não se identificam, diretamente, com a forma binária, esta tradicional nas linguagens de programação e usada largamente nos computadores digitais.

Assim, a Lógica *Fuzzy* é baseada em palavras, não em números, os valores verdadeiros são expressos linguisticamente e o uso de variáveis linguísticas (conjunto *Fuzzy* + qualificadores) nos aproxima do pensamento humano, simplificando a solução de problemas e, conseqüentemente, proporcionando a construção rápida do protótipo dos sistemas.

A partir do método de inferência, ou seja, utilizando-se do conhecimento dos especialistas para desenvolver um raciocínio dedutivo, modelam-se as incertezas dentro de um processo para tomada de decisão, fundamentado na existência de conexões entre causa e efeito, através de regras, naturais ou não, denominadas “regras de inferência” (PAIVA e DOURADO, 2004).

Para compor esse conjunto de regras, são realizadas diversas entrevistas com os especialistas do setor investigado visando transformar o conhecimento prático desses profissionais em regras de inferência.

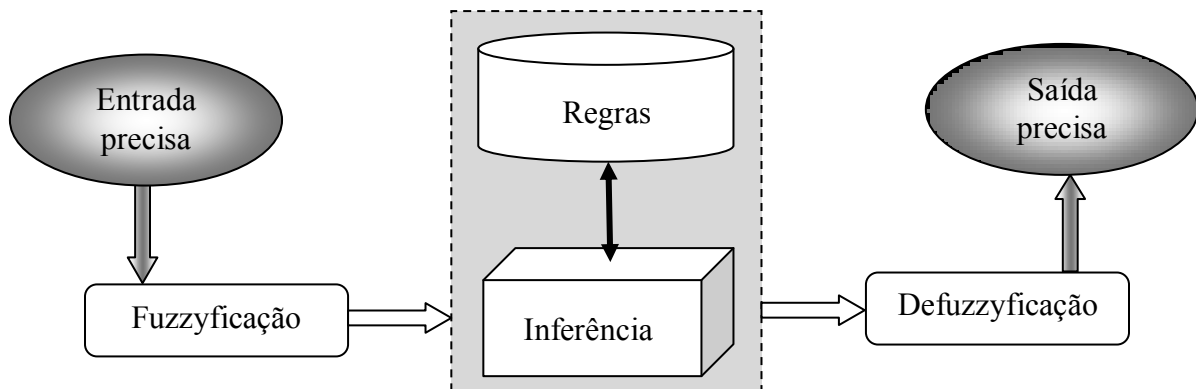


Figura 4.4: Diagrama em blocos de um Sistema *Fuzzy*

A inferência “*Fuzzy*” é o processo pelo qual se obtém as saídas do sistema. Assim um vetor de variáveis de entrada, aciona as regras (proposições *fuzzy*) e definem a situação (forma) da variável de saída correspondente, nessa fase ainda sob a forma “fuzzyficada”.

Procurando complementar os conceitos tratados nesta seção, são apresentadas no Anexo C algumas das principais características e funcionalidades dos sistemas *fuzzy*.

4.3 Sistemas Neuro-Fuzzy

O conceito de sistema híbrido inteligente ou de método híbrido de aquisição de conhecimentos é bastante amplo e pode englobar diferentes tipos de abordagens. De uma maneira mais geral, pode-se dizer que todo sistema que integre dois ou mais métodos diferentes para a solução de um problema é um sistema híbrido.

Neste contexto, um questionamento importante se faz presente: quais as principais motivações na utilização deste tipo de sistema?

Apesar dos sistemas híbridos serem mais complexos e difíceis de serem implementados, devido ao simples fato de serem compostos por múltiplos módulos e também por que é necessário fazer com que estes múltiplos módulos interajam, deve-se levar em consideração uma série de vantagens na utilização destes sistemas:

- a) A integração de duas técnicas complementares permite que uma complete as deficiências da outra, de forma a obter melhor desempenho.
- b) Ao utilizar diferentes técnicas de aquisição e de representação de conhecimentos, são ampliadas a capacidade do sistema em adquirir novas informações e também fazer com que este sistema não possua apenas uma visão parcial, limitada pelas imposições e restrições de um único método, na obtenção de uma solução para um determinado problema tratado.
- c) Algumas tarefas complexas que usualmente não poderiam ser abordadas através da utilização de uma única técnica para a sua solução, podem ser quebradas em subproblemas e estes possam ser tratados individualmente, chegando-se a uma solução global do problema.

Em relação aos sistemas híbridos inteligentes, pode-se considerar também que estes, em seu objetivo maior - que é a reprodução do comportamento inteligente humano, se caracterizam por:

- a) Os seres humanos não empregam um único método para a solução de problemas, visto que usam diferentes técnicas (como soluções baseadas em experiências passadas; em conhecimentos teóricos adquiridos; em diferentes métodos de raciocínio; etc.), os sistemas inteligentes procuram através da integração de diferentes métodos automáticos “imitar” a inteligência humana.

- b) Trocar informações e conhecimentos entre os seus módulos, o que usualmente, lhe confere uma característica de um sistema que evolui com o tempo, construindo o conhecimento através de interações entre o usuário e o sistema e entre os diferentes módulos do sistema.

Os sistemas *Neuro-Fuzzy* (SNF) fazem parte de uma classe de sistemas híbridos que utilizam uma ou mais técnicas inteligentes para a solução de um problema, incorporando dois paradigmas: Rede Neural Artificial (RNA) e Lógica *Fuzzy* (LF) (NAUCK e KRUSE, 1997; TERANO e SUGENO, 1991).

Quando essas técnicas são usadas separadamente, não obstante de suas conhecidas vantagens individuais certas desvantagens são evidentes.

No tocante às RNAs a informação é armazenada de forma distribuída e, portanto não há como interpretar suas funcionalidades. Além disso, o número de camadas e o número de neurônios por camada não é determinado por uma regra específica, tornando o processo, praticamente empírico.

Por outro lado os sistemas *Fuzzy* respondem rigorosamente apenas ao que consta no banco de regras não sendo capazes de generalizar como as RNAs. São altamente dependentes de um especialista para montar, de forma fidedigna, o banco de regras. Entretanto, escolher as funções de pertinência (*membership function* - *MF*) mais adequadas e determinar todas as regras que envolvem o problema em análise são tarefas árduas e nem sempre remete diretamente a bons resultados.

Assim os SNFs procuram usar o máximo das propriedades das RNAs (aprendizado) e da LF (interpretação linguística), minimizando suas limitações e deficiências (ALTROCK, 1996). Dentre outras características de menor monta sustentam-se a característica de aprendizado por exemplos das RNAs e a interpretação da funcionalidade característica da LF.

No apêndice A é apresentada uma relação das principais arquiteturas envolvendo SNF, das quais o modelo ANFIS (*Adaptive Network-based Fuzzy Inference System*) (JANG et al., 1997; JANG, 1993) foi o modelo escolhido para o desenvolvimento desta tese, devido a sua estabilidade e robustez dentre as arquiteturas estudadas.

A Figura 4.5 apresenta uma rede *Neuro-Fuzzy*, com duas entradas (x e y) e uma saída (Z), usando o modelo Sugeno de 1ª. ordem, isto é com $z = f(x, y)$ representado por polinômio de 1ª ordem e com duas regras R_1 e R_2 . A função de pertinência $\mu A(x)$ usada, como exemplo é o sino-beta, Eq. (4.19) e a saída de cada neurônio i da camada j é dado por $Out_{j,i}$.

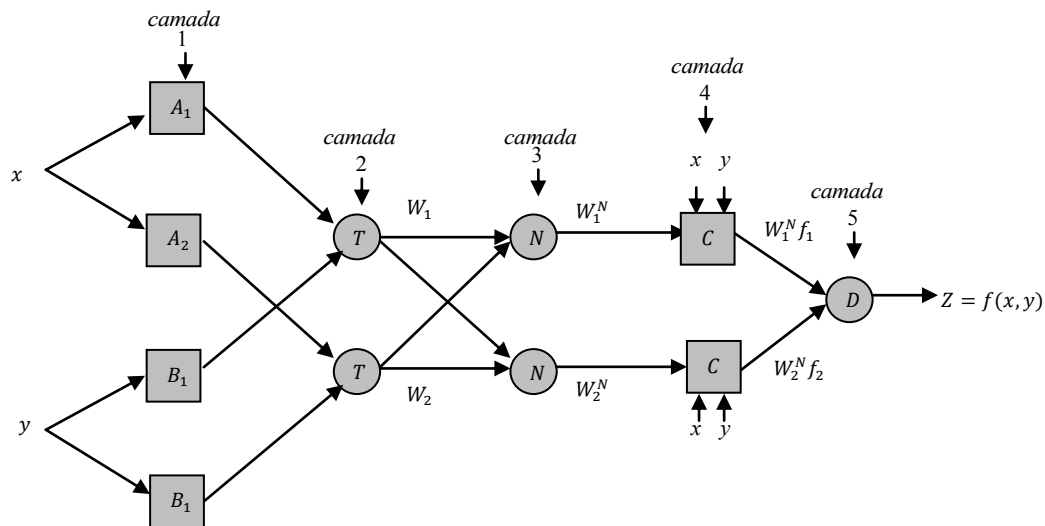


Figura 4.5: Rede Neuro-fuzzy.

As regras são:

$$R_1: \text{Se } x \text{ é } A_1 \text{ e } y \text{ é } B_1 \text{ então } f_1 = p_1 x + q_1 y + r_1 \quad (4.11)$$

$$R_2: \text{Se } x \text{ é } A_2 \text{ e } y \text{ é } B_2 \text{ então } f_2 = p_2 x + q_2 y + r_2 \quad (4.12)$$

Camada 1 – Responsável pelo mapeamento da entrada nos conjuntos *fuzzy* gerando os antecedentes das regras, i.e., computa o grau de pertinência das entradas precisas x e y satisfazendo os termos linguísticos A_i e B_i associados a estes nós. É um nó adaptativo e a saída obedece às Eqs. (4.13) e (4.14).

$$Out_{1,i} = \mu_{A_i}(x), \dots i = 1,2 \quad (4.13)$$

$$Out_{1,i} = \mu_{B_{i-2}}(y), \dots i = 3,4 \quad (4.14)$$

Camada 2 – Cada nó corresponde a uma regra e computa o nível ou força de disparo W_i da regra, indicando o grau de pertinência com que o consequente da regra será atendido. Normalmente esse processo pode ser realizado usando-se uma função AND de acordo com a norma-T. É um nó fixo e a saída obedece a Eq. (4.15).

$$Out_{2,i} = W_i = \mu_{A_i}(x)\mu_{B_i}(y), \dots i = 1,2 \quad (4.15)$$

Camada 3 – Realiza a normalização usada como pré-processamento para defuzzificação. Calcula a relação entre o i -ésimo nível de disparo da regra em relação à soma total dos níveis de disparo. É um nó fixo, a saída é denominada de nível de disparo normalizado e obedece a Eq. (4.16).

$$Out_{3,i} = W_i^N = W_i/(W_1 + W_2) \quad (4.16)$$

Camada 4 – Os consequentes são gerados conforme o modelo linear tipo Takagi-Sugeno, apresentado em Takagi e Sugeno (1985). Desta forma, as saídas são calculadas pelo produto entre os níveis de disparo normalizados W_i^N definidos na camada 3 e o valor do consequente da regra f_i cujos parâmetros são p_i, q_i e r_i correspondem ao consequentes Sugeno. É um nó adaptativo e a saída obedece à Eq. (4.17).

$$Out_{4,i} = W_i^N f_i = W_i^N (p_i x + q_i y + r_i) \quad (4.17)$$

Camada 5 – É um nó fixo que computa através de um somatório todos os consequentes das regras, indicando a saída total da rede. Essa camada é conhecida como camada defuzzyficadora e a saída é representada pela Eq. (4.18).

$$Out_{5,i} = \sum_i W_i^N f_i = \frac{\sum_i W_i f_i}{\sum_i W_i} \quad (4.18)$$

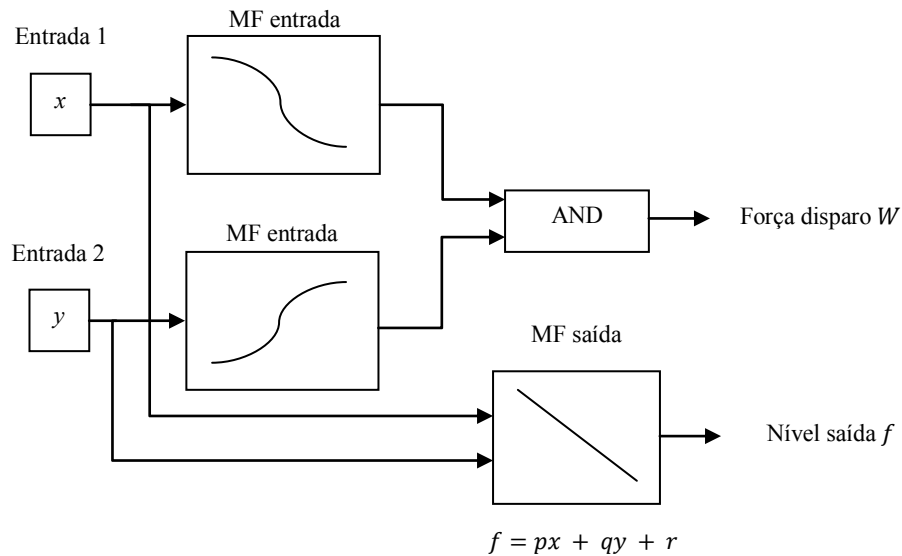


Figura 4.6: Diagrama em blocos para a operação de uma regra Sugeno

É possível identificar os parâmetros do SNF usando-se apenas uma técnica de otimização como, por exemplo, o método do gradiente descendente.

Com o objetivo de aumentar o desempenho do sistema, pode-se usar um aprendizado híbrido, combinando o método dos mínimos quadrados com o método do gradiente descendente. Para tal é necessário realizar duas fases: uma direta e uma reversa (JANG et al., 1997).

Durante a fase de treinamento os SNFs computam os parâmetros das funções de pertinência *fuzzy* iterativamente, calculando o erro médio quadrático entre a resposta obtida pelo sistema e a resposta esperada. Com base neste erro, o sistema realiza um ajuste com a modificação dos parâmetros das funções de pertinência *fuzzy* relacionadas com os antecedentes e os consequentes obtendo assim uma nova resposta para o sistema. Esse procedimento é executado com os dados do treinamento até que não se tenha mais diminuição significativa do erro relativo à saída esperada.

Na fase direta, o sinal de entrada vai se propagando camada por camada até atingir a camada 4 onde os parâmetros dos consequentes da regra são identificados pelo método dos mínimos quadrados.

Na fase reversa o sinal de erro é retropropagado e os parâmetros dos antecedentes são atualizados pelo método do gradiente descendente.

Outros parâmetros que são utilizados na fase de treinamento:

- a) o tamanho do passo, que associado à taxa de aprendizado η , poderá influenciar na velocidade de convergência do método. Se o valor do passo for pequeno, provavelmente a convergência será lenta, pois o gradiente deverá ser calculado muitas vezes. Por outro lado, se o valor do passo for grande, a convergência será inicialmente muito rápida, mas o algoritmo irá oscilar entre os valores ótimos. Com base nestas observações, a atualização do passo seguirá as seguintes regras heurísticas:
 - Se a medida de erro sofrer quatro reduções consecutivas, o valor do passo será aumentado, por um valor definido durante a construção da arquitetura do sistema, como por exemplo em 10%.
 - Se a medida do erro sofrer duas reduções consecutivas, um aumento e uma redução, o valor do passo será reduzido, da mesma forma que utilizado para o incremento do passo, em 10%.
- b) a validação cruzada, da mesma forma que é utilizada durante o treinamento das RNAs, utiliza o controle sobre os dados para evitar tanto o excesso do treinamento (memorização) como também o subtreinamento (falta de aprendizado). Assim, procura-se atingir um dos principais objetivos, o da generalização das redes que será percebido na fase de execução, i.e. a utilização dos SNFs com os valores das funções de pertinência já ajustadas pelo processo de treinamento.

Em um sistema de inferência *fuzzy* convencional, o número de regras é decidido por um especialista que esteja familiarizado com o sistema a ser modelado. Em um SNF no entanto, nenhum especialista está disponível e o número de funções de pertinência atribuído a cada variável de entrada é escolhido empiricamente, ou seja, examinando os dados entrada-saída desejados ou por tentativa e erro. Esta situação é idêntica ao das redes neurais artificiais, pois, não há uma maneira simples de se determinar antecipadamente o número mínimo de camadas ocultas necessárias para atingir um nível de desempenho desejado (GIL, 2005).

Resumidamente, na fase direta fixam-se os antecedentes e identificam-se os consequentes pelo método dos mínimos quadrados e na fase reversa fixam-se os consequentes atualizando os parâmetros dos antecedentes pelo método do gradiente. A fase de treinamento dos SNF é representada no diagrama da Fig. 4.7

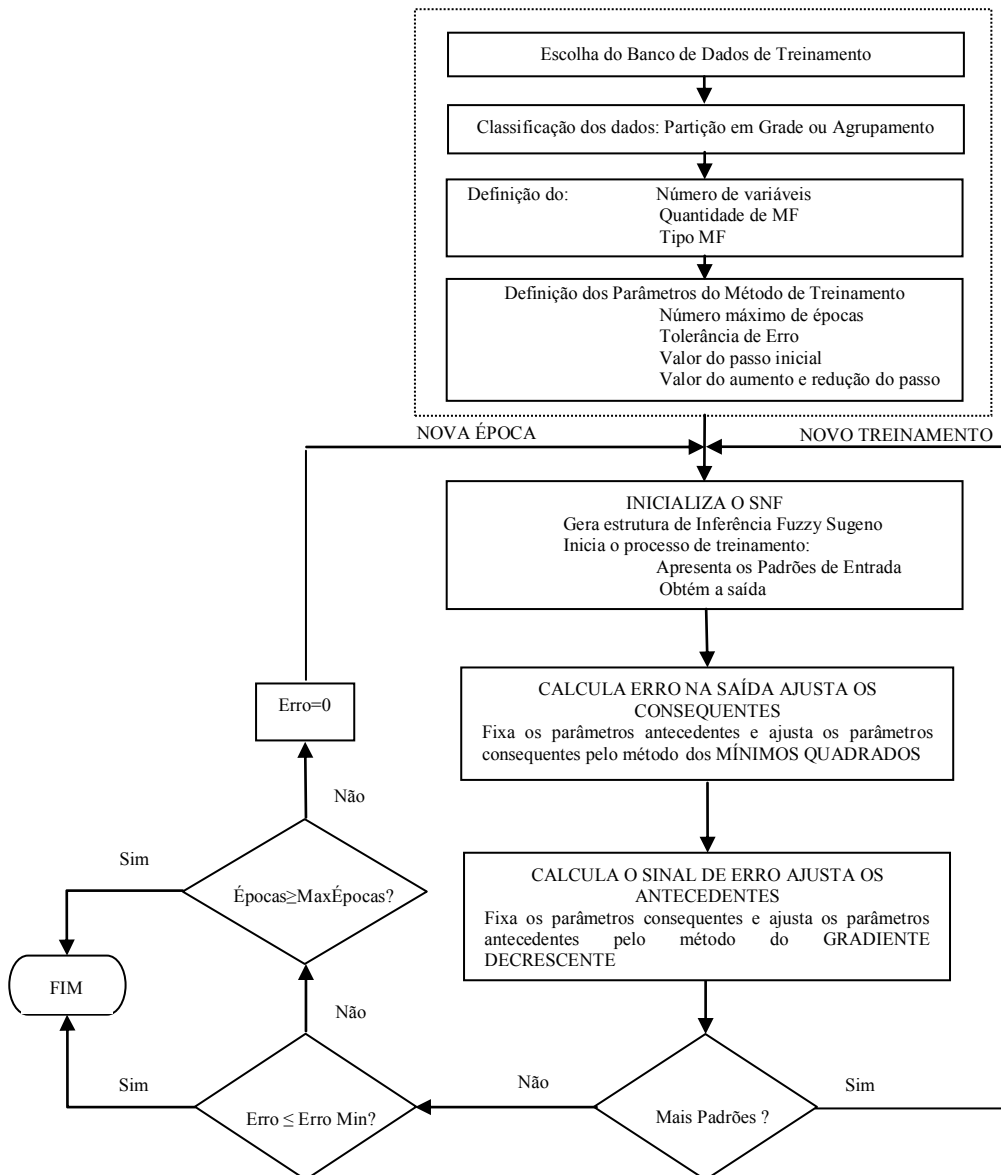


Figura 4.7: Diagrama em blocos do algoritmo de treinamento da Rede Neuro-fuzzy

Depois de se fixar o número de *MF* associados a cada uma das entradas, os valores iniciais dos parâmetros antecedentes são definidos de modo a que as funções *MF* serão distribuídas igualmente ao longo do domínio de cada variável de entrada. A Fig. 4.13 mostra

uma configuração inicial típica das *MFs*, para um SNF com quatro funções de pertinência e universo do discurso de 0 a 0,6.

