



Ministério da  
**Ciência, Tecnologia  
e Inovação**



sid.inpe.br/mtc-m18/2014/02.04.12.41-TDI

## DESENVOLVIMENTO DE METODOLOGIAS PARA ESTIMATIVAS DE COBERTURA DE NUVENS

Eduardo Weide Luiz

Dissertação de Mestrado do Curso de Pós-Graduação em Meteorologia, orientada pelo Dr. Enio Bueno Pereira, aprovada em 19 de fevereiro de 2014.

URL do documento original:

<<http://urlib.net/8JMKD3MGP8W/3FMDJR5>>

INPE  
São José dos Campos  
2014

## **PUBLICADO POR:**

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GB)

Serviço de Informação e Documentação (SID)

Caixa Postal 515 - CEP 12.245-970

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/6921

Fax: (012) 3208-6919

E-mail: pubtc@sid.inpe.br

## **CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELLECTUAL DO INPE (RE/DIR-204):**

### **Presidente:**

Marciana Leite Ribeiro - Serviço de Informação e Documentação (SID)

### **Membros:**

Dr. Antonio Fernando Bertachini de Almeida Prado - Coordenação Engenharia e Tecnologia Espacial (ETE)

Dr<sup>a</sup> Inez Staciarini Batista - Coordenação Ciências Espaciais e Atmosféricas (CEA)

Dr. Gerald Jean Francis Banon - Coordenação Observação da Terra (OBT)

Dr. Germano de Souza Kienbaum - Centro de Tecnologias Especiais (CTE)

Dr. Manoel Alonso Gan - Centro de Previsão de Tempo e Estudos Climáticos (CPT)

Dr<sup>a</sup> Maria do Carmo de Andrade Nono - Conselho de Pós-Graduação

Dr. Plínio Carlos Alvalá - Centro de Ciência do Sistema Terrestre (CST)

### **BIBLIOTECA DIGITAL:**

Dr. Gerald Jean Francis Banon - Coordenação de Observação da Terra (OBT)

### **REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:**

Marciana Leite Ribeiro - Serviço de Informação e Documentação (SID)

Yolanda Ribeiro da Silva Souza - Serviço de Informação e Documentação (SID)

### **EDITORAÇÃO ELETRÔNICA:**

Maria Tereza Smith de Brito - Serviço de Informação e Documentação (SID)

André Luis Dias Fernandes - Serviço de Informação e Documentação (SID)



Ministério da  
**Ciência, Tecnologia  
e Inovação**



sid.inpe.br/mtc-m18/2014/02.04.12.41-TDI

## DESENVOLVIMENTO DE METODOLOGIAS PARA ESTIMATIVAS DE COBERTURA DE NUVENS

Eduardo Weide Luiz

Dissertação de Mestrado do Curso de Pós-Graduação em Meteorologia, orientada pelo Dr. Enio Bueno Pereira, aprovada em 19 de fevereiro de 2014.

URL do documento original:

<<http://urlib.net/8JMKD3MGP8W/3FMDJR5>>

INPE  
São José dos Campos  
2014

Dados Internacionais de Catalogação na Publicação (CIP)

---

Luiz, Eduardo Weide.

L968d      Desenvolvimento de metodologias para estimativas de cobertura de nuvens / Eduardo Weide Luiz. – São José dos Campos : INPE, 2014.

xx + 74 p. ; (sid.inpe.br/mtc-m18/2014/02.04.12.41-TDI)

Dissertação (Mestrado em Meteorologia) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2014.

Orientador : Dr. Enio Bueno Pereira.

1. radiação de onda longa. 2. nebulosidade. 3. redes neurais artificiais. I.Título.

CDU 551.576

---



Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).

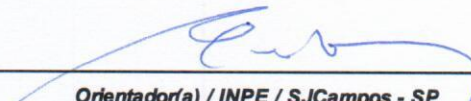
Aprovado (a) pela Banca Examinadora  
em cumprimento ao requisito exigido para  
obtenção do Título de **Mestre** em  
**Meteorologia**

Dra. Maria Paulete Pereira Martins



**Presidente / INPE / São José dos Campos - SP**

Dr. Enio Bueno Pereira



**Orientador(a) / INPE / SJC Campos - SP**

Dr. Fernando Ramos Martins



**Convidado(a) / UNIFESP / Santos - SP**

**Este trabalho foi aprovado por:**

maioria simples

unanimidade

Aluno (a): **Eduardo Weide Luiz**

**São José dos Campos, 19 de Fevereiro de 2014**



## **AGRADECIMENTOS**

Gostaria de agradecer, primeiramente, a meus pais, Vanderlei e Rosane, e à minha irmã, Simone, pelo amor incondicional e apoio constante, tanto emocional quanto financeiro, pela compreensão de minha ausência e, principalmente, pelos esforços empreendidos com o objetivo de ajudar-me a superar as dificuldades que encontrei durante o transcurso do Mestrado.