A função de pertinência tipo sino-beta definida pela Eq. 4.19 será utilizada nesta seção como exemplo, esta *MF* contém três parâmetros de ajuste p , q e r , e para cada um desses parâmetros há um significado físico: r determina o centro da função correspondente, p é a metade da largura; e q (juntamente com p) controla a sua inclinação.

$$\mu_A(x) = \frac{1}{1 + \left(\frac{x-r}{p}\right)^{2q}} \quad (4.19)$$




Figura 4.8: Função de pertinência sino-beta

Para a classificação dos dados de entrada são utilizadas duas abordagens distintas: o particionamento em grade (*grid partitioning*) e a clusterização (*subtractive clustering*).

A abordagem da partição em grade (sem clusterização) possui a vantagem de que todas as regras fuzzy podem ser formuladas com um número relativamente pequeno de termos linguísticos. Esses termos são reutilizados em regras diferentes. Se cada variável de entrada é caracterizado por Q_μ *MFs* e se a entrada é n -dimensional (N_e), então há Q_R regras possíveis fuzzy Eq. (4.20), mas apenas $Q_\mu \times N_e$ diferentes termos linguísticos necessários para gerá-los.

$$Q_R = (Q_\mu)^{N_e} \quad (4.20)$$

Há no entanto, uma séria desvantagem da abordagem da partição em grade devido ao crescimento exponencial da quantidade de regras (problema da dimensionalidade), esta condição impõe uma limitação na capacidade de processamento em um sistema que seja capaz de lidar bem com um determinado conjunto de dados.

A Figura 4.9 mostra a divisão do espaço de entrada com a utilização do particionamento em grade com três funções de pertinência associadas a cada entrada de modo que o espaço de entrada é dividido em nove subespaços *fuzzy*, cada uma das quais é regido por uma regra *fuzzy*.

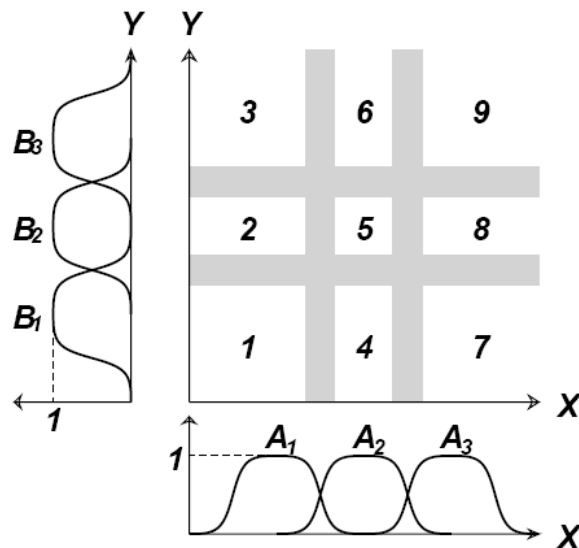


Figura 4.9: Particionamento em grade com três funções de pertinência associadas a duas entradas com nove regras fuzzy.

O Agrupamento ou clusterização de dados numéricos é a base de muitos modelos e algoritmos de classificação de padrões. O objetivo do agrupamento é encontrar agrupamentos naturais de dados em um grande conjunto de dados, revelando padrões nos dados que pode fornecer uma representação concisa do comportamento dos dados.

O *Subtractive Clustering* (agregação ou clusterização) calcula os centros do cluster em um conjunto de dados usando o método que assume cada ponto como um centro potencial do cluster e calcula a probabilidade para cada ponto ser o centro do cluster, com base na densidade em torno de pontos de dados. O algoritmo:

- Seleciona o ponto de dados com o maior potencial para ser o primeiro centro de cluster;
- Remove todos os pontos de dados nos arredores do centro do primeiro cluster (determinado pelo raio), a fim de determinar o próximo conjunto de dados e a localização do seu centro.

O processo é iterado até que todos os dados estejam dentro do raio de um cluster.

O algoritmo *Fuzzy CMeans* (BEZDEC, 1981) e os Mapas Auto-Organizáveis de Kohonen (KOHONEN, 1997 e 1989) são exemplos bem conhecidos como algoritmos de clusterização. Para estes algoritmos, a qualidade da solução, como a maioria dos problemas de otimização não-lineares, depende fortemente da escolha dos valores iniciais, i.e., o número de centros de cluster e suas posições iniciais.

Na Fig. 4.10 é apresentada uma representação esquemática de um SNF, com quatro entradas associadas a três funções de pertinência, com as respectivas 64 regras *fuzzy* e a sua saída, utilizando o particionamento em grade.




Figura 4.10: Arquitetura de um SNF com quatro entradas, três funções de pertinência e particionamento em grade.

Nas Figs. 4.11 e 4.12 estão representadas graficamente e em forma de texto, respectivamente, algumas das regras *fuzzy* do exemplo apresentado na Fig. 4.10.




Figura 4.11: Regras no formato texto de um SNF com quatro entradas, três funções de pertinência e particionamento em grade.

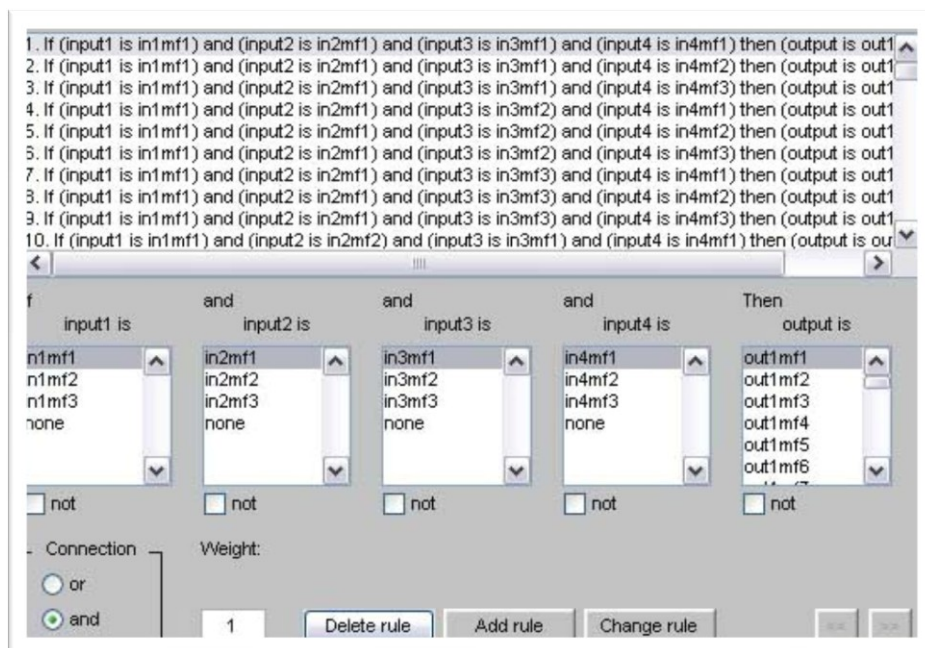


Figura 4.12: Regras no formato texto de um SNF com quatro entradas, três funções de pertinência e particionamento em grade.

Na Fig. 4.13 estão representadas graficamente as três funções de pertinência definidas para o exemplo apresentado na Fig. 4.10. Durante a fase de treinamento deste SNF os parâmetros destas *MFs* (Eq. 4.19) são alterados e o resultado deste ajuste realizado nas *MFs* pode ser visualizado na Fig. 4.14.

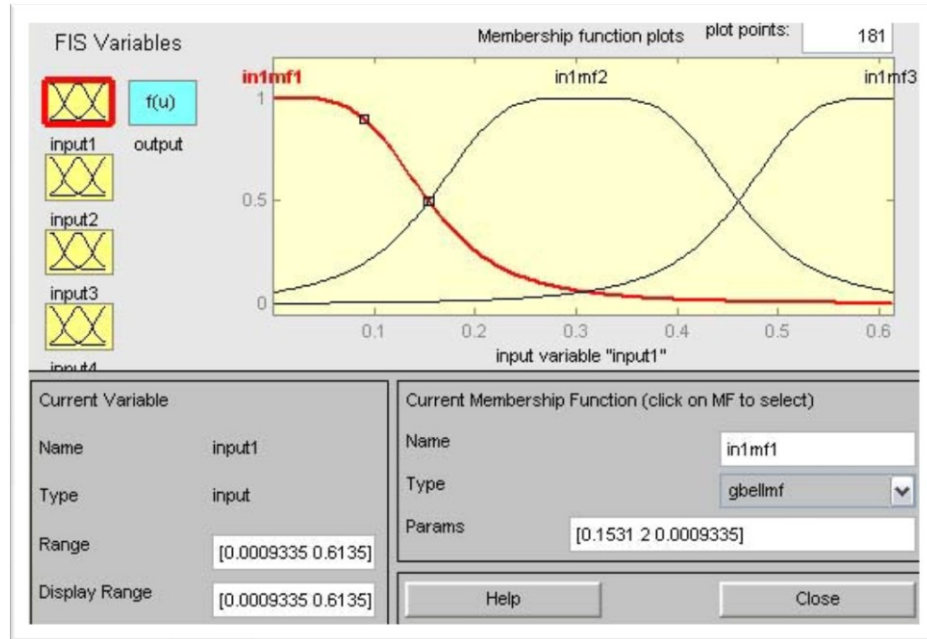


Figura 4.13: Funções de pertinência de um SNF com quatro entradas, três funções de pertinência e particionamento em grade na fase inicial de treinamento.

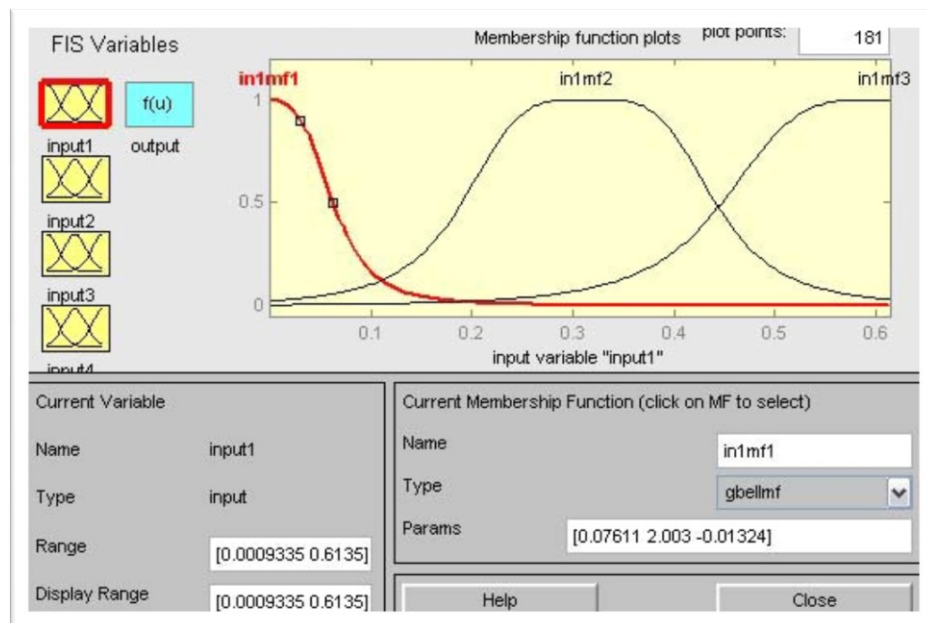


Figura 4.14: Funções de pertinência de um SNF com quatro entradas, três funções de pertinência e particionamento em grade com a fase de treinamento concluída.

Na Fig. 4.15 é apresentada uma representação esquemática de um SNF, com quatro entradas associadas a seis funções de pertinência, com as respectivas seis regras *fuzzy* e a sua saída, utilizando o método da clusterização.

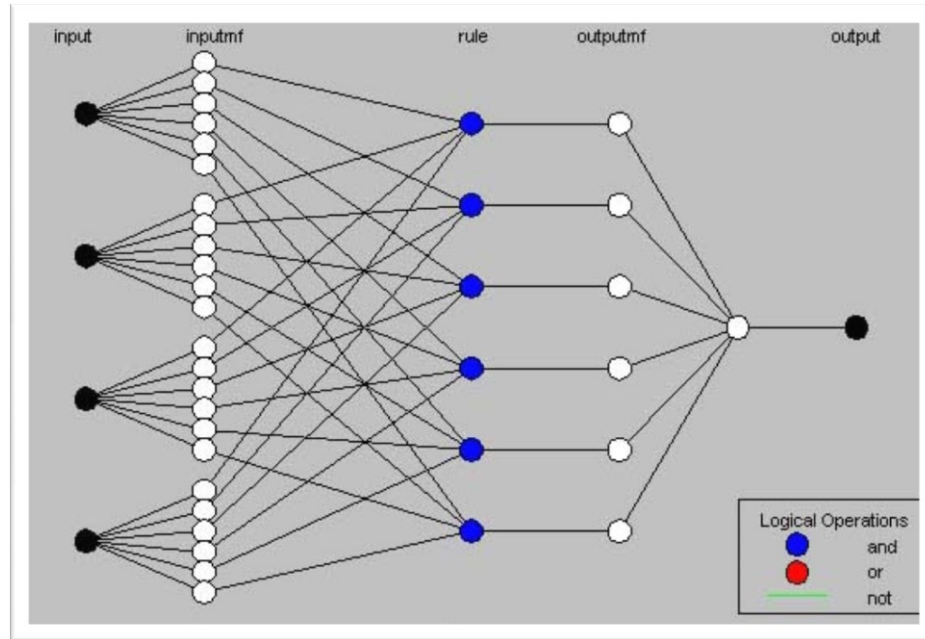


Figura 4.15: Arquitetura de um SNF com quatro entradas, seis funções de pertinência e clusterização.

Nas Figs. 4.16 e 4.17 estão representadas graficamente e em forma de texto, respectivamente, todas as regras *fuzzy* do exemplo apresentado na Fig. 4.15.

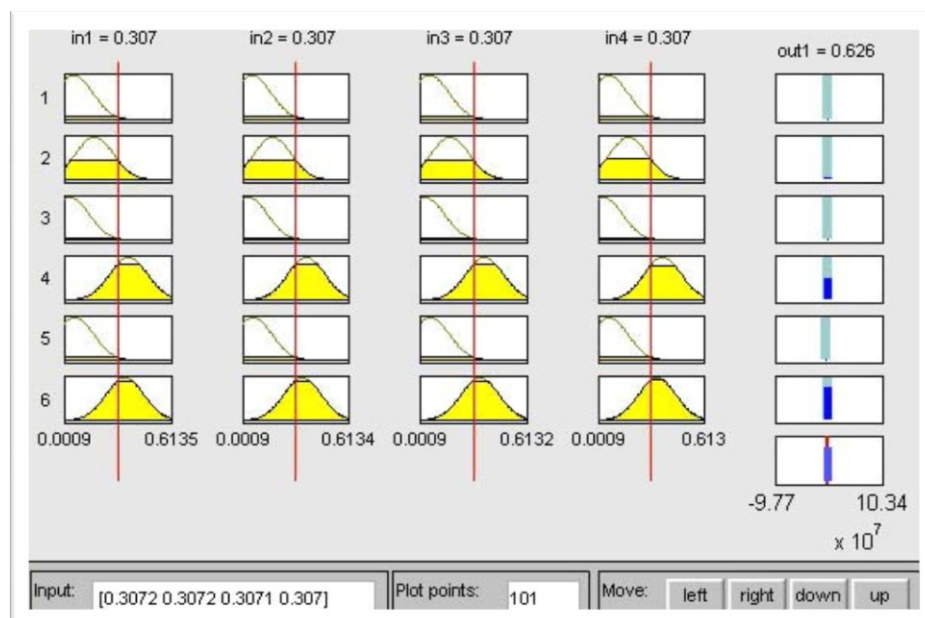


Figura 4.16: Regras no formato texto de um SNF com quatro entradas, seis funções de pertinência e clusterização.

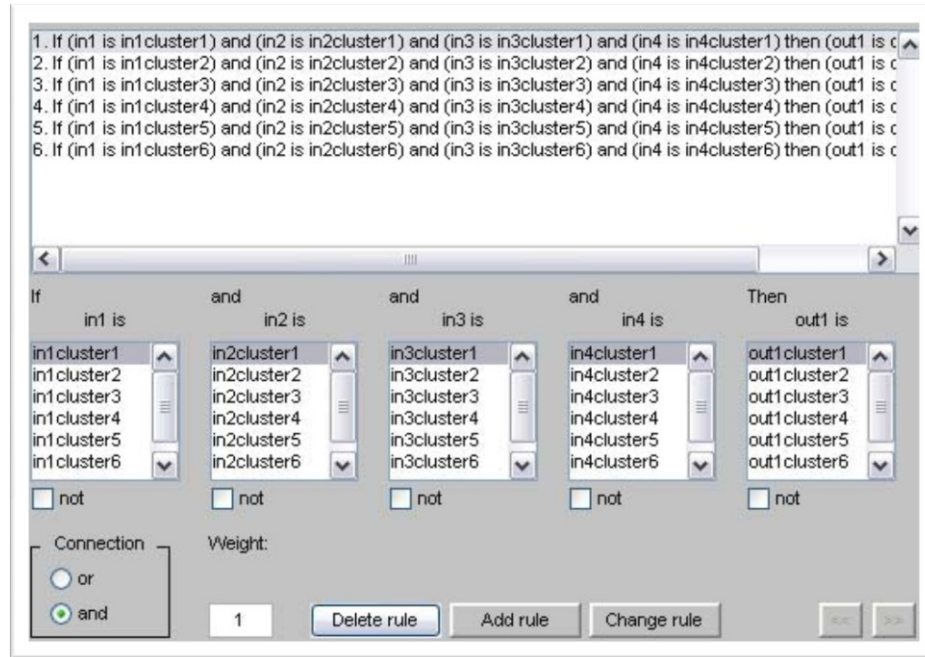


Figura 4.17: Regras no formato texto de um SNF com quatro entradas, seis funções de pertinência e clusterização.

Na Fig. 4.18 estão representadas graficamente as seis funções de pertinência definidas para o exemplo apresentado na Fig. 4.15. Durante a fase de treinamento deste SNF os parâmetros destas *MFs* são alterados e o resultado deste ajuste realizado nas *MFs* pode ser visualizado na Fig. 4.19.

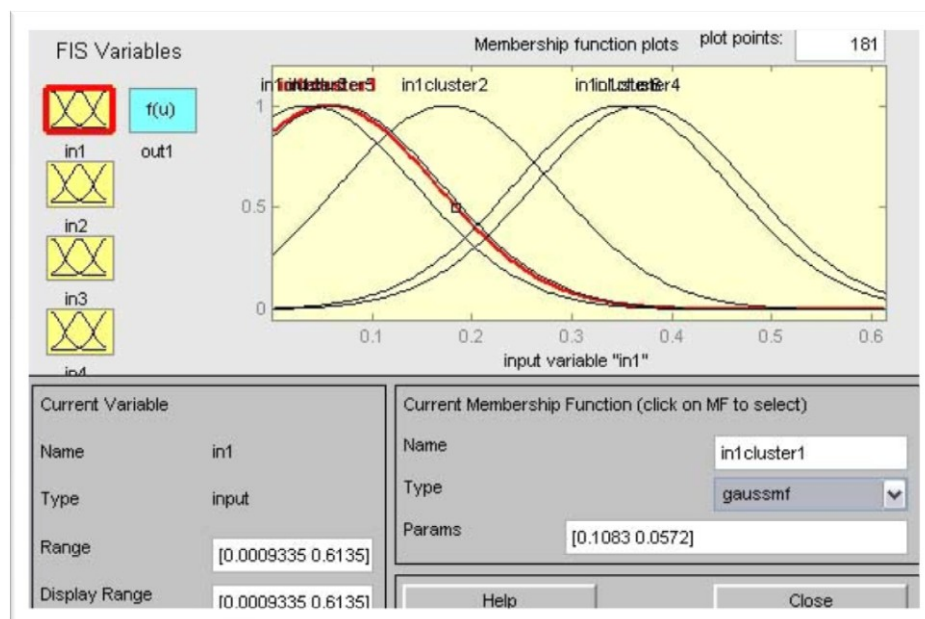


Figura 4.18: Funções de pertinência de um SNF com quatro entradas, seis funções de pertinência e clusterização na fase inicial de treinamento.

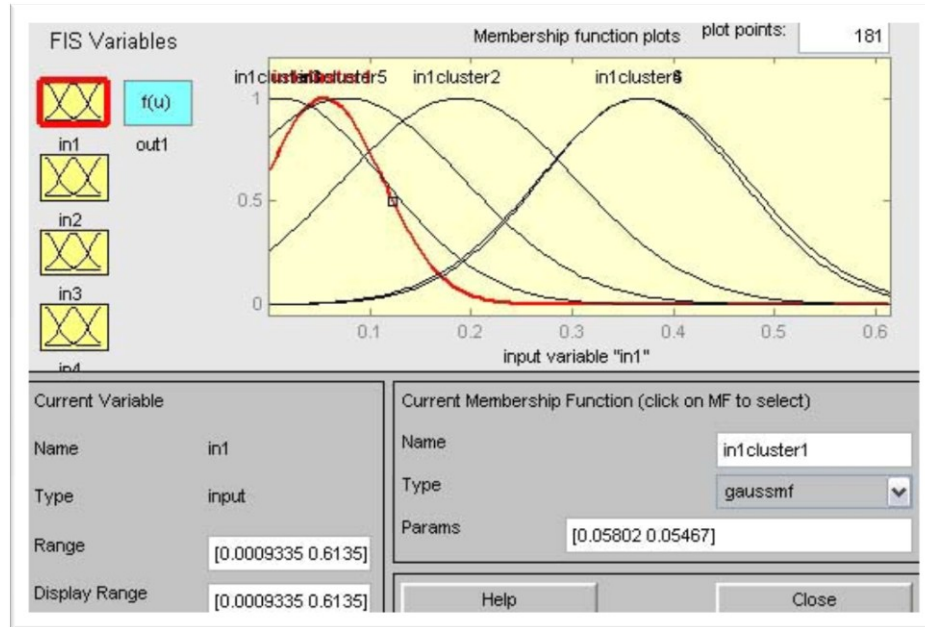


Figura 4.19: Funções de pertinência de um SNF com quatro entradas, seis funções de pertinência e clusterização com a fase de treinamento concluída.

4.4 Máquinas de Comitê de Redes Neuro-Fuzzy

As máquinas de comitê são técnicas usadas para resolver problemas encontrados no treinamento supervisionado, especialmente no tocante a generalização. Baseiam-se na idéia de dividir problemas computacionais complexos em diversos problemas mais simples computacionalmente. Combinando-se os resultados desses problemas simples, chega-se ao resultado final (SILVA, 2005; HAYKIN, 2001; DUDA et al., 2001; SCHAPIRE, 1999).

Uma prática comumente utilizada em máquinas de comitês com RNAs é fazer o treinamento de um número elevado de “redes candidatas”, configuradas com parâmetros distintos selecionando-se as melhores redes com base nos resultados do desempenho sobre um conjunto independente dados para a validação e o teste, descartando-se o restante.

Nesta tese é proposta a formação de um comitê com redes *neuro-fuzzy*. Tal opção justifica-se pelo fato do resultado combinado de um comitê, frequentemente, apresentar melhor resultado do que através de uma rede isoladamente.

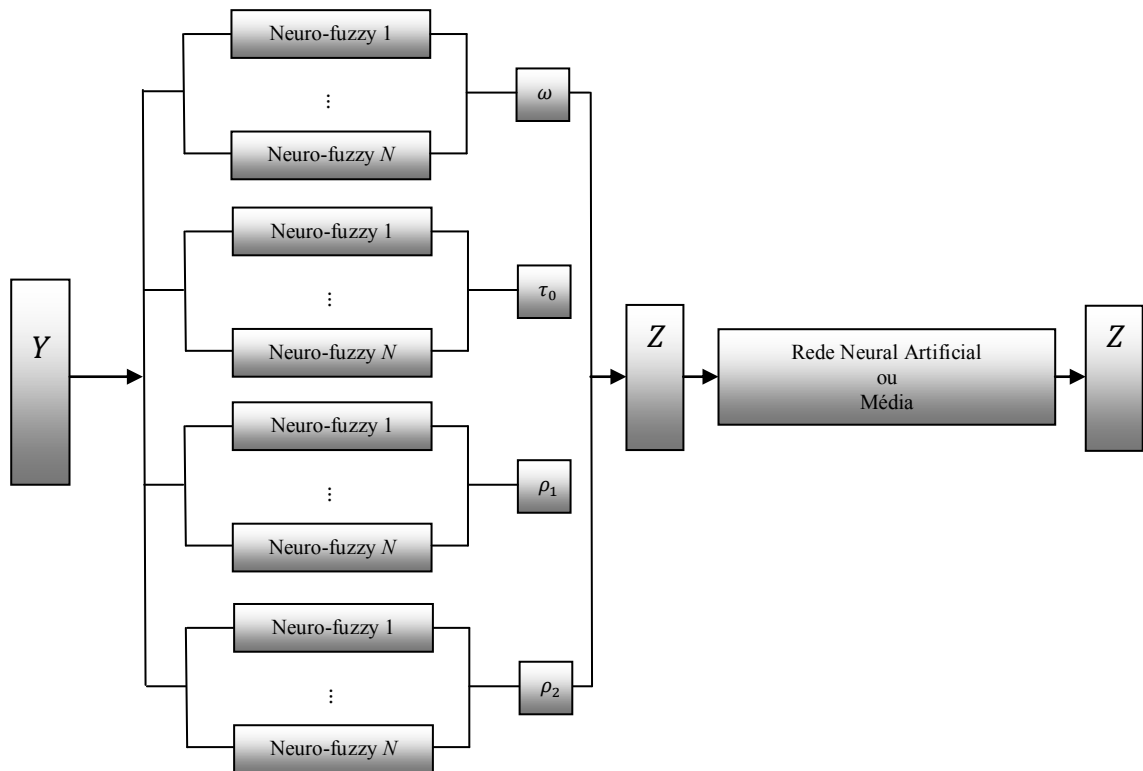


Figura 4.20: Representação esquemática do comitê neuro-fuzzy para o problema inverso de transferência radiativa.

Ainda em relação à opção, vale ressaltar que o comitê de SNFs pode ser basicamente, classificado em duas grandes categorias: estruturas estáticas e estruturas dinâmicas. Serão utilizadas máquinas de comitê com a estrutura estática, onde as saídas das redes especialistas são combinadas sem a participação do sinal de entrada. Essa classe usa principalmente dois métodos de tratamento do sinal de saída dos SNFs especialistas, a saber: a média do conjunto e a aproximação pelas redes neurais artificiais.

Tanto no método da média como no através das RNAs (Fig. 4.20) as entradas Y dos SNFs especialistas são rigorosamente as mesmas e a saída global Z é dada pela combinação linear das saídas das SNFs especialistas. São permitidas variações nas condições iniciais usadas no treinamento e modificações nos parâmetros e algoritmos de minimização do erro.

4.5 Formulação e solução do problema inverso com sistemas neuro-fuzzy e com comitês de redes neuro-fuzzy

Para a solução do problema inverso com a determinação das propriedades radiativas em um meio participante unidimensional homogêneo, utilizando as medidas de intensidade de radiação que deixam o meio participante. A modelagem do problema (direto e inverso) e a formulação matemática encontram-se detalhadas nos capítulos 2 e 3, conforme a representação resumida no diagrama da Fig. 4.21.

Assim, de forma resumida, o problema direto (PD) consiste em, sendo conhecidas a geometria do meio, as propriedades radiativas e as condições limites, determinar a intensidade da radiação que deixa o meio $I(\tau, \mu)$, onde τ representa a variável ótica espacial (limites $\tau = 0$ e $\tau = \tau_0$) e $\mu = \cos \theta$, sendo θ o ângulo polar entre a direção do feixe de radiação e o eixo τ . Nesse caso, ρ_1 e ρ_2 representam as reflectividades nos limites $\tau = 0$ e $\tau = \tau_0$, respectivamente, ω o albedo de espalhamento e τ_0 a espessura ótica do meio.




Figura 4.21: Diagrama esquemático – Problema Direto e o Problema Inverso

Supondo-se que as propriedades radiativas do meio sejam desconhecidas, temos uma restrição severa para aplicação do PD, mas que existam dados experimentais disponíveis de intensidades de radiação que deixam o meio participante nos limites $\tau = 0$ e $\tau = \tau_0$, e que o número de dados experimentais seja igual ao número de direções N_e usadas na discretização do domínio do ângulo polar θ , empregando o método descrito no capítulo 2 através de ordenadas discretas com quadratura Gauss-Legendre e com uma aproximação por diferenças finitas para a discretização do domínio espacial, de modo que as intensidades sejam medidas para cada correspondente valor de $\mu = \cos \theta$.

Supondo ainda que esses dados experimentais possam ser gerados por simulações - e dessa forma criados tantos pares quantos forem necessários para a sua utilização em qualquer

técnica de determinação desses parâmetros-, com o formato adequado à sua aplicação, será tornado possível de forma inversa a determinação dessas propriedades radiativas.

A Fig. 4.22 representa um conjunto de dados sintéticos, gerados pelo simulador neste caso com seis intensidades de radiação, agora denominadas de Y_i e mapeando as propriedades radiativas Z . Por questões de espaço, estão mostrados na mesma figura, apenas cinco amostras contendo cada uma seis intensidades e mapeando suas respectivas propriedades radiativas.

2.415677461844775E-001	2.431182104431427E-001	2.433743565778772E-001
5.484551846746441E-001	5.481127223646433E-001	5.460398010911347E-001
2.308311839569457E-001	5.154132201630510E-001	6.353711933095111E-001
2.659345275427217E-002	3.272641177685388E-002	5.135012730974829E-002
1.824781989043219E-003	4.814576744929781E-003	6.186802814468506E-003
1.681615569957070E-001	1.619413118903284E-001	1.636977957652270E-001
7.040119293839027E-002	3.334026423444075E-001	4.535566641837303E-001
1.007564645877577E-002	1.218765984781473E-002	1.936936170530243E-002
1.470966823511116E-001	3.530323658409311E-001	4.147709679590376E-001
9.762919900916392E-002	9.432888713861390E-002	8.674115719224580E-002

(a)

5.304934668962348E-001	3.698125017666316E-003	1.543871719177753E-001
7.851984220487990E-001		
8.298793741641004E-001	7.826415760361783E-001	8.569684400488475E-001
6.857190098081338E-002		
4.879397845305222E-001	8.039586044866399E-001	1.322656069566801E-001
9.880561209228151E-001		
2.592243497535700E-001	7.836463082505606E-001	7.435027671714792E-001
5.100785105070465E-002		
2.889526091930236E-001	4.265027071472736E-001	2.309990242267954E-001
4.006001797507518E-001		

(b)

Figura 4.22: Dados experimentais simulados (GAGLIARDI, 2010) (a) intensidades de radiação que deixam o meio - Y_i (b) variáveis radiativas - Z

A partir deste contexto serão apresentados e discutidos no capítulo 5 os resultados na determinação dessas propriedades radiativas através de redes neurais artificiais, redes *neuro-fuzzy* e máquinas de comitê *neuro-fuzzy*.

5 ESTUDO DE CASOS

Os sistemas *Neuro-Fuzzy* (SNF) e as máquinas de comitê *Neuro-Fuzzy* introduzidos no capítulo 4, foram avaliados em seis casos distintos conforme o resumo através da Tabela 5.1.

Na descrição desses seis casos, serão comparados os resultados das soluções dos respectivos problemas com a utilização de métodos de inteligência computacional e métodos híbridos desenvolvidos por pesquisadores da área de problemas inversos com os sistemas *Neuro-Fuzzy* e as máquinas de comitês propostas nesta tese. Assim, poderá ser possível validar e avaliar a eficácia dos SNFs e das máquinas de comitês *Neuro-Fuzzy* para a solução de problemas inversos em transferência radiativa.

Tabela 5.1: Casos Testes realizados com os modelos neuro-fuzzy e comitê neuro-fuzzy

Caso #	Tipo Aplicação	Método Comparativo	Seção	AT	# Padrões	# Entradas	# Regras	Combinador Comitê	AT	# Saídas
1	AF	-	5.2.1	HB	1089	2	25	-	-	1
2	PR	RNA	5.2.2	HB	100	2 4 6	36 81 64	-	-	1
3	PR	Híbrido (RNA e LM); Minimização Tikhonov	5.4	BP, HB	100	6	729	Média e RNA	LM, GD, GDX, RP	4
4	PR	PCA	5.5	BP, HB	100	6	729	Média e RNA	LM, GD, GDX, RP	4
5	PR	PCA	5.6	BP, HB	100	6	729	Média e RNA	LM, GD, GDX, RP	4
6	PR	Híbrido (PCA e LM)	5.7	BP, HB	100	6	729	Média e RNA	LM, GD, GDX, RP	4

Tipo de aplicação:

AP – Aproximação de Funções

PR – Previsão

AT (Algoritmo de Treinamento):

BP – Retropropagação do erro (Backpropagation)

LM – Levenberg-Marquardt

GDX – Taxa de aprendizado Adaptativa

RP (Rprop) – Resilient Backpropagation

Métodos Comparativos:

RNA – Redes Neurais Artificiais

PCA - Algoritmo de Colisão de Partículas

5.1 Validação das Redes Neuro-Fuzzy: Caso Teste 1

Com o objetivo de validar os conceitos do SNF é apresentado a seguir através de um exemplo didático como uma rede *Neuro-Fuzzy* pode aprender a função $f(x, y)$ da Eq. (5.1), difícil de ser aproximada usando-se apenas uma única RNA tradicional e apresentada na Fig. 5.1.

$$f(x, y) = \frac{\text{sen}(x)\text{sen}^2(y)}{xy} \quad (5.1)$$

Para tal foi usado um banco de dados com 1089 pares distribuídos para x e y com os dados de treinamento no intervalo $[-10, 10]$. Foram utilizadas duas variáveis cada uma delas com cinco funções de pertinência (*MF*). O modelo de Inferência *Fuzzy* é o Sugeno. O número de regras atingiu um total de 25. O número de parâmetros não lineares (antecedentes) é igual a 30 e o número de parâmetros lineares relativos aos consequentes é 75.




Figura 5.1: Função $f(x,y)$ a ser treinada pela rede Neuro-Fuzzy

A Fig. 5.2 representa as variáveis linguísticas x e y , do tipo sino-beta curvas (a,b) no instante inicial, e curvas (c,d) final do treinamento.

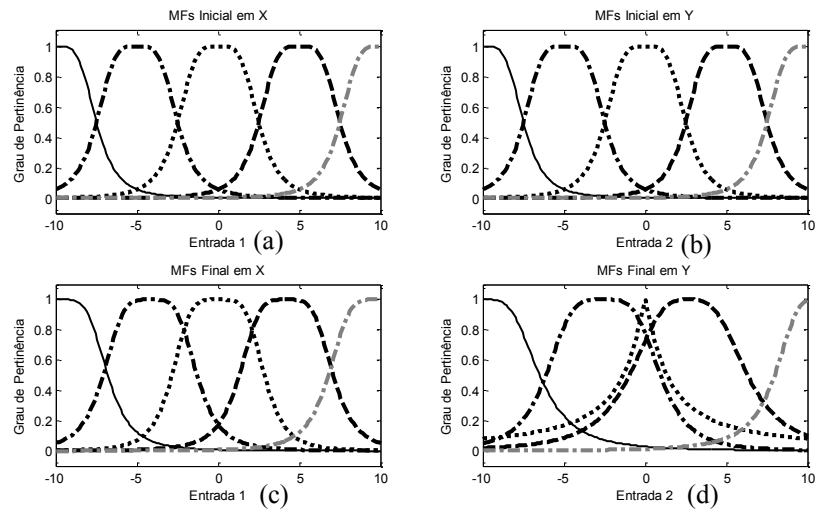


Figura 5.2: Variáveis linguísticas x e y , inicial e final do treinamento

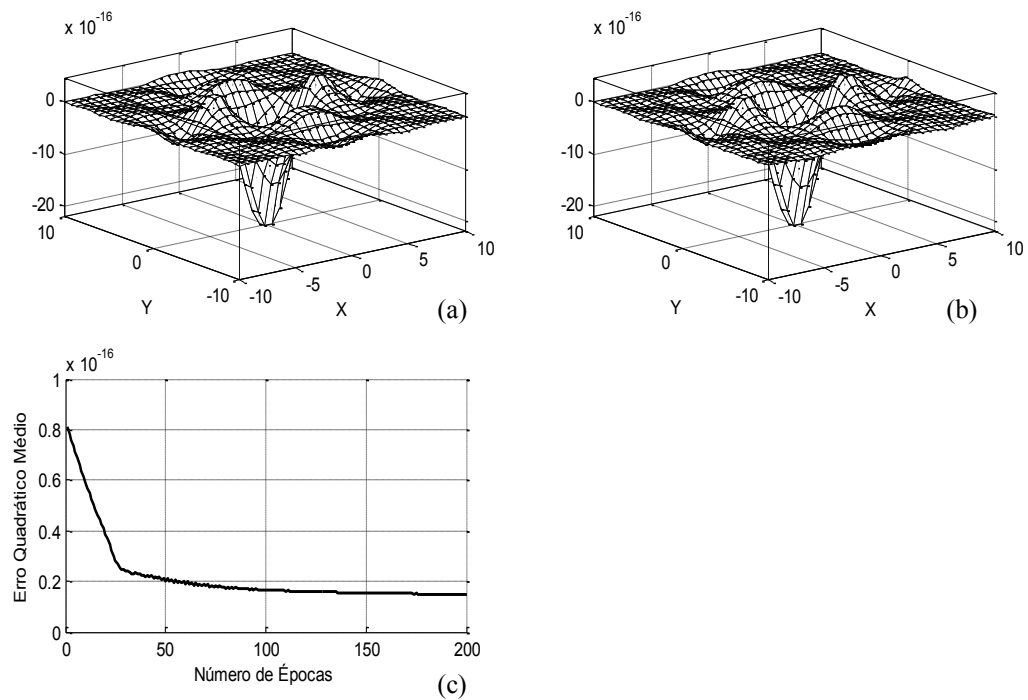


Figura 5.3: (a) Função de treinamento, (b) saída do *SNF* e (c) curva de erro.

A Fig. 5.3 apresenta a curva com os dados de treinamento (a), a saída do sistema *Neuro-Fuzzy* (b) e a curva de erro (c) gerada durante o processo de identificação dos parâmetros. Como se pode notar as curvas são praticamente idênticas, o que demonstra que o sistema *Neuro-Fuzzy* é uma aplicação que pode ser utilizada para a aproximação de funções.

5.2 Validação das Redes Neuro-Fuzzy: Caso Teste 2

Ainda procurando avaliar e validar a utilização dos SNFs em sistemas não lineares serão comparados neste caso teste os resultados obtidos pelos sistemas *Neuro-Fuzzy* para um caso particular de problemas inversos em transferência radiativa com os resultados de uma rede neural artificial, conforme modelagem descrita no capítulo 3.

Este caso em particular trata de um meio participante com uma espessura ótica $\tau_0 = 4,0$, que é considerado um valor elevado para esta variável, o albedo de espalhamento $\omega = 0,7$, que indica um meio com espalhamento relativamente alto e as reflectividades difusas $\rho_1 = 0,2$ e $\rho_2 = 0,8$.

Para essa avaliação será utilizado também para efeito de comparação a análise de sensibilidade conforme descrito no capítulo 3, onde serão usadas as direções das intensidades de radiação que deixam o meio participante que apresentam os maiores e os menores coeficientes de sensibilidade separadamente. Complementando essa análise, procura-se avaliar também a variação do número de funções de pertinência das redes *Neuro-Fuzzy* e a quantidade das intensidades de radiação que serão fornecidas às redes na fase de treinamento.