Agradeço sinceramente ao Dr. Enio Bueno Pereira, meu orientador, e ao Dr. Fernando Ramos Martins, por todo o apoio e orientação necessários para que esta Dissertação estivesse concluída. Um grande agradecimento ao Dr. Nelson Jorge Schuch e todos os meus professores de graduação e pós-graduação que me incentivaram, apoiaram e compartilharam seu conhecimento comigo. Tudo isso, fundamental para meu amadurecimento, tanto em níveis acadêmicos quanto pessoais.

Agradeço aos colegas de mestrado, pela amizade e compartilhamento de conhecimentos ao longo do período de disciplinas. Agradeço, também, aos colegas do grupo de pesquisa, pela companhia diária e pela ajuda no desenvolvimento deste estudo.

Aos meus amigos que me apoiaram em todos os momentos. À minha namorada, Ielena, que aguentou junto comigo todos os momentos bons e conturbados que passei.

Ao Instituto Nacional de Pesquisas Espaciais – INPE, ao seu Centro de Previsão do Tempo e Estudos Climáticos – CPTEC e ao Centro de Ciências do Sistema Terrestre – CCST, e à Coordenação de Aperfeiçoamento Pessoal de Nível Superior – CAPES, pela oportunidade de estudo, disponibilização de infraestrutura e suporte financeiro.

Por fim, a todos que de alguma forma contribuíram para o cumprimento de mais esta etapa.





## RESUMO

O papel de cada componente do balanço de energia terrestre e sua correspondente influência no clima da Terra é a chave para entendermos o clima e sua variabilidade. Estimativas de quantidade de nuvens e altura da nuvem são de grande importância para modelagem do clima. Sob o ponto de vista aplicado, pode-se citar o importante papel que tais informações fornecem para o controle do tráfego aéreo. A presente pesquisa teve como objetivo desenvolver metodologias para estimar parâmetros de nebulosidade utilizando dados de irradiação de onda longa incidente na superfície juntamente com dados meteorológicos medidos em estações superfície em duas localidades, Brasília (DF) e Petrolina (PE). A primeira metodologia proposta emprega conceitos de física atmosférica para a estimativa da fração de cobertura de nuvens e apresentou comportamento similar à climatologia das localidades estudadas. O segundo método propõe a utilização de Redes Neurais Artificiais para a estimativa do Coeficiente de Cobertura Efetiva de Nuvens. O método apresentou boa correlação com as medições satelitais, com coeficientes de correlação de aproximadamente 0,9 e desvios MBE da ordem de  $10^{-4}$  e RMSE abaixo de 0,11 para ambas as localidades. Além disso, o método conseguiu avaliar bem as não linearidades da estimativa, quando comparado com métodos lineares como Regressão Linear Múltipla.



## DEVELOPMENT OF METHODOLOGIES FOR CLOUD COVER ESTIMATION

### ABSTRACT

The role of each component in the Earth's energy budget and its corresponding influence on Earth's climate is the key to understanding the climate and its variability. Cloud amount and height estimates are of great importance to climate modeling. From a more applied point of view, one can mention the importance of such information in air traffic control, among other applications. This research aimed at to develop methodologies to estimate cloudiness parameters using downward longwave irradiation data along with meteorological data measured at surface stations in two locations, Brasília (DF) and Petrolina (PE). The first proposed methodology employs concepts of the physics of the atmosphere to estimate the cloud cover fraction showing similar behavior with the climatology in both sites. The second method uses artificial neural networks techniques to estimate the Effective Cloud Cover Index. The method presented a good correlation with the satellite measurements, with correlation coefficients of about 0.9 and MBE deviations of  $10^{-4}$  and RMSE below 0.11 for both locations. In addition, the method could evaluate the estimates nonlinearities, when compared with linear methods such as multiple linear regression.