Nessa avaliação foi usado um banco de dados com 100 padrões. Os parâmetros para a construção das redes *Neuro-Fuzzy* e das redes neurais artificiais são fornecidos nas Tabelas 5.2 e 5.3 respectivamente.

Tabela 5.2: Parâmetros utilizados na construção das Redes Neuro-Fuzzy – Caso Teste 2.

Parâmetros	Valores		
Número máximo de épocas	100	100	100
Tolerância do erro médio quadrático (treinamento)	10^{-5}	10^{-5}	10^{-5}
Quantidade de funções de pertinência Q_μ por rede NF	6	4	2
Tipo das funções de pertinência	Sino	Sino	Sino
Quantidade de dados experimentais N_e por rede NF	2 por amostra	4 por amostra	6 por amostra
Quantidade das amostras dos dados (\bar{Y})	100	100	100
Quantidade das amostras na fase de treinamento	60	60	60
Quantidade das amostras para validação do treinamento	20	20	20
Quantidade de regras Q_R	36	81	64
Método do treinamento	Híbrido	Híbrido	Híbrido
Classificação de dados	Particionamento	Particionamento	Particionamento

Tabela 5.3: Parâmetros utilizados na construção das Redes Neurais Artificiais – Caso Teste 2.

Parâmetros	Valores		
	MLP	MLP	MLP
Tipo da rede neural artificial	MLP	MLP	MLP
Número máximo de épocas	100	100	100
Tolerância do erro médio quadrático (treinamento)	10^{-5}	10^{-5}	10^{-5}
Número de camadas ocultas	2	2	2
Função de ativação	Tangente Hiperbólica	Tangente Hiperbólica	Tangente Hiperbólica
Quantidade de dados experimentais N_e por RNA	2 por amostra	4 por amostra	6 por amostra
Quantidade das amostras dos dados (\bar{Y})	100	100	100
Quantidade das amostras na fase de treinamento	60	60	60
Quantidade das amostras para validação do treinamento	20	20	20
Quantidade de regras Q_R	36	81	64
Método do treinamento com e sem a validação cruzada	Levenberg-Marquardt	Levenberg-Marquardt	Levenberg-Marquardt
Taxa de aprendizado	0,1	0,1	0,1

5.2.1 Resultados – Caso Teste 2

Ainda procurando validar os SNF foram criadas e treinadas 20 RNFs e 20 RNAs. Durante a fase de treinamento é utilizado o mesmo conjunto dados para todas as redes, e após a conclusão desta fase, tanto as RNFs como as RNAs foram submetidas ao caso teste proposto nesta seção.

Os resultados obtidos nesta fase são comparados aos valores esperados de cada uma das variáveis, resultando no cálculo do erro percentual entre esses valores. Nas tabelas a seguir são apresentados os valores desses erros percentuais em cada uma das situações proposta nesta seção conforme descrito na Tabela 5.3 e são ainda encontrados separados em tabelas distintas, para cada uma das variáveis radiativas tratadas.

Essas tabelas ainda estão organizadas, cada qual com suas respectivas legendas que descrevem os valores dos erros percentuais dos dados obtidos e possuem a título de organização, uma referência orientadora.

As tabelas estão organizadas da seguinte forma:

- a) Estimativas para o albedo de espalhamento ω , pelo SNF e pela RNA, com diferentes números de medidas experimentais N_e , utilizando as direções das intensidades de radiação que deixam

o meio participante, que possuem as maiores e menores sensibilidades (Tabelas 5.4 e 5.5), respectivamente.

Tabela 5.4: Erro percentual dos SNF e RNA - albedo de espalhamento ω com os maiores coeficientes de sensibilidade – Caso Teste 2.

Método	Quantidade de dados experimentais N_e					
	2		4		6	
	SNF	RNA	SNF	RNA	SNF	RNA
Erro % Mínimo	0,00	0,03	0,00	0,01	0,00	0,01
Erro % Máximo	0,03	1,04	0,00	2,38	0,03	3,14
Erro % Médio	0,01	0,42	0,00	0,58	0,00	0,66

Tabela 5.5: Erro percentual dos SNF e RNA - albedo de espalhamento ω com os menores coeficientes de sensibilidade – Caso Teste 2.

Método	Quantidade de dados experimentais N_e					
	2		4		6	
	SNF	RNA	SNF	RNA	SNF	RNA
Erro % Mínimo	0,22	0,03	0,02	0,01	0,04	0,01
Erro % Máximo	11,16	69,82	25,78	49,57	6,74	41,22
Erro % Médio	5,82	8,46	4,25	8,83	2,91	3,06

b) Estimativas para a espessura ótica τ_0 – Tabelas 5.6 e 5.7.

Tabela 5.6: Erro percentual dos SNF e RNA - espessura ótica τ_0 com os maiores coeficientes de sensibilidade – Caso Teste 2.

Método	Quantidade de dados experimentais N_e					
	2		4		6	
	SNF	RNA	SNF	RNA	SNF	RNA
Erro % Mínimo	0,04	0,01	0,01	0,00	0,02	0,00
Erro % Máximo	0,73	0,29	0,29	0,12	0,44	0,09
Erro % Médio	0,24	0,10	0,11	0,04	0,20	0,03

Tabela 5.7: Erro percentual dos SNF e RNA - espessura ótica τ_0 com os menores coeficientes de sensibilidade – Caso Teste 2.

Método	Quantidade de dados experimentais N_e					
	2		4		6	
	SNF	RNA	SNF	RNA	SNF	RNA
Erro % Mínimo	0,01	0,02	0,01	0,02	0,04	0,04
Erro % Máximo	0,24	0,10	0,21	0,16	6,74	0,09
Erro % Médio	0,09	0,06	0,07	0,04	2,91	0,06

c) Estimativas para a reflectividade difusa ρ_1 – Tabelas. 5.8 e 5.9.

Tabela 5.8: Erro percentual dos SNF e RNA – reflectividade difusa ρ_1 com os maiores coeficientes de sensibilidade – Caso Teste 2.

Método	Quantidade de dados experimentais N_e					
	2		4		6	
	SNF	RNA	SNF	RNA	SNF	RNA
Erro % Mínimo	0,00	0,06	0,00	0,00	0,00	0,09
Erro % Máximo	0,63	19,82	0,27	12,90	0,31	27,91
Erro % Médio	0,05	2,01	0,02	1,14	0,02	2,32

Tabela 5.9: Erro percentual dos SNF e RNA – reflectividade difusa ρ_1 com os menores coeficientes de sensibilidade – Caso Teste 2.

Método	Quantidade de dados experimentais N_e					
	2		4		6	
	SNF	RNA	SNF	RNA	SNF	RNA
Erro % Mínimo	0,01	0,02	0,07	0,02	0,00	0,00
Erro % Máximo	11,92	36,48	123,39	37,82	18,09	18,69
Erro % Médio	0,96	2,54	9,09	2,58	1,47	1,69

d) Estimativas para a reflectividade difusa ρ_2 – Tabelas. 5.10 e 5.11.

Tabela 5.10: Erro percentual dos SNF e RNA - reflectividade difusa ρ_2 com os maiores coeficientes de sensibilidade – Caso Teste 2.

Método	Quantidade de dados experimentais N_e					
	2		4		6	
	SNF	RNA	SNF	RNA	SNF	RNA
Erro % Mínimo	0,00	0,02	0,00	0,03	0,00	0,00
Erro % Máximo	0,02	108,15	0,02	164,89	0,06	189,10
Erro % Médio	0,01	6,10	0,01	8,89	0,01	9,91

Tabela 5.11: Erro percentual dos SNF e RNA - reflectividade difusa ρ_2 com os menores coeficientes de sensibilidade – Caso Teste 2.

Método	Quantidade de dados experimentais N_e					
	2		4		6	
	SNF	RNA	SNF	RNA	SNF	RNA
Erro % Mínimo	0,00	0,02	0,01	0,01	0,01	0,00
Erro % Máximo	0,51	9,95	0,82	140,55	0,26	175,79
Erro % Médio	0,24	5,16	0,13	7,55	0,12	9,39

Comparando-se os valores dos erros percentuais encontrados nas Tabelas 5.4 a 5.10, é possível verificar para as estimativas dos parâmetros ω , τ_0 , ρ_1 e ρ_2 do caso proposto, os sistemas *Neuro-Fuzzy* conseguiram resultados com valores aceitáveis como solução para este caso teste, já que apresentaram menores valores do erro médio em comparação aos mesmos valores obtidos pelas redes neurais artificiais, quando utilizadas com as direções das intensidades que deixam o meio que possuem as maiores sensibilidades para este caso, i.e., utilizando os dados que possuem maior representatividade neste modelo.

A partir desta análise serão apresentados neste capítulo os resultados para quatro casos teste atípicos, que são difíceis de serem solucionados pelos métodos de otimização. Para tanto serão avaliados os resultados destes quatro casos com os sistemas *Neuro-Fuzzy* e através do método híbrido de comitês *Neuro-Fuzzy*.

5.3 Testes das Redes Neuro-Fuzzy e dos Comitês Neuro-Fuzzy

Apresenta-se nesta seção a análise de sensibilidade para os quatro casos distintos. A título de esclarecimento, serão utilizadas nas fases de treinamento e execução os valores das intensidades de radiação Y que possuem os maiores coeficientes de sensibilidade para cada variável radiativa em cada um dos casos de estudo propostos.

5.3.1 Casos Testes

Foram intencionalmente escolhidos quatro casos teste por apresentarem propriedades radiativas difíceis de serem recuperadas para o tratamento do problema inverso em transferência radiativa por métodos distintos aos desenvolvidos nesta tese. Os valores das variáveis radiativas para cada caso um dos quatro casos propostos são apresentados na Tabela 5.12.

Caso Teste 3, Soeiro et. al (2004) apresentam uma solução com um método híbrido de uma RNA com o método de Levenberg-Marquardt; e para o mesmo problemas Pinheiro et al. (2005) implementa uma solução de te PI através do funcional de Tikhonov, pois, o método de otimização isoladamente não convergia para a solução esperada.

Casos Teste 4 e 5, Sacco et al. (2009), utilizaram o Algoritmo de Colisão de Partículas – PCA (*Particle Collision Algorithm*) na solução do problema inverso, pois, identificaram que nesses casos também são difíceis de serem estimadas as propriedades radiativas pelo algoritmo de otimização.

No Caso Teste 6, Knupp et. al (2007), utilizaram também o Algoritmo de Colisão de Partículas – PCA (*Particle Collision Algorithm*) na solução do problema inverso, entretanto, identificaram uma melhora expressiva em relação nos resultados obtidos pelos seus métodos com a utilização da análise da sensibilidade.

Para todos os quatro casos foram consideradas fontes externas isotrópicas com intensidades $f_1(\mu) = 1$, $f_2(\mu) = 0$, e sem fonte interna.

Tabela 5.12: Parâmetros associados aos casos testes

	Caso Teste 3	Caso Teste 4	Caso Teste 5	Caso Teste 6
ω	0,5	0,1	0,9	0,3
τ_0	1,0	0,5	2,0	4,0
ρ_1	0,1	0,1	0,5	0,1
ρ_2	0,95	0,9	0,5	0,9

5.3.2 Cálculo e análise dos coeficientes de sensibilidade

Serão realizadas as análises de sensibilidade para cada um dos quatro Casos Teste definidos na Tabela 5.12, com base na teoria exposta na Seção 3.4 do Capítulo 3, para cada um dos parâmetros estudados e uma análise simultânea a fim de avaliar aqueles que sejam relevantes na solução do problema inverso.

Para uma melhor visualização dos resultados da análise dos coeficientes de sensibilidade são representadas na Fig. 5.4 as direções nas quais são obtidos os dados experimentais Y_i , $i = 1, 2, \dots, 20$, com o ângulo polar correspondente a μ_i , onde $\mu_i = \cos\theta$.

Os Casos 3 a 6 são apresentados, respectivamente, nas Fig. 5.5 a Fig. 5.8.




Figura 5.4: Representação esquemática do dado experimental.

5.3.2.1 Análise de Sensibilidade - Caso Teste 3

Analisando-se a Fig. 5.5:

Pode-se perceber que sensibilidade do parâmetro albedo de espalhamento simples ω é relativamente alta entre μ_{15} a μ_{20} ($\mu < 0$), i.e., os coeficientes de sensibilidade que apresentam os maiores valores estão contidos entre [0,5526 a 0,6880]. Entretanto, para $\mu > 0$ os valores dos coeficientes são muito baixos, quase que inexistente.

Pode-se observar que a região de maior sensibilidade do parâmetro espessura ótica τ_0 está situada no intervalo μ_{11} a μ_{16} , i.e., os coeficientes de sensibilidade que apresentam os maiores valores estão contidos entre [-0,2361 a -0,2050]. Para $\mu > 0$ os valores dos coeficientes são muito mais baixos.

Para a reflectividade difusa ρ_1 , observa-se para $\mu < 0$ os coeficientes de sensibilidade apresentam valores maiores do que para $\mu > 0$.

Já para a reflectividade difusa ρ_2 , identifica-se um aumento nos valores dos coeficientes de sensibilidade tanto para $\mu < 0$ quanto para $\mu > 0$ com valores crescentes de

$|\mu|$. As informações contidas entre μ_5 a μ_{10} são os valores dos coeficientes com maior relevância.




Figura 5.5: Sensibilidade para o albedo de espalhamento simples ω , a espessura ótica do meio τ_0 e as reflectividades difusas ρ_1 e ρ_2 (Caso Teste 3).

Os gráficos relativos aos coeficientes de sensibilidade estão representados separadamente por parâmetro no anexo II, seção II.1.

5.3.2.2 Análise de Sensibilidade - Caso Teste 4

Analisando-se a Fig. 5.6:

As áreas de sensibilidade significativamente mais altas para ω estão situadas entre μ_{15} a μ_{20} ($\mu < 0$). Para $\mu > 0$ os valores dos coeficientes de sensibilidade são muito baixos, quase que inexistentes.

Já para a espessura ótica τ_0 os valores dos coeficientes são relativamente altos para os menores valores de μ ($\mu < 0$), sendo que os melhores valores para serem utilizados são

aqueles entre μ_{11} a μ_{16} . Para $\mu > 0$ os coeficientes de sensibilidade são praticamente constantes e desprezíveis para quaisquer valores de μ .

O mesmo acontece para os coeficientes de sensibilidade do parâmetro ρ_1 no que se refere tanto para $\mu < 0$ como também para $\mu > 0$.

As áreas mais sensíveis para o parâmetro ρ_2 são aquelas cujos valores de $|\mu|$ (μ_{11} a μ_{16}) possuem os maiores valores.




Figura 5.6: Sensibilidade para o albedo de espalhamento simples ω , a espessura ótica do meio τ_0 e as reflectividades difusas ρ_1 e ρ_2 (Caso Teste 4).

Os gráficos relativos aos coeficientes de sensibilidade estão representados separadamente por parâmetro no anexo II, seção II.2.

5.3.2.3 Análise de Sensibilidade - Caso Teste 5

Analisando-se a Fig. 5.7:

Para o parâmetro ω vê-se como áreas de maior sensibilidade conforme ocorre o aumento para $|\mu|$ tanto para $\mu < 0$ como para também para $\mu > 0$.

Pode-se perceber que, para $\mu > 0$ possuem os valores com maior sensibilidade para os demais parâmetros τ_0 , ρ_1 e ρ_2 .




Figura 5.7: Sensibilidade para o albedo de espalhamento simples ω , a espessura ótica do meio τ_0 e as reflectividades difusas ρ_1 e ρ_2 (Caso Teste 5).

Os gráficos relativos aos coeficientes de sensibilidade estão representados separadamente por parâmetro no anexo II, seção II.3.

5.3.2.4 Análise de Sensibilidade - Caso Teste 6

Analisando-se a Fig. 5.8:

Pode-se perceber que os valores dos coeficientes de sensibilidade dos parâmetros ω e ρ_1 possuem valores relativamente altos entre μ_{15} a μ_{20} ($\mu < 0$). Mas, para $\mu > 0$ possuem valores desses coeficientes muito baixos, quase que inexistentes.

Por outro lado, para os parâmetros τ_0 e ρ_2 , pode ser percebido que existe uma baixa sensibilidade em todas as direções, apesar dos valores dos coeficientes para $\mu > 0$ serem menores do que para $\mu < 0$.




Figura 5.8: Sensibilidade para o albedo de espalhamento simples ω , a espessura ótica do meio τ_0 e as reflectividade difusa ρ_1 e ρ_2 (Caso Teste 6).

Os gráficos relativos aos coeficientes de sensibilidade estão representados separadamente por parâmetro no anexo II, seção II.4.

Knupp et. al (2007) convergiram para os mesmos resultados encontrados nesta seção em uma análise de sensibilidade que foi realizada de forma similar ao que foi tratado nesta tese, o que ratifica o modelo desenvolvido para a análise de sensibilidade estudada.

5.3.2.5 Análise de Sensibilidade - Resumo

A partir da análise de sensibilidade serão utilizadas as seguintes direções das intensidades para cada um dos casos conforme a Tabela 5.13.

Tabela 5.13: Direções (μ) das intensidades de radiação com os maiores coeficientes de sensibilidade

	Caso Teste 3	Caso Teste 4	Caso Teste 5	Caso Teste 6
ω	μ_{15} a μ_{20}	μ_{15} a μ_{20}	μ_{15} a μ_{20}	μ_{15} a μ_{20}
τ_0	μ_{11} a μ_{16}	μ_{11} a μ_{16}	μ_5 a μ_{10}	μ_5 a μ_{10}
ρ_1	μ_{15} a μ_{20}	μ_{11} a μ_{16}	μ_{15} a μ_{20}	μ_{15} a μ_{20}
ρ_2	μ_5 a μ_{10}	μ_5 a μ_{10}	μ_5 a μ_{10}	μ_5 a μ_{10}

5.3.3 Resultados dos casos teste com os Sistemas Neuro-Fuzzy, com os Comitês Neuro-Fuzzy e Análise de Sensibilidade

Para a análise dos resultados encontrados através dos SNFs e das máquinas de comitê *Neuro-Fuzzy* para cada um dos casos teste propostos, foram utilizadas seis intensidades de radiação que deixam o meio participante.

É importante considerar que o número máximo de épocas permitidas durante a fase de treinamento foi especificada como 500; a tolerância mínima desejada é igual a 10^{-5} e, combinando com essas características, são utilizados os métodos de treinamento *backpropagation* e híbrido (*backpropagation* combinado com mínimos quadrados), a quantidade de funções de pertinência utilizadas foi igual a 2 ou 3 para cada SNF, e com a classificação dos dados por Partição de Grade ou Clusterização.

A partir dessas características foram criadas dez redes *Neuro-Fuzzy*, o resultado das mesmas serão avaliados e, conseqüentemente, serão utilizados individualmente e também combinando as redes que apresentaram os melhores resultados para a utilização nas máquinas de comitê *Neuro-Fuzzy*.

Os resultados obtidos na fase de execução tanto dos SNF como também dos comitês, serão comparados nas seções seguintes com os métodos de inteligência computacional ou métodos híbridos desenvolvidos por pesquisadores em problemas inversos em transferência radiativa, conforme descrito na seção 5.3.1.

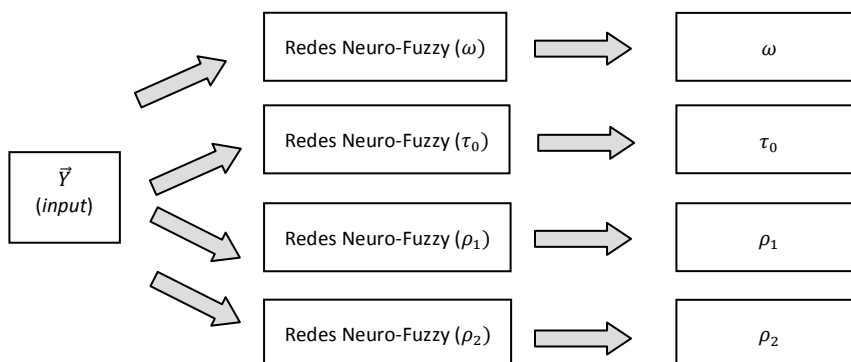


Figura 5.9: Diagrama esquemático – Solução do Problema Inverso com Redes NF

Devido à limitação imposta pelo sistema *Neuro-Fuzzy*, quanto a sua capacidade de produzir apenas uma saída na arquitetura da rede, optou-se em utilizar a combinação de um

método híbrido das redes *neuro-fuzzy* para cada uma das quatro propriedades radiativas que serão determinadas, e um método que estará atuando como o combinador desses resultados na máquina de comitê.

Conforme descrito na seção 5.4 foram construídos quatro conjuntos de redes *neuro-fuzzy* com características distintas para a determinação de cada variável radiativa: o albedo de espalhamento simples (ω), a espessura ótica do meio (τ_0), e as reflectividades difusas (ρ_1 e ρ_2) conforme as características descritas na Tabela 5.14 e representado na Fig. 5.10.

Tabela 5.14: Parâmetros utilizados na construção das Redes Neuro-Fuzzy – Casos Teste 3,4, 5 e 6.

Parâmetros	valores
Número máximo de épocas	500
Tolerância do erro médio quadrático (treinamento)	10^{-5}
Quantidade de funções de pertinência Q_μ por rede NF	2 e 3
Tipo das funções de pertinência	Sino
Quantidade de dados experimentais N_e por rede NF	6 por amostra
Quantidade das amostras dos dados (\vec{Y})	100
Quantidade das amostras na fase de treinamento	60
Quantidade das amostras para validação do treinamento	20
Quantidade de regras Q_R	64 e 729
Método do treinamento	Híbrido e <i>Backpropagation</i>
Classificação de dados	Clusterização e Particionamento
Quantidade de redes NF por comitê para cada variável	5

Os resultados dessas redes NF foram combinados em uma máquina de comitê de duas formas distintas:

- a) Combinador – média: é avaliada a média de cada variável isoladamente a partir dos resultados obtidos através do conjunto de redes *neuro-fuzzy*;
- b) Combinador – Rede Neural Artificial: os resultados obtidos através das redes *neuro-fuzzy* são apresentados a uma RNA previamente treinada, construídas conforme as características descritas na Tab. 5.15.

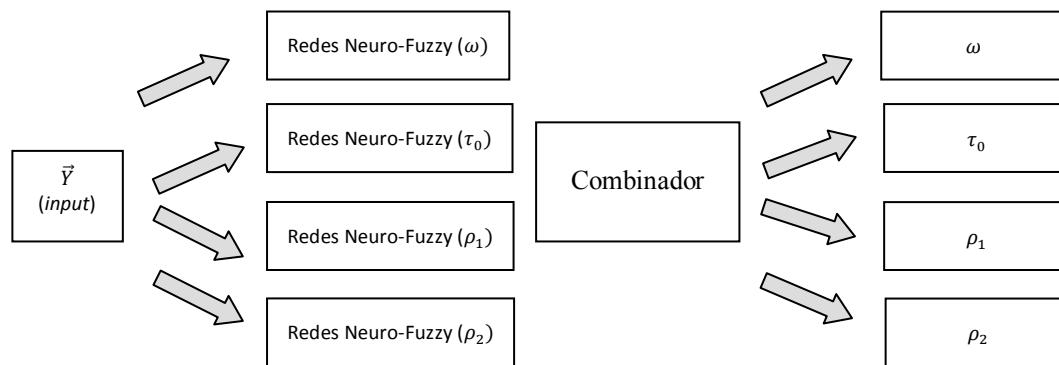


Figura 5.10: Diagrama esquemático – Solução do Problema Inverso com Comitês de Redes NF

Tabela 5.15: Parâmetros utilizados na construção da RNA combinadora.

Tipo da rede neural artificial	<i>MLP</i>
Número de camadas ocultas	2
Número de neurônios nas camadas ocultas	16 e 8
Número de neurônios na camada de saída	4
Funções de ativação	Tangente Hiperbólica
Método do treinamento	Resiliente <i>Backpropagation</i>
Número máximo de épocas	2000
Erro mínimo	10^{-5}

Durante o treinamento da RNA combinadora foram avaliados vários métodos de treinamento: Gradiente Decrescente, Levenberg-Marquardt, Taxa de Aprendizagem Adaptativa e Resiliente *Backpropagation*. Conforme consta na Tab. 5.15 o método Resilient (Rprop) foi o escolhido para ser o método utilizado nas respectivas RNAs, pois, apresentou o menor erro durante a fase de execução para os quatro casos estudados.

Para a o treinamento da máquina de comitê de Redes *Neuro-fuzzy* foram utilizados as mesmas 100 amostras de dados para todas as redes NF.

Ao término desta fase de treinamento das redes *neuro-fuzzy*, os mesmos dados utilizados durante esta fase são apresentados a camada de entrada da rede neural, produzindo uma segunda fase de treinamento - agora para a rede neural artificial.

5.3.3.1 Caso Teste 3

Tabela 5.16: Parâmetros associados ao Caso Teste 3 (SOEIRO et al., 2004) e (PINHEIRO et al., 2005)

	ω	τ_0	ρ_1	ρ_2
Valores das variáveis	0,5	1,0	0,1	0,95
Direções (μ) usadas – maior sensibilidade	μ_{15} a μ_{20}	μ_{11} a μ_{16}	μ_{15} a μ_{20}	μ_5 a μ_{10}

Soeiro et al. (2004) apresenta como solução para este caso a utilização de um método híbrido de uma RNA produzindo valores iniciais uma solução que utiliza o método de Levenberg-Marquardt (LM).

Tabela 5.17: Resultados obtidos pelo método RNA-LM – Caso Teste 3 (SOEIRO et al., 2004)

	Ruído			
	$\pm 2\%$		$\pm 5\%$	
	valor	Erro %	valor	Erro %
ω	0,502	0,40	0,502	0,40
τ_0	0,999	0,10	0,999	0,10
ρ_1	0,106	6,00	0,107	7,00
ρ_2	0,95	0,00	0,951	0,11

E também Pinheiro et al. (2005) busca-se essa mesma solução com um método de otimização utilizando o funcional de Tikhonov (RT).

Tabela 5.18: Resultados obtidos pelo método RT – Caso Teste 3 (PINHEIRO et al., 2005)

	Ruído					
	$\pm 0\%$		$\pm 5\%$		$\pm 7\%$	
	valor	Erro %	valor	Erro %	valor	Erro %
ω	0,5	0,00	0,5017	0,34	0,4884	2,32
τ_0	1	0,00	0,9983	0,17	0,989	1,10
ρ_1	0,0999	0,10	0,1015	1,50	0,0833	16,71
ρ_2	0,9499	0,01	0,9496	0,04	0,9538	0,40

Dessa forma, procurando avaliar a eficácia dos métodos SNF e Comitê NF, os resultados obtidos por esses dois métodos serão comparados aos resultados encontrados pelos métodos RNA-LM e RT, Tabelas 5.17 e 5.18 respectivamente.

Para a análise dos SNFs foram construídas dez redes NF com características distintas conforme Tabela 5.14. Procurando simular os dados experimentais, utilizaremos o método proposto na seção 3.3, com a inserção de ruídos pseudo-aleatórios com erros da ordem de 2%, 3%, 5% e 7% nos valores das intensidades de radiação que deixam o meio. Os resultados das estimativas das propriedades radiativas pelos SNFs estão contidos na Tabela 5.19.

Tabela 5.19: Resultados obtidos pelo SNF – Caso Teste 3

	Ruído							
	±0%		±3%		±5%		±7%	
	valor	Erro %	valor	Erro %	valor	Erro %	valor	Erro %
ω	0,5000	0,00	0,4988	0,25	0,5008	0,16	0,5005	0,10
τ_0	1,0000	0,00	1,0007	0,07	1,0023	0,23	0,9938	0,62
ρ_1	0,1000	0,01	0,0968	3,21	0,0971	2,86	0,1011	1,14
ρ_2	0,9500	0,00	0,9500	0,00	0,9498	0,02	0,9504	0,04

Analisando-se os resultados obtidos com o SNF (Tabela 5.19) em comparação aos resultados dos dois métodos que também solucionaram este mesmo caso, é possível verificar em quase sua totalidade (90%) os resultados dos SNFs foram melhores, mesmo com a presença de ruído aditivo nos dados.

Ainda, procurando evoluir com a utilização dos SNFs, também é proposta nesta tese a utilização de máquinas de comitê NF, nas quais usa-se a analogia sobre o conhecimento de um grupo de especialistas no tratamento de um único problema é aplicado em conjunto com os SNFs.

Neste contexto, serão analisados os resultados encontrados através deste modelo de máquinas de comitê utilizando tanto com um combinador média como também com um combinador RNA. E, devido à comprovação da importância da utilização da análise de sensibilidade na solução dos SNFs, também será de grande importância a sua utilização neste modelo.

Para a utilização das RNAs como combinador nas máquinas de comitê, serão construídas redes neurais com as características descritas na Tabela 5.15. Na composição do comitê serão utilizados as cinco redes NF que apresentaram os melhores resultados para este caso em estudo. Os resultados das estimativas das propriedades radiativas pelos comitês NFs estão contidos nas Tabelas. 5.20 e 5.21.

Tabela 5.20: Resultados obtidos pelo Comitê NF com o combinador média – Caso Teste 3

	Ruído							
	±0%		±3%		±5%		±7%	
	Valor	Erro %	valor	Erro %	valor	Erro %	valor	Erro %
ω	0,5000	0,00	0,5001	0,01	0,4986	0,28	0,4996	0,08
τ_0	0,9999	0,01	1,0001	0,01	1,0004	0,04	0,9907	0,93
ρ_1	0,1000	0,02	0,1016	1,65	0,0971	2,85	0,1043	4,32
ρ_2	0,9500	0,00	0,9499	0,01	0,9496	0,04	0,9505	0,06

Tabela 5.21: Resultados obtidos pelo Comitê NF com o combinador RNA – Caso Teste 3

	Ruído							
	±0%		±3%		±5%		±7%	
	valor	Erro %	Valor	Erro %	valor	Erro %	valor	Erro %
ω	0,4989	0,23	0,482557	3,49	0,482018	3,60	0,497672	0,47
τ_0	0,9988	0,12	0,998334	0,17	1,0000	0,00	0,970226	2,98
ρ_1	0,1001	0,06	0,098701	1,30	0,109176	9,18	0,097631	2,37
ρ_2	0,9536	0,38	0,953466	0,36	0,953357	0,35	0,953866	0,41

Neste momento, os resultados com a máquina de comitê com o combinador média (Tabela 5.20) apresentou uma melhora em comparação ao SNF quando tratado isoladamente, pois, é possível verificar em 95% dos resultados foram melhores do que os métodos que estão sendo utilizados em comparação. Mesmo assim, para os 5% dos resultados restantes, ainda é possível verificar que ocorreu uma redução no valor do erro percentual obtido pelo comitê NF quando comparado ao resultado do método SNF para esse caso teste.

Por outro lado, quando é utilizado a máquina de comitê com o combinador RNA há uma melhora nos resultados encontrados em relação aos dois métodos que estão sendo comparados em 65% dos casos, mesmo assim, para 10% dos resultados na qual o comitê NF não obteve melhora, o erro percentual máximo encontrado foi de 0,41% o que pode ser considerado um valor baixo do erro, mesmo considerando a adição de ruído neste caso.

5.3.3.2 Caso Teste 4

Tabela 5.22: Parâmetros associados ao Caso Teste 4 (SACCO et al., 2009)

	ω	τ_0	ρ_1	ρ_2
Valores das variáveis	0,1	0,5	0,1	0,9
Direções (μ) usadas – maior sensibilidade	μ_{15} a μ_{20}	μ_{11} a μ_{16}	μ_{11} a μ_{16}	μ_5 a μ_{10}

Sacco et al. (2009) utilizaram o Algoritmo de Colisão de Partículas – PCA (*Particle Collision Algorithm*) na solução do problema inverso para este caso proposto. E da mesma forma que foi ilustrado no caso anterior, nesta seção procura-se avaliar a eficácia dos métodos SNF e Comitê NF, com a comparação dos resultados desses três métodos, conforme Tabela 5.23.

Para a análise dos SNFs foram construídas dez redes NF com características distintas conforme Tabela 5.14 e procurando simular os dados experimentais, utilizaremos o método

proposto na seção 3.3, com a inserção de ruídos pseudo-aleatórios de até 5.5% nos valores das intensidades de radiação que deixam o meio.

Tabela 5.23: Resultados obtidos pelos métodos: PCA, SNF e Comitê NF Caso Teste 4

	Ruído $\pm 5,5\%$							
	PCA melhor estimativa		SNF		Comitê NF média		Comitê NF RNA	
	Valor	Erro %	Valor	Erro %	Valor	Erro %	Valor	Erro %
ω	0,115	15,00	0,0989	1,12	0,0973	2,70	0,0969	3,08
τ_0	0,499	0,20	0,5000	0,01	0,5010	0,20	0,5025	0,50
ρ_1	0,124	24,00	0,0994	0,59	0,1077	7,71	0,1048	4,83
ρ_2	0,899	0,11	0,9011	0,13	0,8996	0,05	0,8959	0,45

Analisando-se os resultados da Tabela 5.23 obtidos com o SNF e o Comitê NF com o combinador média, em comparação aos resultados do método PCA, é possível verificar em sua totalidade (100%) os resultados tanto o SNF como o comitê NF foram melhores, mesmo com a presença de ruído aditivo nos dados.

Por outro lado, quando é utilizado a máquina de comitê com o combinador RNA para os resultados na qual o comitê NF não obteve melhora, o erro percentual máximo encontrado foi de 0,45% o que pode ser considerado um valor baixo do erro, mesmo considerando a adição de ruído neste caso.

5.3.3.3 Caso Teste 5

Tabela 5.24: Parâmetros associados ao Caso Teste 5 (SACCO et al., 2009)

	ω	τ_0	ρ_1	ρ_2
Valores das variáveis	0,9	2,0	0,5	0,5
Direções (μ) usadas – maior sensibilidade	μ_{15} a μ_{20}	μ_5 a μ_{10}	μ_{15} a μ_{20}	μ_5 a μ_{10}

Sacco et al. (2009) também utilizaram o Algoritmo de Colisão de Partículas – PCA (*Particle Collision Algorithm*) na solução do problema inverso para este caso proposto. Na Tabela 5.25 serão apresentados os resultados obtidos pelos métodos PCA, SNF e Comitês NF deste caso.

Da mesma forma que os casos anteriores foram construídas 10 redes NF com características distintas conforme Tab. 5.14 e utilizaremos a inserção de ruídos pseudo-

aleatórios com erro da ordem de até 5.5% nos valores das intensidades de radiação que deixam o meio.

Tabela 5.25: Resultados obtidos pelos métodos: PCA, SNF e Comitê NF Caso Teste 5

	Ruído $\pm 5,5\%$							
	PCA melhor estimativa		SNF		Comitê NF média		Comitê NF RNA	
	Valor	Erro %	Valor	Erro %	Valor	Erro %	Valor	Erro %
ω	0,8970	0,33	0,8995	0,05	0,8981	0,21	0,9005	0,05
τ_0	1,9520	2,40	1,9931	0,34	1,9876	0,62	1,9582	2,09
ρ_1	0,4950	1,00	0,5010	0,19	0,5001	0,02	0,5035	0,70
ρ_2	0,5110	2,20	0,4936	1,29	0,4898	2,03	0,4894	2,11

Analisando-se os resultados da Tabela 5.25 obtidos com o SNF e o Comitê NF com o combinador média e também com o combinador RNA, em comparação aos resultados do método PCA, é possível verificar em sua totalidade (100%) os resultados tanto o SNF como o comitê NF foram melhores, mesmo com a presença de ruído aditivo nos dados.

5.3.3.4 Caso Teste 6

Tabela 5.26: Parâmetros associados ao Caso Teste 6 (KNUPP et al., 2007)

	ω	τ_0	ρ_1	ρ_2
Valores das variáveis	0,3	4,0	0,1	0,9
Direções (μ) usadas – maior sensibilidade	μ_{15} a μ_{20}	μ_5 a μ_{10}	μ_{15} a μ_{20}	μ_5 a μ_{10}

Knupp et al. (2007) utilizaram o Algoritmo de Colisão de Partículas – PCA (*Particle Collision Algorithm*) e também um modelo híbrido do PCA com o método estocástico de *Levenberg-Marquardt* na solução do problema inverso para o mesmo caso proposto.

Nas Tabelas 5.27 a 5.29 são apresentados respectivamente os melhores valores e a média dos valores para cinco iterações da estimativa inicial da solução do PI com a primeira execução do PCA, PCA_{INI} , as estimativas obtidas com o PCA em conjunto com os de dados com maior sensibilidade, PCA_{SA} (neste cada caso cada uma das variáveis radiativas são estimadas separadamente), e as estimativas obtidas com o método de *Levenberg-Marquardt* PCA_{LM} , utilizando PCA_{SA} como uma estimativa inicial. Neste último desenvolvimento as variáveis radiativas são estimadas simultaneamente.

Tabela 5.27: Resultados obtidos pelos métodos: PCA_{INI} - melhor resultado e média Caso Teste 6

	Ruído									
	$\pm 0\%$		$\pm 5\%$				$\pm 8\%$			
	Melhor valor		Melhor valor		Média		Melhor valor		Média	
	Valor	Erro %	Valor	Erro %	Valor	Erro %	Valor	Erro %	Valor	Erro %
ω	0,33	10,00	0,38	26,67	0,38	26,67	0,51	70,00	0,43	43,33
τ_0	2,19	45,25	3,01	24,75	2,39	40,25	3,61	9,75	3,86	3,50
ρ_1	0,23	130,00	0,33	230,00	0,34	240,00	0,56	460,00	0,44	340,00
ρ_2	0,91	1,11	0,80	11,11	0,81	10,00	0,80	11,11	0,68	24,44

Tabela 5.28: Resultados obtidos pelos métodos: PCA_{SA} - melhor resultado e média Caso Teste 6

	Ruído									
	$\pm 0\%$		$\pm 5\%$				$\pm 8\%$			
	Melhor valor		Melhor valor		Média		Melhor valor		Média	
	Valor	Erro %	Valor	Erro %	Valor	Erro %	Valor	Erro %	Valor	Erro %
ω	0,31	3,33	0,28	6,67	0,29	3,33	0,28	6,67	0,30	0,00
τ_0	4,10	2,50	4,37	9,25	4,06	1,50	3,45	13,75	4,58	14,50
ρ_1	0,13	30,00	0,02	80,00	0,19	90,00	0,01	90,00	0,16	60,00
ρ_2	0,89	1,11	0,85	5,56	0,88	2,22	0,95	5,56	0,79	12,22

Tabela 5.29: Resultados obtidos pelos métodos: PCA_{LM} - melhor resultado e média Caso Teste 6

	Ruído									
	$\pm 0\%$		$\pm 5\%$				$\pm 8\%$			
	Melhor valor		Melhor valor		Média		Melhor valor		Média	
	Valor	Erro %	Valor	Erro %	Valor	Erro %	Valor	Erro %	Valor	Erro %
ω	0,30	0,00	0,25	16,67	0,30	0,00	0,31	3,33	0,29	3,33
τ_0	4,00	0,00	3,15	21,25	3,77	5,75	3,40	15,00	3,48	13,00
ρ_1	0,10	0,00	0,01	90,00	0,14	40,00	0,15	50,00	0,11	10,00
ρ_2	0,90	0,00	0,95	5,56	0,88	2,22	0,95	5,56	0,93	3,33

Mantendo a mesma abordagem dos casos anteriores, procura-se avaliar a eficácia dos métodos SNF e Comitê NF para este caso em particular com a comparação dos resultados desses três métodos. Os resultados encontrados pelo SNF e pela máquina de comitê estão apresentados nas Tabelas 5.30 e 5.31.

Tabela 5.30: Resultados obtidos pelo método SNF Caso Teste 6

	Ruído					
	$\pm 0\%$		$\pm 5\%$		$\pm 8\%$	
	Valor	Erro %	Valor	Erro %	Valor	Erro %
ω	0,30	0,00	0,30	0,03	0,30	0,53
τ_0	4,00	0,00	4,00	0,08	4,01	0,36
ρ_1	0,10	0,03	0,10	1,76	0,12	18,28
ρ_2	0,90	0,00	0,90	0,04	0,90	0,01

Tabela 5.31: Resultados obtidos pelo método Comitê NF Caso Teste 6

	Ruído											
	±0%				±5%				±8%			
	Combinador Média		Combinador RNA		Combinador Média		Combinador RNA		Combinador Média		Combinador RNA	
	Valor	Erro %	Valor	Erro %	Valor	Erro %	Valor	Erro %	Valor	Erro %	Valor	Erro %
ω	0,30	0,00	0,30	0,20	0,30	0,26	0,30	0,29	0,29	2,95	0,29	3,14
τ_0	4,00	0,00	4,00	0,01	4,01	0,13	4,00	0,10	4,00	0,02	3,92	2,00
ρ_1	0,10	0,03	0,10	0,31	0,11	6,35	0,10	0,68	0,12	23,98	0,12	23,93
ρ_2	0,90	0,00	0,91	0,59	0,90	0,02	0,91	0,66	0,90	0,16	0,91	0,75

Conforme pode ser identificado nas Tabelas 5.30 e 5.31 em apenas 0,1% dos resultados o SNF e a máquina de comitê não obtiveram uma melhora expressiva em relação aos métodos a que foram comparados mesmo com a inserção de ruído nos dados.