## LISTA DE FIGURAS

	Pág.
Figura 2.1 – Radiação de corpo negro emitida pelo Sol e pela Terra. ....	4
Figura 2.2 - Espectro Eletromagnético. ....	4
Figura 2.3 - Interação da radiação solar com a atmosfera terrestre. ....	5
Figura 2.4 - Espectros da radiação solar no topo da atmosfera e incidente na superfície terrestre, ao nível do mar, com o espectro de emissão de um corpo negro a 6000 K. ...	6
Figura 2.5 - Interação da energia emitida pela Terra com a atmosfera terrestre. ....	7
Figura 3.1 – Esquema representando os tipos básicos de nuvens, a altura de suas bases e seus desenvolvimentos verticais. ....	12
Figura 4.1 - Representação gráfica de uma RNA do tipo MLP com duas camadas intermediárias. ....	19
Figura 4.2 - Modelo de um Neurônio Artificial de uma rede MLP. ....	20
Figura 4.3 - Representação gráfica de diferentes funções de ativação: (a) função degrau; (b) função linear; (c) função logística; (d) função tangente hiperbólica. ....	21
Figura 5.1 - Mapa de estações da Rede SONDA espalhadas pelo território brasileiro com destaque em cor preta nas estações utilizadas nesse estudo. ....	32
Figura 5.2 – Exemplos de dia de céu claro (lado esquerdo) e céu com variação de nebulosidade (lado direito). ....	35
Figura 5.3 - Desvio da função encontrada com os dados destinados para a validação para Brasília (lado esquerdo) e Petrolina (lado direito). ....	36
Figura 5.4 - dispersões entre os dados destinados para a validação das emissividades de céu claro medidas e estimadas para Brasília (lado esquerdo) e Petrolina (lado direito). ....	36
Figura 5.5 – Gráfico relacionando o número de ocorrências de cada classe da radiação visível medida pelo satélite durante janeiro de 2011, no horário 12:30 GMT, sobre a área centrada nas coordenadas geográficas da estação SONDA de Petrolina. ....	37
Figura 6.1 – Comparação entre as médias mensais da Fração de Cobertura de Nuvens Estimada, para todo o período de estudo, em Brasília, com a Normal Climatológica. ....	44
Figura 6.2 – Comparação entre as médias mensais da Fração de Cobertura de Nuvens Estimada dos anos de 2008 a 2012, com a Normal Climatológica, em Petrolina (PE). ....	44
Figura 6.3 – Comparação entre a fração de cobertura de nuvens mensal média estimada e a normal da radiação solar global do período de 1968 a 2009 em Petrolina. ....	46
Figura 6.4 – Dispersão entre as medidas da Fração de Cobertura de Nuvens e o Coeficiente de Cobertura Efetiva de Nuvens para os meses de janeiro de 2012 (esquerda) e maio de 2012 (direita) em Brasília. ....	47
Figura 6.5 – Dispersão entre as medidas da Fração de Cobertura de Nuvens e o Coeficiente de Cobertura Efetiva de Nuvens para os meses de janeiro de 2012 (esquerda) e maio de 2012 (direita) em Petrolina. ....	48
Figura 6.6 - Relação da média mensal do período de 2008 a 2012 do Coeficiente de Cobertura Efetiva de Nuvens com a média mensal da Fração de Cobertura de Nuvens estimada do mesmo período, para Brasília. ....	48