Para o caso específico da reflectividade difusa no lado $\tau = 0$, tanto o SNF como o comitê NF apresentaram um erro percentual elevado na determinação desta variável. Porém, este resultado pode ser justificado recorrendo-se à seção 5.3.2.4 onde podem ser identificados os pequenos valores dos coeficientes de sensibilidade deste parâmetro.

CONCLUSÕES E TRABALHOS FUTUROS

Nesta tese foi apresentada a investigação para a determinação de parâmetros para um problema inverso em transferência radiativa com o uso dos sistemas *neuro-fuzzy* e com as máquinas de comitê *neuro-fuzzy*. A evolução deste trabalho se deu a partir da utilização das técnicas de inteligência computacional para a solução deste problema. Inicialmente, através da utilização das redes neurais artificiais e o desenvolvimento da integração do método de validação cruzada na incorporação na fase de treinamento dessas redes. A seguir, com a intenção da integração dos sistemas de inferência *fuzzy*, requisitava-se a necessidade do conhecimento de especialistas durante a fase de desenvolvimento. A partir daquele momento algumas propostas foram analisadas, mas sem êxito. Entre elas, a utilização dos mapas de Kohonen, mas apenas foram obtidos resultados positivos como classificadores. A utilização de sistemas híbridos por outros pesquisadores, fez surgir uma alternativa para a limitação imposta pelas deficiências isoladas de cada técnica analisada individualmente. Assim, foram avaliadas inicialmente diferentes arquiteturas de SNF, que em sua grande maioria apresentavam serem eficientes em sistemas de controle e como classificadores. A partir de então, surge um grande desafio a ser contornado em uma pesquisa deste porte, a dimensão do problema atrelada às limitações computacionais.

Quanto aos objetivos desta pesquisa, os resultados obtidos pelos sistemas híbridos *neuro-fuzzy* e também com as máquinas de comitê *neuro-fuzzy* apresentaram em sua grande maioria, resultados muito satisfatórios quando comparados aos métodos híbridos utilizados por outros pesquisadores, principalmente com a utilização da análise de sensibilidade e a incorporação da validação cruzada durante a fase de treinamento dos SNFs e dos comitês, visto que tal procedimento reduz o esforço computacional para a determinação do ponto ótimo de aprendizado nessas redes.

O benefício da utilização das máquinas de comitê *neuro-fuzzy* foi o da determinação de todos os parâmetros envolvidos na solução do problema inverso em transferência radiativa. Já que esta condição é uma limitação dos sistemas *neuro-fuzzy*.

Outro objetivo alcançado é a exploração de uma importante característica que é a velocidade de resposta, pois uma vez realizado o treinamento dos sistemas *neuro-fuzzy* e das

máquinas de comitê *neuro-fuzzy* o resultado para uma nova amostra é um simples produto dos pesos das redes; diferentemente de outros métodos para a solução de problemas inversos, nos quais uma nova amostra acarreta uma grande quantidade de avaliações do problema direto e um grande esforço computacional.

Complementado, a utilização dos sistemas neuro-fuzzy simplifica a o uso de um sistema de inferência, pois elimina a necessidade de um especialista para a extração das regras fuzzy e combinado com a capacidade das redes neurais em tratar aprendizado por experiência e a generalização do conhecimento, realiza o ajuste das funções de pertinência do modelo.

Para trabalhos futuros, é interessante prosseguir na pesquisa sobre soluções dos problemas inversos em transferência radiativa com a implementação de sistemas neuro-fuzzy com computação paralela e distribuída, buscando acelerar o processo de treinamento das redes e também a construção sistemas híbridos com a utilização de redes especialistas.

Da mesma forma, também é bastante interessante dar continuidade a pesquisas voltadas para o uso de técnicas de inteligência computacional como a utilização de Redes de Funções de Base Radial (RBF – Radial Basis Function Network), Sistemas *Neuro-fuzzy* Adaptativos, entre outros.

REFERÊNCIAS BIBLIOGRÁFICAS

- Abraham, A., 2001, Neuro Fuzzy Systems: State-of-the-Art Modeling Techniques, Proceedings of the 6th International Work-Conference on Artificial and Natural Neural Networks: connectionist Models of Neurons, Learning Processes and Artificial Intelligence-Part I, p.269-276.
- Abraham, A. e Nath, B., 2000, Evolutionary Design of Neuro-Fuzzy Systems – A Generic Framework, Proceedings of the 4th Japan – Australia joint Workshop on Intelligent and Evolutionary Systems, Japan.
- Abramowitz, M. e Stegun, I.A., 1970, Handbook of Mathematical Functions with Formulas, Graphs, and Mathematical Tables, Dover Publications Inc., New York.
- Altrock, C.V., 1996, Fuzzy Logic and NeuroFuzzy Applications in Business and Finance, New Jersey: Prentice Hall PTR.
- Alvarez Acevedo, N.I.; Roberty, N.C. e Silva Neto, A.J., 2002, A One-Dimensional Inverse Radiative Transfer Problem with Time-dependent Boundary Conditions. 4th International Conference on Inverse Problems in Engineering: Theory and Practice, Proc. Angra dos Reis, Brasil.
- Ballini, R. e Gomide, F., 2005, Índice de Igualdade e Aprendizado em Redes Neurofuzzy Recorrentes em Previsão de Séries Macroeconômicas, Revista da Sociedade Brasileira de Redes Neurais, Vol. 3, Nº. 1, pp. 08-18
- Bakirov, F.G., Zverev, G.N., Kashapov, R.S., e Shaikhutdinov, Z.G., 1986, Solution of Inverse Problems of Radiative Transport by Soot Particles of Complex Shapes, J., Engng. Phys., Vol.49, No.6, pp.921-925.
- Beck, J.V., Blackwell, B. e St. Clair Jr., C.R., 1985, Inverse Heat Conduction – Ill-Posed Problems, John Wiley & Sons, New York.
- Bedregal, B.R.C., Dimuro, G.P. e Costa, A.C.R., 2007, Hand Gesture Recognition in an Interval Fuzzy Approach, TEMA, Tend. Mat. Apl. Comput., 8, No. 1, 21-31.
- Bezdec, J.C., 1981, Pattern Recognition with Fuzzy Objective Function Algorithms, Plenum Press, New York.
- Bherenji H. R. and Khedkar P., 1992, Learning and Tuning Fuzzy Logic Controllers through Reinforcements, IEEE Transactions on Neural Networks, Vol (3), pp. 724-740.
- Biondi Neto, L. e Chiganer, L., 2000, Sistema Especialista Fuzzy no Diagnóstico de Falhas em Transformadores, Eletricidade Moderna, Nº 315, pp. 158-169.
- Biondi Neto, L., Coelho, P.H.G, Amaral, J.L.M., Mello, M.H.C.S., 2006, Minicurso de Sistema Especialista Nebuloso, Sobrapo, XXXVIII Simpósio Brasileiro de Pesquisa Operacional, Goiás.

- Bishop, C.M., 1995, *Neural Networks for Pattern Recognition*, Oxford University Press, Oxford, UK.
- Braga, J.P.; Almeida, M.B.; Braga, A.P.; Belchior, J.C., 2000, Hopfield Neural Network Model for Calculating the Potential Energy Function from Second Virial data. *Chemical Physics*, v. 260, n. (3), p. 347-352.
- Campos Velho, H.F., 2008, *Problemas Inversos em Pesquisa Espacial*, SBMAC, São José dos Campos, SP
- Castanho, M.J.P. 2007, Sistema Neuro-fuzzy para Prognóstico de Câncer de Próstata, *Biomatemática IMECC, Unicamp*, Vol. 17, PP 11-20.
- Castro, C.L., Braga, A.P. e Andrade, A.V., 2003, Aplicação de um Modelo Ensemble de Redes Neurais Artificiais para Previsão de Séries Temporais não Estacionárias, *Anais do XXV Congresso da Sociedade Brasileira de Computação*, São Leopoldo, Brasil, pp 722-731.
- Cazes, T.B., Feitosa, R.Q. e Rego, L.F.G., 2007, Incorporação de Conhecimento do Especialista através de Regras para a Classificação de Imagens de Sensores Remotos de alta resolução, *XIII Simpósio Brasileiro de Sensoriamento Remoto*, Florianópolis, Brasil, pp 5659-5666.
- Chandrasekhar, S., 1950, *Radiative Transfer*, Oxford University Press.
- Ciaramella, A., Tagliaferri, R., Pedrycz, W. e Di Nola, A., 2006, Fuzzy Relational Neural Network, *International Journal of Approximate Reasoning*, Vol. 41, pp 146–163.
- Cox, E., 1995, *Fuzzy Logic for Business and Industry*. Massachusetts: Charles River Media Inc.
- Das, S.K., Chiang C.-W. e Nee, J.-B., 2009, Characteristics of Cirrus Clouds and its Radiative Properties Based on Lidar Observation over Chung-Li, Taiwan, *Atmospheric Research*, Vol. 93, pp 723–735.
- Demuth, H. e Beale, M., 2002, *User's Guide for Use with Matlab*, version 4, Mathworks.
- Duda, R., Hart, P.E. e Stork, D.G., 2001, *Pattern Classification*. New York:Wiley.
- Engl, H.W., Hanke, M. and Neubauer, A., 1996, *Regularization of Inverse Problems: Mathematics and its Applications*, vol. 375, Kluwer Academic Publishers.
- Fukshansky-Kazarinova, N., Fukshansky, L., Kühl, M. e Jorgensen, B.B., 1998, Solution of the Inverse Problem of Radiative Transfer on the Basis of Measured Internal Fluxes, *Journal of Quantitative Spectroscopy and Radiative Transfer* 59(1/2), 77–89.

- Fukshansky, L., Fukshansky-Kasarinova, N. e Remisowsky, A.M., 1991, Estimation of Optical Parameters in a Living Tissue by Solving the Inverse Problem of the Multiflux Radiative Transfer, *Appl. Optics*, Vol.30, No.22, pp.3145-3153.
- Gagliardi, R.L., 2010, Aplicação de Inteligência Computacional para a Solução de Problemas Inversos de Transferência Radiativa em Meios Participantes Unidimensionais, Dissertação de Mestrado, UERJ, Rio de Janeiro.
- Gil, M.C.C., 2005, Aplicação de Redes Neurais Artificiais na Restauração de Imagens Obtidas com Microscópios de Força Atômica, Dissertação de Mestrado, IPRJ-UERJ, Nova Friburgo.
- Gil, M.C.C., Silva Neto, A.J., Biondi Neto, L. e Soeiro, F.J.C.P., 2009a, On the Use of Hybrid Neuro-Fuzzy Systems for the Solution of Inverse Radiative Transfer Problems, *Anais do 20th International Congress of Mechanical Engineering*, Gramado, RS.
- Gil, M.C.C., Silva Neto, A.J., Biondi Neto, L. e Soeiro, F.J.C.P., 2009b, Estimation of the Diffuse Reflectivity Boundary Surfaces in One-dimensional Participating Media with Neuro-fuzzy Networks Committee, *Anais do 30º Congresso Ibero-Latino-Americano de Métodos Computacionais em Engenharia*, Armação de Búzios, RJ.
- Gil, M.C.C., Silva Neto, A.J., Biondi Neto, L. e Soeiro, F.J.C.P., 2008a, Determinação do Albedo de Espalhamento Simples em um Meio Participante Homogêneo Unidimensional através de Redes Neuro-fuzzy, *Anais do V Congresso Nacional de Engenharia Mecânica*, Salvador.
- Gil, M.C.C., Silva Neto, A.J., Biondi Neto, L. e Soeiro, F.J.C.P., 2008b, Determinação da Espessura Ótica de um Meio Participante Homogêneo Unidimensional através de Redes Neuro-fuzzy, *Anais do XL Simpósio Brasileiro de Pesquisa Operacional*, João Pessoa.
- Gil, M.C.C., Silva Neto, A.J., Biondi Neto, L. e Soeiro, F.J.C.P., 2008c, Aplicação de um Método de Comitês de Redes Neuro-fuzzy Combinado com Redes Neurais Artificiais em Cascata para a Solução de Problemas Inversos em Transferência Radiativa, *Anais do XI Encontro de Modelagem Computacional*, CD-ROM, Volta Redonda, ISBN 978-85-228-0487-0.
- Haber, R.E., Alique, J.R., Alique, A. e Haber, R.H., 2005, Controlling a Complex Electromechanical Process on the Basis of a Neurofuzzy Approach, *Future Generation Computer Systems*, Vol 21, pp 1083–1095.
- Hassoun, M., H., 1995, *Fundamentals of Artificial Neural Networks*, MIT Press.
- Haykin, S., 2001, *Redes Neurais: Princípios e Prática*, 2.ed, Porto alegre: Bookman.
- Hopfield, J.J., 1982, Neural Networks and Physical Systems with Emergent Collective Computational Abilities, *Proceedings of the National Academy of Sciences*, Vol. 79, pp. 2554-2558.

- Issamoto, E.; Miki, F.T.; Luz J.I.; Silva J.D.; Oliveira P.B.; Velho H.F.C., 1999, An Inverse Initial Condition Problem in Heat Conductions: A Neural Network Approach. In: Brazilian Congress on Mechanical Engineering (COBEM), 22-26, Campinas (SP), Brasil, 238.
- Jang, J.S.R., 1993, ANFIS: Adaptive-Network-Based Fuzzy Inference System, IEEE Transactions on Systems, Man, and Cybernetics, Vol.23, No.3, pp.665-685.
- Jang, J.S.R., 1992, Neuro-Fuzzy Modeling: Architectures, Analyses and Applications, PhD Thesis, University of California, Berkeley, USA.
- Jang, J.S.R., Sun, C.T. e Mizutani, E., 1997, Neuro-Fuzzy and Soft Computing: a Computational Approach to Learning and Machine Intelligence, Prentice Hall, New Jersey.
- Kauati, A.T., Roberty, N.C. e Silva Neto, A.J., 1999, A Source Detector Methodology for the Construction and Solution of the One-dimensional Inverse Transport Equation, in Proc. 3rd International Conference on Inverse Problems in Engineering: Theory and Practice, Port Ludlow, USA.
- Kauati, A.T., Roberty, N.C. e Silva Neto, A.J., 2000, Uso da Técnica Fonte-Detector em Tomografia com Espalhamento Anisotrópico, Anais do XVII Congresso Brasileiro de Engenharia Biomédica, Florianópolis, Santa Catarina.
- Kaufmann, A.; Gupta, M. M., 1988 Fuzzy Mathematical Models in Engineering and Management Science. Amsterdam: Elsevier Science Publishers B.
- Knupp, D.C., Silva Neto, A.J. e Sacco, W.F., 2007, Radiative Properties Estimation Based on Sensivity Analysis, Anais do 19th International Congress of Mechanical Engineering- COBEM, Brasília, Brasil.
- Kohonen, T., 1997, Self-Organizing Maps, 2nd ed., New York, Springer.
- Kohonen, T., 1989, Self-Organization and Associative Memory, Berlin: Springer-Verlag
- Krejsa, J.; Woodbury K.A.; Ratliff, J. D.; Raudensky, M., 1999, Assessment of Strategies and Potential for Neural Networks in Inverse Heat Conduction Problem. Inverse Problem in Engineering, v. 7, n. 3, p. 197-213.
- Kruse, R., Gebhardt, J., Klawon, F., 1994, Foundations of Fuzzy Systems, Wiley, Chichester , pp. 26-32.
- Li, H.Y. e Yang, C.Y., 1997, A Genetic Algorithm for Inverse Radiation Problems, Int. J. Heat Mass Transfer 40(7), 1545–1549.
- Lii, C.C. e Özisik, M.N., 1973, Hemispherical Reflectivity an Transmissivity of an Absorbing, Isotropically Scattering Slab with a Reflecting Boundary, Int. J. Heat Mass Transfer 16, 685–690.

- Lugon, J., Pinheiro, R.P.F., Vasconcellos, J.F.V. e Silva Neto, A.J., 2002, Estudo de Sensibilidade Aplicado ao Problema Simultâneo de Difusão de Calor e Massa, in Anais do XXV Congresso Nacional de Matemática Aplicada e Computação Científica.
- Lugon, J., Silva Neto, A.J., Santana, C.C., 2009, A Hybrid Approach with Artificial Neural Networks, Levenberg–Marquardt and Simulated Annealing Methods for the Solution of Gas-liquid Adsorption Inverse Problems, *Inverse Probl. Sci. Eng.* 17 (1), 85–96
- Malhotra, R. e Malhotra, D., 2002, Differentiating between Good Credits and Bad Credits Using Neuro-fuzzy system, *European Journal of Operational Research*, v.136, iss. 1, p. 190-211.
- Meza, E. B. M., Souza, J. C.S., Schilling, M.T. e Coutto Filho, M. B., 2006, Utilização de um Modelo Neuro-fuzzy para a Localização de Defeitos em Sistemas de Potência, *Controle & Automação*, Vol.17, nº.1.
- Milandri, A., Asllanaj, F. and Jeandel, G., 2002, Determination of Radiative Properties of Fibrous Media by an Inverse Method – Comparison with the Mie Theory, *Journal of Quantitative Spectroscopy & Radiative Transfer*, Vol. 74, pp. 637-653.
- Minsky, M. e Papert, S., *Perceptrons*, 1969, MIT Press, Cambridge, M.A.
- Mobley, C.D., 1994, *Light and Water - Radiative Transfer in Natural Waters*, Academic Press, San Diego.
- Montero, R.F.C., Roberty, N. C. e Silva Neto, A. J., 1999, Natural Base Construction for Absorption Coefficient Estimation in Heterogeneous Participating Media with Divergent Beams, in Proc. 3rd International Conference on Inverse Problems in Engineering: Theory and Practice, Port Ludlow, USA.
- Montero, R.F.C., Roberty, N.C. e Silva Neto, A.J., 2001, Absorption Coefficient Estimation in Heterogeneous Media using a Domain Partition Consistent with Divergent Beams, *Inverse Problems in Engineering* 9, 587–617.
- Murat, Y.S., 2005, Comparison of Fuzzy Logic and Artificial Neural Networks Approaches in Vehicle Delay Modeling, *Transportation Research, Part C* 14, pp 316–334.
- Nauck, D., 1997, Neuro-fuzzy Systems: Review and Prospects, Proc. 5th European Congress on Intelligent Techniques and Soft Computing-EUFIT, Aachen, Germany.
- Nauck, D., 1994, A Fuzzy Perceptron as a Generic Model for Neuro-fuzzy Approaches, Proc. 2nd German GI-Worshop Fuzzy-System, Munich, Germany.
- Nauck, D. e Kruse, R., 1999a, Neuro-fuzzy for Function Approximation, *Fuzzy Sets and Systems*, v.101, n.2, p. 261-271.

- Nauck, D. e Kruse, R., 1999b, Design and Implementation of a Neuro-Fuzzy Data Analysis Tool in Java, Technische Universität Braunschweig, Institut für Betriebssysteme und Rechnerverbund Aufgabenstellung und Betreuung, Braunschweig, Germany.
- Nauck, D. e Kruse, R., 1997, Neuro-Fuzzy systems for Function Approximation, 4th International Workshop Fuzzy-Neuro Systems.
- Nauck, D. e Kruse, R., 1995, Nefclass – A Neuro-fuzzy Approach for the Classification of Data, Proc. ACM Symposium of Applied Computing, p 461-465, New York, ACM Press.
- Nauck, D e Nürnberg, A., 2005, The Evolution of Neuro-Fuzzy Systems, Annual Meeting of the North American Fuzzy Information Processing Society, Michigan, USA.
- Oliveira, R.C., Alvarez Acevedo, N.I., Silva Neto e A.J. e Biondi Neto, L., 2008, Aplicação da Técnica de Máquina de Comitê de Redes Neurais Artificiais para a Solução de Problemas Inversos em Transferência Radiativa, XI Encontro de Modelagem Computacional, Volta Redonda, CD-ROM, Volta Redonda. ISBN 978-85-228-0487-0
- Özisik, M.N., 1973, Radiative Heat Transfer and Interactions with Conduction and Convection, John Wiley Sons.
- Paiva, R. e Dourado, A., 2004, Interpretability and Learning in Neuro-fuzzy Systems, Fuzzy Sets and Systems, vol. 147, pp. 17-38.
- Pessoa Filho, J., 1998, Transferência de Calor em Meios Participantes. Série de Palestras de Modelagem Matemática & Métodos Numéricos, IME-USP.
- Pinheiro, R.P.F., Silva Neto, A.J. e Roberty, N.C., 2005, On the use of Bregman Distances for the Solution of Inverse Radiative Transfer Problems in One-Dimensional Participating Media, 5th International Conference on Inverse Problems in Engineering: Theory and Practice, Cambridge, UK.
- Qi, H., Ruan, L.M., Shi, M., An, W. e Tan, H.P., 2008, Application of Multi-phase Particle Swarm Optimization Technique to Inverse Radiation Problem, Journal of Quantitative Spectroscopy & Radiative Transfer , Vol. 109, pp. 476–493.
- Quadrelli, G., Tanscheit, R. e Vellasco, M.M., 2003, Neuro-Fuzzy Modelling and Control of Nonlinear Dynamic Systems, Revista da Sociedade Brasileira de Redes Neurais, Vo. 1, No. 1, pp. 1-9.
- Rodrigues Silva, V.S. e Thomé, A.C.G., 2007, Um Comitê de Redes Neurais para o Reconhecimento de Letras Manuscritas, Anais do XXVII Congresso da Sociedade Brasileira de Computação – SBC, Rio de Janeiro, RJ.
- Rosenblatt, F., 1962, Principles of Neurodynamics: Perceptrons and the Theory of Brain Mechanisms, Spartan, New York.

- Rumelhart, D.E., Hinton, G.E., e Williams, R.J., 1986, Learning Internal Representations by Error Propagation. *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, Volume 1, Chapter 8, pages 318-362. MIT Press, Cambridge, M.A.
- Sacco, W., Knupp, D., Luz, E., Silva Neto, A.J., Algoritmo de Colisão de Partículas (Particle Collision Algorithm). In: Silva Neto, A.J. e Becceneri, J.C., 2009 (em preparação), *Técnicas de Inteligência Computacional Inspiradas na Natureza – Aplicação em Problemas Inversos em Transferência Radiativa*, SBMAC.
- Sandri, S. e Correa, C., 1999, *Lógica Nebulosa*, Anais da V Escola de Redes Neurais. São José dos Campos, pp 073-090.
- Sangalli, A., 1998, *The Importance of Being Fuzzy and Other Insights from the Border between Math and Computers*, Princeton University Press.
- Schapire, R.E., A Brief Introduction to Boosting, (1999), *Proceedings of the Sixteenth International Joint Conference on Artificial Intelligence*, p. 1-6.
- Siegel, R. e Howell, J.R., 1981, *Thermal Radiation Transfer*, Hemisphere Publishing Corporation
- Silva, L.A., 2005, *Classificação de Nódulos Mamográficos utilizando um Comitê de Redes Neurais Artificiais*, dissertação de mestrado, Escola Politécnica da Universidade de São Paulo.
- Silva Filho, S.R.L e Roisenberg, M., 2006, *An Application of a Committee Machine Architecture in the Users Authentication using Keystroke Dynamic*, Anais 6º Simpósio Brasileiro em Segurança da Informação e de Sistemas Computacionais – SBSEG-06, Santos, SP.
- Silva Neto, A.J., 2002, *Explicit and Implicit Formulations for Inverse Radiative Transfer problems*. In: *5th World Congress on Computational Mechanics, Mini-Symposium MS 125 - Computational Treatment of Inverse Problems in Mechanics*, Vienna, Austria.
- Silva Neto, A. J., 2007, *Problemas Inversos: Aplicações em Engenharia e Medicina*, em “Cápsulas de Ciência” (Moura Neto, F.D.), 57-86.
- Silva Neto, A.J. e Becceneri, J.C., 2009, *Técnicas de Inteligência Computacional Inspiradas na Natureza – Aplicação em Problemas Inversos em Transferência Radiativa*, SBMAC.
- Silva Neto, A.J. e McCormick, N.J., 2002, *An Explicit Formulation Based on the Moments of the Exit Radiation Intensity for the One-dimensional Inverse Radiative Heat Transfer Problem*, 4th International Conference on Inverse Problems in Engineering: Theory and Practice, Vol.II, pp.347-354, Angra dos Reis, Brasil.
- Silva Neto, A.J. e Moura Neto, F.D., 2005, *Problemas Inversos: Conceitos Fundamentais e Aplicações*, Ed. da Universidade do Rio de Janeiro, Rio de Janeiro.

- Silva Neto, A.J. e Özisik, M.N., 1993, An Inverse Problem of Estimating Thermal Conductivity, Optical Thickness, and Single Scattering Albedo of Semitransparent Medium, Proc. 1st International Conference on Inverse Problems in Engineering: Theory and Practice, Florida, USA, pp. 267–273.
- Silva Neto, A.J. e Özisik, M.N., 1995, An Inverse Problem of Simultaneous Estimation of Radiation Phase Function, Albedo and Optical Thickness, J. Quant. Spectrosc. Radiat. Transfer 53(4), 397–409.
- Silva Neto, A.J. e Soeiro, F.J.C.P., 2000, The solution of an Inverse Radiative Transfer Problem with the Simulated Annealing and Levenberg-Marquardt Methods, in Anais do Mini-Symposium on Inverse Problems in Medicine, Engineering and Geophysics, Santos, São Paulo, pp. 62–71.
- Silva Neto, A.J. e Soeiro, F.J.C.P., 2002, Estimation of the Phase Function of Anisotropic Scattering with a Combination of Gradient Based and Stochastic Global Optimization Methods, in Proc. 5th World Congress on Computational Mechanics, Viena, Austria.
- Silva Neto, A.J. e Soeiro, F.J.C.P., 2003, Solution of Implicitly Formulated Inverse Heat Transfer Problems with Hybrid Methods, in Mini-Symposium Inverse Problems from Thermal/ Fluids and Solid Mechanics Applications - 2nd MIT Conference on Computational Fluid and Solid Mechanics, Cambridge, EUA.
- Silva Neto, A.J. e Soeiro, F.J.C. P. , 2005, Inverse Problem of Space Dependent Albedo Estimation with Artificial Neural Networks and Hybrid Methods, 18th International Congress of Mechanical Engineering, ABCM, Ouro Preto, Brasil.
- Soeiro, F.J.C.P. e Silva Neto, A.J., 2006, Solution of Inverse Radiative Transfer Problems in Two-layer Media with Artificial Neural Networks, 14th Inverse Problems in Engineering Seminar, Ames, EUA.
- Soeiro, F.J.C.P., Soares, P.O. e Silva Neto, A.J., 2004, Solution of Inverse Radiative Transfer Problems with Artificial Neural Networks and Hybrid Methods, 13th Inverse Problems in Engineering Seminar, pp. 163-169, Cincinnati, EUA.
- Souto, R.P., Stephany, S., Becceneri, J.C., Campos Velho, H.F. e Silva Neto, A.J., 2005a, Reconstruction of Spatial Dependent Scattering Albedo in a Radiative Transfer Problem using a Hybrid ant Colony System Implementation and a Pre-Regularization Scheme, Proc. 6th World Congress on Structural and Multidisciplinary Optimization, Rio de Janeiro, Brasil.
- Souto, R.P., Stephany, S., Becceneri, J.C., Campos Velho, H.F. e Silva Neto, A.J., 2005b, On the Use of the Ant Colony System for Radiative Properties Estimation, in: Proceedings of the Fifth International Conference on Inverse Problems in Engineering: Theory and Practice, Cambridge, UK,.
- Stephany, S., Becceneri, J.C., Souto, R.P., Campos Velho, H.F., Silva Neto, A.J., 2010, A Pre-regularization Scheme for the Reconstruction of a Spatial Dependent

- Scattering Albedo using a Hybrid Ant Colony Optimization Implementation, *Applied Mathematical Modelling*, Vol. 34, pp 561–572
- Stutz, J.C.L., Gil, M.C.C., Biondi Neto, L. e Silva Neto, A.J. , 2006, Solução de Problemas Inversos em Transferência Radiativa com Redes Neurais Artificiais e Validação Cruzada, IX Encontro de Modelagem Computacional, CD-ROM, Belo Horizonte. ISBN 978-85-99836-02-6
- Takagi, T. e Sugeno, M., 1985, Fuzzy Identification of Systems and its Application to Modeling and Control, *IEEE, Trans. Syst., Man, Cybern.*, vol. SMC-15, pp. 116–132.
- Terano, T., Asia, K. e Sugeno, M., 1991, *Fuzzy Systems Theory and Its Applications*, Academic Press, San Diego, CA.
- Unbehauen, R., He, S. e Rei, K., 2000, Multilayer Neural Networks for Solving a Class of Partial Differential Equations, *Neural Networks*, n.13, pp.385-396.
- Vasconcellos, J.F.V., Silva Neto, A.J. e Santana, 2006, C.C., Estimativa do Coeficiente de Difusão e da Isotherma de Adsorção em Processos de Separação de Proteínas. *Boletim SBMAC*, v. VII, p. 139-156.
- Vieira, J., Dias, F.M. e Mota, A., 2004, Artificial Neural Networks and Neuro-fuzzy Systems for Modelling and Controlling Real Systems: a Comparative Study, *Engineering Applications of Artificial Intelligence*, Vol. 17, pp 265–273.
- Werbos, P., 1974, *Beyond regression: New Tools for Prediction and Analysis in the Behavioral Sciences*, Phd. thesis, Harvard University.
- Woodbury, K.A., 1998, *Neural Networks and Genetic Algorithms in the Solution of Inverse Problems*. Workshop on Novel Approaches for Inverse Problems, November, São José dos Campos.
- Xu, W., Wang, D., Zhou, Z., e Chen, H., 1997, Fault Diagnosis of Power Transformers: Application of Fuzzy Set Theory, Expert Systems and Artificial Neural Networks, *IEE Proceedings- Science, Measurement and Technology*, vol. 144, N° 1, pp. 39-44.
- Yang, H.T. e Liao C. C., 1999, Adaptive Fuzzy Diagnosis System for Dissolved Gas Analysis of Power Transformers, *IEEE Trans.Power Delivery*, vol. 14, N°4, pp. 1342-1350.
- Yazdi, H. S. e Pourreza, R., 2010, Unsupervised Adaptive Neural-fuzzy Inference System for Solving Differential Equations, *Applied Soft Computing*, Volume 10, Issue 1, pp 267-275.
- Yen, J.; Langari, R.; Zadeh, 1994, L. A. *Industrial Applications of Fuzzy Logic and Intelligent Systems*. New York: IEEE Press.

Yi, H. C., Sanchez, R. and McCormick, N. J. , 1992, Bioluminescence Estimation from Ocean in Situ Irradiances, *Appl. Optics*, Vol.31, No.6, pp.822-830.

Zadeh, L.A., 1965, Fuzzy Sets., *Information and Control*, 8:338-353.

Zadeh, L.A., 1968, Fuzzy Algorithms, *Info. & Ctl.*, Vol. 12, pp. 94-102.

Zadeh, L.A., 1973, *Outline of a New Approach to the Analysis of Complex Systems and Decision Processes.*

Zadeh, L.A., 1984, *Making Computers Think Like People*, IEEE. Spectrum, 8.

Zurada, J. M., 1992, *Introduction to Artificial Neural Systems*, West Publishing Company.

APÊNDICE A - ARQUITETURAS NEURO-FUZZY

Neste apêndice são listados os sistemas *neuro-fuzzy* NEFCON, NECLASS, NEFROX e ANFIS avaliados durante a elaboração desta tese.

A.1. Neuro-Fuzzy Control (NEFCON)

O sistema NEFCON (Nauck e Kruse, 1997) foi concebido para implementar um sistema de controle *fuzzy* tipo Mamdani. Os processos de otimização e aprendizado são baseados nas redes neurais artificiais, através uma mistura aprendizagem por reforço e *backpropagation*. O sistema NEFCON tem duas variantes: NEFPROX (para a aproximação função) e NEFCLASS (para tarefas de classificação).

A.2 Neuro Fuzzy Classification (NEFCLASS)

É um sistema *neuro-fuzzy* para classificação de padrões que deriva as regras *fuzzy* a partir dos dados e usa um algoritmo de aprendizagem supervisionado baseado na retropropagação do erro *fuzzy* (NAUCK e KRUSE, 1995).

Este sistema utiliza um modelo genérico de perceptron *fuzzy* (NAUCK, 1994) apresentando uma arquitetura similar á rede MLP de três camadas e permite a incorporação de conhecimento sobre o domínio do problema. Apenas os pesos, as entradas dos nós e as ativações dos nós de saída são modeladas como conjuntos *fuzzy* (NAUCK, 1997).

A.3 Neuro Fuzzy Function Approximation (NEFPROX)

Sistema utilizado para aproximação de funções contínuas baseada no sistema *Fuzzy* Mandani, derivado no NEFCLASS (NAUCK e KRUSE, 1999a e 1999b).

A.4 Adaptive Neuro Fuzzy Inference System (ANFIS)

É um modelo *neuro-fuzzy* que apresenta uma classe de redes adaptativas que são funcionalmente equivalentes a um sistema de inferência *fuzzy* (JANG et al., 1997; JANG, 1992).

Utilizando um conjunto de dados, se constrói um sistema de inferência *fuzzy* cujos parâmetros das funções de pertinência são ajustados através de um algoritmo retropropagação ou de um algoritmo de aprendizagem híbrida que combina a retropropagação e o método LSM (*Least Squares Method*) (MALHORTA e MALHORTA, 2002)

O sistema ANFIS implementa um sistema de inferência *fuzzy* tipo Takagi Sugeno (TAKAGI e SUGENO, 1985) com cinco camadas e possui uma arquitetura como mostrado na Fig. 4.5.

APÊNDICE B - ANÁLISE DE SENSIBILIDADE

Este apêndice complementa o estudo desenvolvido no Capítulo 5 sobre a análise de sensibilidade para os quatro Casos Teste definidos na Tabela 5.12, com a avaliação individual para cada um dos parâmetros estudados.

B.1 Análise de Sensibilidade - Caso Teste 3

Analisando-se a Fig. B.1, pode-se perceber que sensibilidade do parâmetro albedo de espalhamento simples ω é relativamente alta entre μ_{15} a μ_{20} ($\mu < 0$), i.e., os coeficientes de sensibilidade que apresentam os maiores valores estão contidos entre [0,5526 a 0,6880]. Entretanto, para $\mu > 0$ os valores dos coeficientes são muito baixos, quase que inexistente.

Com relação à Fig. B.2, pode-se observar que a região de maior sensibilidade do parâmetro espessura ótica τ_0 está situada no intervalo μ_{11} a μ_{16} , i.e., os coeficientes de sensibilidade que apresentam os maiores valores estão contidos entre [-0,2361 a -0,2050]. Para $\mu > 0$ os valores dos coeficientes são muito mais baixos.

Analisando a Fig. B.3 para reflectividade difusa ρ_1 , observa-se para $\mu < 0$ os coeficientes de sensibilidade apresentam valores maiores do que para $\mu > 0$.

Já para a reflectividade difusa ρ_2 , Fig. B.4, identifica-se um aumento nos valores dos coeficientes de sensibilidade tanto para $\mu < 0$ quanto para $\mu > 0$ com valores crescentes de $|\mu|$. As informações contidas entre μ_5 a μ_{10} são os valores dos coeficientes com maior relevância.




Figura B.1: Sensibilidade para o albedo de espalhamento simples ω (Caso Teste 3).




Figura B.2: Sensibilidade para a espessura ótica do meio τ_0 (Caso Teste 3).




Figura B.3: Sensibilidade para a reflectividade difusa ρ_1 (Caso Teste 3).




Figura B.4: Sensibilidade para a reflectividade difusa ρ_2 (Caso Teste 3).

B.2 Análise de Sensibilidade - Caso Teste 4

As áreas de sensibilidade significativamente mais altas para ω estão situadas entre μ_{15} a μ_{20} ($\mu < 0$). Para $\mu > 0$ os valores dos coeficientes de sensibilidade são muito baixos, quase que inexistentes.

Já para a espessura ótica τ_0 os valores dos coeficientes são relativamente altos para os menores valores de μ ($\mu < 0$), sendo que os melhores valores para serem utilizados são aqueles entre μ_{11} a μ_{16} . Para $\mu > 0$ os coeficientes de sensibilidade são praticamente constantes e desprezíveis para quaisquer valores de μ (vide Fig. B.6).

O mesmo acontece para os coeficientes de sensibilidade do parâmetro ρ_1 Fig. B.7 no que se refere tanto para $\mu < 0$ como também para $\mu > 0$.

As áreas mais sensíveis para o parâmetro ρ_2 apresentada na Fig. B.8 são aquelas cujos valores de $|\mu|$ (μ_{11} a μ_{16}) possuem os maiores valores.




Figura B.5: Sensibilidade para o albedo de espalhamento simples ω (Caso Teste 4).




Figura B.6: Sensibilidade para a espessura ótica do meio τ_0 (Caso Teste 4).




Figura B.7: Sensibilidade para a reflectividade difusa ρ_1 (Caso Teste 4).




Figura B.8: Sensibilidade para a reflectividade difusa ρ_2 (Caso Teste 4).

B.3 Análise de Sensibilidade - Caso Teste 5

Na Fig. B.9 para ω vê-se como áreas de maior sensibilidade conforme ocorre o aumento para $|\mu|$ tanto para $\mu < 0$ como para também para $\mu > 0$.

Pode-se perceber nas Figs. B.10 – B.12, para $\mu > 0$ possuem os valores com maior sensibilidade para os demais parâmetros τ_0 , ρ_1 e ρ_2 .




Figura B.9: Sensibilidade para o albedo de espalhamento simples ω (Caso Teste 5).




Figura B.10: Sensibilidade para a espessura ótica do meio τ_0 (Caso Teste 5).




Figura B.11: Sensibilidade para a reflectividade difusa ρ_1 (Caso Teste 5).




Figura B.12: Sensibilidade para a reflectividade difusa ρ_2 (Caso Teste 5).

B.4 Análise de Sensibilidade - Caso Teste 6

Analisando-se as Figs. B.13 e B.16 perceber que os valores dos coeficientes de sensibilidade dos parâmetros ω e ρ_1 possuem valores relativamente altos entre μ_{15} a μ_{20} ($\mu < 0$). Mas, para $\mu > 0$ possuem valores desses coeficientes muito baixos, quase que inexistentes.

Por outro lado, para os parâmetros τ_0 e ρ_2 Figs. B.14 e B.15, pode ser percebido que existe uma baixa sensibilidade em todas as direções, apesar dos valores dos coeficientes para $\mu > 0$ serem menores do que para $\mu < 0$.




Figura B.13: Sensibilidade para o albedo de espalhamento simples ω (Caso Teste 6).




Figura B.14: Sensibilidade para a espessura ótica do meio τ_0 (Caso Teste 6).




Figura B.15: Sensibilidade para a reflectividade difusa ρ_1 (Caso Teste 6).




Figura B.16: Sensibilidade para a reflectividade difusa ρ_2 (Caso Teste 6).

ANEXO I - SISTEMAS FUZZY

Este anexo ilustra a implementação dos sistemas *fuzzy* e as suas principais características.

I.1 Conjuntos Fuzzy

Conjunto de objetos com características comuns. Esses objetos possuem mais de uma maneira de se relacionarem ao conjunto, além de pertencer ou não pertencer a essa coleção.

Um Conjunto *Fuzzy* é caracterizado pela Função de Pertinência que mapeia os elementos de um domínio X para o intervalo [0,1].

Com o objetivo de caracterizar os conjuntos *Fuzzy* são formuladas as seguintes proposições:

- SE forem 14h30min horas, e SE ainda *não* almocei e SE tomei um *farto* café às 08h30min, ENTÃO eu estou com *pouca* fome.
- SE forem 16h30min horas, e SE almocei *muito pouco* às 12h00min e SE tomei um *pequeno* café da antes das 07h00min, ENTÃO eu estou com *muita* fome.
- SE forem 14h00min horas, e SE almocei *muito* às 13h00min horas e SE tomei café *normalmente* às 08h00min, ENTÃO eu estou com *muito pouca* fome.

A interpretação de “*farto, pouca, muita, pequeno, normalmente, muito pouca, etc*”, varia de pessoa para pessoa, não são valores exatos, embora todos saibam o seu significado. É importante salientar dentro do contexto das proposições apresentadas que: não ter almoçado é diferente de ter almoçado muito pouco, ter almoçado pouco, ter almoçado muito, ou simplesmente, ter almoçado normalmente.

Usando-se apenas os valores (0 e 1) para representar o grau de pertinência μ da variável na Lógica de Boole, isto é “ $\mu=0$ ”, não pertence ao conjunto e “ $\mu=1$ ” pertence ao conjunto é impossível representar essa variável, que apresenta graus de pertinência diversificados dentro do intervalo 0 e 1.

Uma variável que apresenta essas características é uma variável *Fuzzy* e pode apresentar valores μ , tais como: 0.2, 0.5, 0.8, 0.9, etc., dependendo de seu grau de pertinência no conjunto. A lógica que trata essas variáveis, dotadas de certo grau de incerteza, é denominada de Lógica *Fuzzy*, Lógica nebulosa ou Lógica Difusa. Na tradicional Lógica de Boole, quando um elemento pertence a um conjunto ele é dito "membro do conjunto", caso contrário não é "membro do conjunto" (BIONDI e CHIGANER, 2000; YANG e LIAO, 1999; XU et al., 1997).

Assim, conforme mostrado na Figura I.1, apenas para exemplificar que uma mudança abrupta em 100 °C de temperatura de "não alta para alta" é no mínimo contra o senso comum do pensamento humano e não deve ser tratada dessa forma.




Figura I.1: Representação da variável, usando-se álgebra de Boole

Por outro lado, usando-se a representação através da Lógica *Fuzzy* (Fig. I.2), uma temperatura pode pertencer a um ou mais conjuntos *fuzzy* com grau de pertinência diferente e entre 0 e 1, permitindo a representação completa da variável (lingüística). As variáveis linguísticas representam o conhecimento em inferência *Fuzzy*. As variáveis de entrada e saída de um sistema *fuzzy* são linguísticas. São variáveis para as quais os valores representam conjuntos *fuzzy*. Fornecem a caracterização aproximada do fenômeno (mal entendido, vago, inexato, incerto, etc...).




Figura I.2 – Representação da variável, usando-se Conjuntos Fuzzy

Os conjuntos *Fuzzy* possuem características específicas (JANG, 1992), cujas principais são:

- . Altura - É o maior grau de pertinência da função de pertinência;
- . Normalização - O conjunto *Fuzzy* está na Forma Normal Mínima se pelo menos um elemento possui “ $\mu(u)=1$ ”. O conjunto *Fuzzy* está na Forma Normal Máxima se pelo menos um elemento possui “ $\mu(u)=1$ ” e um elemento “ $\mu(u)=0$ ”;
- . Domínio - É o universo total de valores possíveis dos elementos do conjunto. Dependendo do contexto, o domínio pode ser aberto ou fechado e cresce monotonicamente da esquerda para direita;

Conjunto *Singleton*

É um conjunto *Fuzzy*, cujo suporte é definido como um único ponto $u \in U$ com pertinência $\mu(u = a) = 1$ e conhecido como Conjunto Unitário Fuzzy (*singleton*), mostrado na Fig. I.3. Representa o grau de pertinência 1 em um ponto (a) de seu domínio e grau 0 nos demais (ABRAHAM e NATH, 2000; BHERENJI e KHEDKAR, 1992). Simplifica os cálculos para produzir saídas *Fuzzy*, quando usado na entrada. Alguns autores, por sua peculiaridade não a classificam como um conjunto *Fuzzy*.




Figura I.3 – Conjunto Singleton

Conjunto α - CUT

É a restrição limite imposta ao domínio, baseada no valor de “ $\mu(u)$ ” de cada elemento, contendo todos os elementos do domínio que possuam “ $\mu(u)$ ” acima de certo valor de α .

I.2 Funções de pertinência

A Função de pertinência, função verdade ou *membership* de um conjunto *Fuzzy* representa as propriedades semânticas do conceito.

As principais funções de pertinência (JANG, 1992) são: linear; curva Z; sigmóide; *pi*; sino-beta; gaussiana; trapezoidal; triangular.

A função de pertinência Sino-Beta é mostrada na Fig. I.4 e obedece a Eq. (I.1). Dependendo do sinal de b a função aparece invertida.

$$f(x, a, b, c) = \frac{1}{1 + \left| \frac{x - c}{a} \right|^{2b}} \quad (\text{I.1})$$




Figura I.4 - Função de pertinência Sino-Beta

Funções de Pertinência 2D

Dada uma função de duas entradas, cada uma com seu universo de discurso próprio. A extensão Cilíndrica (JANG, 1993), representada na Figura I.5, é definida como:

Seja A um conjunto *Fuzzy* em X . Sua extensão cilíndrica em $(X \times Y)$ é um conjunto *Fuzzy* definido pela Eq. (I.2).

$$cil(A) = \int_{(X \times Y)} \mu_A(x)/(x, y) \quad (I.2)$$




Figura - I.5 - Extensão Cilíndrica de A

Seja P um conjunto *Fuzzy* de duas dimensões em $(X \times Y)$. Suas projeções, Fig. I.5, em X e Y são definidas pelas Eqs. (I.3) e (I.4).

$$P_x = \int_x \frac{[\max \mu_p(x, y)]}{x} \quad (I.3)$$

$$P_y = \int_y \frac{[\max \mu_p(x, y)]}{y} \quad (I.4)$$

Uma função de pertinência 2D, normalmente decorre de operações de MIN-AND- \cap ou MAX-OR- \cup . Quando esse resultado pode ser decomposto por duas funções analíticas de uma dimensão a função de pertinência 2D é denominada de composta.

Partindo-se então de duas funções em X e Y do tipo trapezoidal representadas na Fig. I.3 e aplicando-se os operadores clássicos de *Interseção* AND (MIN) e *União* OR (MAX) *Fuzzy* chega-se as funções de pertinência 2D mostradas na Figura I.6.

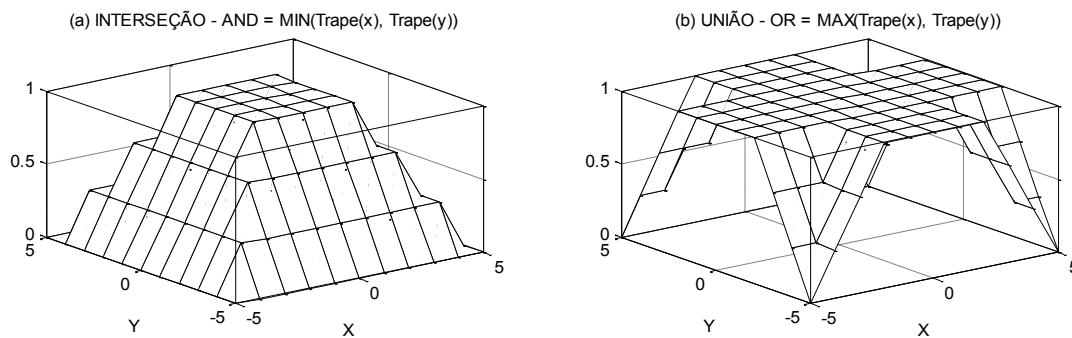


Figura I.6 – Extensão Cilíndrica 2D

Norma – T e Norma S (co-Norma T)

Norma T ou Norma Triangular é um tipo de operação binária usada em lógica multivalorada, especificamente em lógica *Fuzzy*. É uma operação algébrica sobre o intervalo $[0,1]$. Representa uma generalização para lógica *Fuzzy* da operação *conjunção lógica* (\wedge), que postula a verdade simultânea entre duas proposições. É usada para construir a *interseção* de conjuntos *Fuzzy*, ou como base de agregação de operadores (BIONDI et al., 2006; ABRAHAM e NATH, 2000; SANDRI e CORREA, 1999).

Por outro lado a Norma S é Dual (na ordem reversa de operação) da Norma T, isto é $1-x$ para x sobre o intervalo $[0,1]$. Logo, $S(a, b)=1-T(1-a, 1-b)$ e que generaliza a

lei de De Morgan. É uma generalização para lógica *Fuzzy* da operação *disjunção lógica* (\vee), que postula a verdade de uma ou de ambas as proposições. É usada para construir a *união* de conjuntos *Fuzzy*.

Axiomas da Interseção - Norma T

Seja, na forma binária, $T(x, y)$ uma função $T: [0,1] \times [0,1] \rightarrow [0,1]$, que satisfaz os axiomas abaixo para $\forall x, y, z, w \in [0,1]$, tal que:

- $T(0,0) = 0$ Condições limites
- $T(x, 0) = T(0, x) = 0$
- $T(x, 1) = T(1, x) = x$
- $T(x, y) = T(y, x)$ comutatividade
- $T[T(x, y), z] = T[x, T(y, z)]$ associabilidade
- $T(z, w) \leq T(x, y)$ se $z \leq x$ e $w \leq y$ monotonicidade crescente

Os principais operadores das normas T são: mínimo; produto algébrico; produto limitado e produto drástico, representados nas Eqs. (I.5) a (I.8).

$$\text{Mínimo} - T_{min}(x, y) = \text{Min}(x, y) = x \cap y = x \text{ AND } y \quad (\text{I.5})$$

$$\text{Produto Algébrico} - T_{PA}(x, y) = xy \quad (\text{I.6})$$

$$\text{Produto Limitado} - T_{PL}(x, y) = 0 \cup (x + y - 1) = 0 \text{ OR } (x + y - 1) \quad (\text{I.7})$$

$$\text{Produto Drástico} - T_{PD}(x, y) = \begin{cases} 0 & \text{se } x, y < 1 \\ x & \text{se } y = 1 \\ x & \text{se } a = 1 \end{cases} \quad (\text{I.8})$$

Axiomas da União – Norma S

Seja $S(x, y)$ uma função $S: [0,1] \times [0,1] \rightarrow [0,1]$, que satisfaz a $\forall \square x, y, z, w \in [0,1]$, tal que:

- $S(1,1) = 1$ limites
- $S(x, 0) = S(0, x) = x$
- $S(x, 1) = S(1, x) = 1$

- $S(x, y) = S(y, x)$ comutatividade
- $S[S(x, y), z] = S[x, S(y, z)]$ associatividade
- $S(z, w) \leq S(x, y)$ se $z \leq x$ e $w \leq y$ monotonicidade (crescente)

Os principais operadores das normas S são: máximo; soma algébrica; soma limitada; soma drástica, representados nas Eqs. (I.9) a (I.12).

$$\text{Máximo} - S_{max}(x, y) = Max(x, y) = x \cup y = x \text{ OR } y \quad (\text{I.9})$$

$$\text{Soma Algébrica} - S_{SA}(x, y) = x + y - xy \quad (\text{I.10})$$

$$\text{Soma Limitada} - S_{SL}(x, y) = 1 \cap (x + y) = 1 \text{ AND } (x + y) \quad (\text{I.11})$$

$$\text{Soma Drástica} - S_{SD}(x, y) = \begin{cases} 1 & \text{se } x, y > 0 \\ x & \text{se } y = 0 \\ y & \text{se } x = 0 \end{cases} \quad (\text{I.12})$$

Na Tabela I.1 algumas operações compensatórias funcionais usando-se norma T e norma S.

Tabela I.1 – Operações compensatórias funcionais

TIPO	INTERSEÇÃO Norma - T	UNIÃO Norma - S
ZADEH	$Min(\mu a[x] + \mu b[y])$	$Max(\mu a[x] + \mu b[y])$
MÉDIA	$(\mu a[x] + \mu b[y])/2$	$(2 * Min(\mu a[x] + \mu b[y]) + 4 * (Max(\mu a[x] + \mu b[y]))) / 6$
MÉDIA ²	$média^2$	$média^2$
MÉDIA ^{1/2}	$média^{1/2}$	$média^{1/2}$
PRODUTO	$(\mu a[x] * \mu b[y])$	$(\mu a[x] + \mu b[y]) - (\mu a[x] * \mu b[y])$
SOMA LIMITADA	$Max(0, \mu a[x] + \mu b[y] - 1)$	$Min(1, \mu a[x] + \mu b[y])$

I.3 Fuzzyficação

Inicialmente todas as variáveis de entrada e saída são adjetivadas transformando-se em variáveis linguísticas, representando dessa forma o espaço *Fuzzy* de entrada e saída. Os valores da variável representam sentenças em linguagem natural escritas usando-se predicados, como qualificadores e modificadores. A variável linguística envolve: Nome “simbólico”; Valores Linguísticos; Universo de Discurso; Domínio e Sintaxe e regras semânticas que explicam os valores linguísticos. Em lógica *Fuzzy* trabalha-se sempre com graus de pertinência, assim é necessário preparar o dado preciso da entradas, normalmente medidas realizadas no sistema que está sendo investigado, transformado-as da forma determinística (número) para forma *Fuzzy* (pertinência). Esse processo chama-se de Fuzzyficação.

Supondo-se que a variável temperatura faça parte do grupo de variáveis de entrada de certo sistema térmico tratado sob a ótica da lógica *Fuzzy*. Admita que sejam feitas várias medidas e que uma delas seja $T1 = 110\text{ }^{\circ}\text{C}$, representada na Fig. I.7. Conforme pode ser constatado analisando-se a mesma figura, $T1$ apresenta dois graus distintos de pertinência dependendo em que função de pertinência que mapeia os elementos de um domínio ele se encontra. Assim para o domínio relativo à temperatura alta o grau de pertinência é 0,38 e para temperatura normal 0,66. Dessa forma transforma-se a medida de $T1 = 110\text{ }^{\circ}\text{C}$ em dois graus de pertinência distintos, isto é procede-se a Fuzzificação.




Figura I.7 – Funções de pertinência para a variável temperatura.

I.4 Raciocínio Fuzzy

A metodologia de inferência utilizada para se chegar as conclusões é denominada de Raciocínio *Fuzzy*. Um conjunto de regras, do tipo Se ... Então ..., condicionais ou não, relacionam os antecedentes com os consequentes e são combinadas por operadores. Através do método de implicação a variável de saída é modelada.

O raciocínio *Fuzzy* que imita essa características do ser humano é realizado através da inferência, que permite tirar conclusões (*deduzir, concluir*) partindo de fatos conhecidos, realizado por operações (*Min-Max*).

Num sistema *Fuzzy* o conhecimento é representado através de *regras* ou proposições (Sandri e Correa, 1999). As regras são declarações que relacionam as variáveis do modelo com os conjuntos *Fuzzy*. As regras envolvem *antecedentes* e *consequentes*, nas quais o antecedente é composto por uma ou mais cláusulas ligadas pelos operadores AND, OR, NOT e o consequente representa a conclusão. Regra \equiv Antecedente + Consequente \equiv Condição + Ação. Apenas a título de exemplo é formulada a seguinte regra:

[Se a pressão arterial do indivíduo é alta e o indivíduo é velho e o indivíduo é fumante] então [o custo do plano de saúde é muito alto].

Assim as regras relacionam os *antecedentes* com os *consequentes* e podem ser condicionais e incondicionais. Um ponto importante está relacionado com a ordem de execução das regras. Para modelos com somente regras condicionais ou incondicionais, a ordem é irrelevante. Se o modelo contém ambos a ordem é importante dependendo se a regra incondicional é aplicada antes ou depois da condicional.

As regras incondicionais devem ser executadas antes, são geralmente usadas como *default* isto é, se nenhuma regra condicional é executada, então o valor da solução é determinado pela regra incondicional. Se nenhuma regra condicional possui um antecedente com força maior que a interseção máxima das regras incondicionais, as condicionais não contribuirão para a solução do modelo.

O particionamento do espaço de entrada indica a forma como as regras estão relacionadas com este espaço. Vamos imaginar a existência de quatro variáveis de entrada com três adjetivos cada o que envolve um total de $3^4 = 81$ regras.

É desejável que qualquer combinação das variáveis de entrada deva ativar pelo menos uma regra. Que duas ou mais regras com as mesmas entradas devam ter saídas mutuamente exclusivas, caso contrário as regras são inconsistentes e não devem existir regras vizinhas com saídas cujas funções de pertinência não apresentem interseção.

Inferência

A Inferência *Fuzzy* é o procedimento de avaliação das regras que relacionam as variáveis e que levam a conclusão final do sistema *Fuzzy*.

AND – Modelado como interseção através de norma-T.

OR – Modelado como união através de norma-S.

Esse procedimento é feito em duas fases: Avaliação da implicação de cada regra e a composição das conclusões de todas as regras em um valor consolidado. O método de Inferência *Fuzzy*, mais comumente usada é o Min-Max no qual o Min – usa-se a Norma –T e no Max usa-se a Norma – S.

Existem vários modelos de inferência *Fuzzy* cada um apresentando um conjunto distinto de características:

No sistema de inferência *Fuzzy Mamdani*, cuja regra é tipicamente representada por: Se x é A e y é B então z é C , na qual A e B são os conjuntos *Fuzzy* antecedentes e C os conjuntos *Fuzzy* consequentes, a saída precisa z é obtida pela defuzzificação do conjunto *Fuzzy* da saída resultante da aplicação da operação de norma S sobre os conjuntos consequentes que por sua vez, foram modificados via norma T pelo grau de disparo do antecedente.

No modelo de inferência *Fuzzy* denominado de *Sugeno* ou *Takagi-Sugeno* cuja regra é normalmente representada por: Se x é A e y é B então z é $f(x,y)$, a saída precisa z é dada pela combinação linear das entradas, representada por um polinômio $z = px_1 + qx_2 + r$. Se $p = q = 0 \dots z = r$, um *singleton*.

I.5 Defuzzyficação

Para certo conjunto de entradas, a ligação funcional entre a região *Fuzzy* da variável de saída e o valor esperado é denominado de método de “defuzzyficação”. Transforma a variável da forma *Fuzzy* (pertinência) em forma precisa (número).

Supondo-se um universo de discurso discreto, a saída precisa Z é dada pelo centro de área (centróide) do conjunto de consequente obtido pela composição das regras. Nesse caso m indica o número de quantização da saída, Z_i representa o valor da variável de saída para o intervalo de quantização i e $\mu_c(z_i)$ o grau de pertinência. Supondo-se um universo de discurso discreto, a saída precisa Z é dada pelo centro de gravidade do conjunto de consequente μ_c obtido pela composição das regras.

Assim, encontra o ponto de equilíbrio da região *Fuzzy* calculando a média ponderada das regiões (Jang e Sun, 1997), aplicando-se a Eq. (I.13).

$$Z = \frac{\sum_{i=0}^m \mu_c(z_i) * Z_i}{\sum_{i=0}^m \mu_c(z_i)} \quad (\text{I.13})$$

No caso *Takagi-Sugeno*, quando apenas *Singletons* são usados como consequentes das regras, combina-se o consequente das regras com o nível de disparo de cada uma delas, gerando a saída Z , aplicando-se a Eq. (I.14), na qual n é o número de regras; Z_i valor da *singleton* i e μ_i é o nível de disparo da regra.

$$Z = \frac{\sum_{i=1}^n \mu_i * Z_i}{\sum_{i=1}^n \mu_i} \quad (\text{I.14})$$

Livros Grátis

(<http://www.livrosgratis.com.br>)

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

[Baixar livros do Conselho Nacional de Educação - CNE](#)

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

[Baixar livros de Literatura](#)
[Baixar livros de Literatura de Cordel](#)
[Baixar livros de Literatura Infantil](#)
[Baixar livros de Matemática](#)
[Baixar livros de Medicina](#)
[Baixar livros de Medicina Veterinária](#)
[Baixar livros de Meio Ambiente](#)
[Baixar livros de Meteorologia](#)
[Baixar Monografias e TCC](#)
[Baixar livros Multidisciplinar](#)
[Baixar livros de Música](#)
[Baixar livros de Psicologia](#)
[Baixar livros de Química](#)
[Baixar livros de Saúde Coletiva](#)
[Baixar livros de Serviço Social](#)
[Baixar livros de Sociologia](#)
[Baixar livros de Teologia](#)
[Baixar livros de Trabalho](#)
[Baixar livros de Turismo](#)