Figura 6.7 - Relação da média mensal do período de 2008 a 2012 do Coeficiente de Cobertura Efetiva de Nuvens com a média mensal da Fração de Cobertura de Nuvens estimada do mesmo período, para Petrolina.....	49
Figura 6.8 - Dispersão entre as medidas da Fração de Cobertura de Nuvens e o Coeficiente de Cobertura Efetiva de Nuvens para o mês de agosto de 2010 e 2011 em Brasília (DF).....	51
Figura 6.9 - Dispersão entre o Coeficiente de Cobertura Efetiva de Nuvens observado e estimado de Brasília no ano de 2011 utilizando Regressão Linear Múltipla. ....	56
Figura 6.10 – Dispersão entre o Coeficiente de Cobertura Efetiva de Nuvens observado e estimado em Brasília nos anos de 2008 e 2012. ....	57
Figura 6.11 – Dispersão entre o Coeficiente de Cobertura Efetiva de Nuvens observado e estimado em Petrolina nos anos de 2008 e 2012. ....	57
Figura A1 – Comparação entre as médias mensais da fração de cobertura de nuvens estimada dos anos de 2008 e 2009 e a normal climatológica em Brasília (DF).....	72
Figura A2 – Comparação entre as médias mensais da fração de cobertura de nuvens estimada dos anos de 2010 e 2011 e a normal climatológica em Brasília (DF).....	72
Figura A3 – Comparação entre as médias mensais da fração de cobertura de nuvens estimada de 2012 e a normal climatológica em Brasília (DF).....	73
Figura A4 – Comparação entre as médias mensais da fração de cobertura de nuvens estimada dos anos de 2008 e 2009 e a normal climatológica em Petrolina (PE). ....	73
Figura A5 – Comparação entre as médias mensais da fração de cobertura de nuvens estimada dos anos de 2008 e 2009 e a normal climatológica em Petrolina (PE). ....	74
Figura A6 – Comparação entre as médias mensais da fração de cobertura de nuvens estimada do ano de 2012 e a normal climatológica em Petrolina (PE).....	74

## LISTA DE TABELAS

	<b>Pág.</b>
Tabela 3.1 – Canais espectrais do radiômetro imageador dos satélites GOES.....	13
Tabela 5.1 - Equipamentos utilizados na medição das variáveis na estação da Rede SONDA de Brasília (DF) e de Petrolina (PE). .....	33
Tabela 5.2 - Média da radiação de onda longa de céu claro de 2008 a 2012, por intervalos de temperatura, em W/m <sup>2</sup> . .....	34
Tabela 5.3 - Novos valores encontrados para as constantes A e B. ....	35
Tabela 6.1 – Combinações de variáveis para serem utilizadas como entrada na Rede Neural Artificial de Brasília e Petrolina e seus respectivos Coeficientes de Correlação e Erros Quadráticos Médios.....	53
Tabela 6.2 - Resultados do treinamento de diferentes arquiteturas para as estações de Brasília e Petrolina. ....	55
Tabela 6.3 – Comparação do desempenho da Rede Neural Artificial com o da Regressão Linear Múltipla para as localidades estudadas. ....	58
Tabela 6.4 – Desempenho da RNA para o ano de 2011 dividido em período chuvoso e não chuvoso. ....	58





## LISTA DE SIGLAS E ABREVIATURAS

BRB - Brasília  
CCD - *Charged Coupled Device*  
DF - Distrito Federal  
GOES – *Geostationary Operational Environmental Satellite*  
INMET – Instituto Nacional de Meteorologia  
INPE – Instituto Nacional de Pesquisas Espaciais  
IPCC - *Intergovernmental Panel on Climate Change*  
IV – Infravermelho  
IR - *Infrared*  
LCL - *Lift Condensation Level*  
MLP - Perceptrons de Múltiplas Camadas  
OMM – Organização Meteorológica Mundial  
PE – Pernambuco  
PTR – Petrolina  
NASA – *National Aeronautics and Space Administration*  
RNA - Rede Neural Artificial  
RS - Rio Grande do Sul  
SONDA - Sistema de Organização Nacional de Dados Ambientais  
TSI – *Total Sky Imager*  
UV – Ultravioleta  
VIS – Visível

### Unidades de Medida

ft – Pés  
g/m<sup>3</sup> - Gramas por metro cúbico  
hPa - Hectopascal  
K - Kelvin  
kg – Quilograma  
km – Quilômetro  
ppm – Partes por milhão  
m – Metros  
nm – Nanômetros  
W/m<sup>2</sup> – Watts por metro quadrado  
Wm<sup>-2</sup> – Watts por metro quadrado  
Wm<sup>-2</sup>ano<sup>-1</sup> – Watts por metro quadrado por ano  
Wm<sup>-2</sup>década<sup>-1</sup> – Watts por metro quadrado por década  
Wm<sup>-2</sup>sr<sup>-1</sup> μm<sup>-1</sup> – Watts por metro quadrado por esferorradiano por micrometro  
μm – Micrometro  
°C – Graus centígrados



## LISTA DE SÍMBOLOS

$\alpha$  – Cosseno do Ângulo Zenital  
 $\sigma$  - Constanta de Stefan-Boltzmann ( $5,67 \cdot 10^{-8} \text{ Wm}^{-2}\text{K}^{-4}$ )  
 $\sigma_{vis}$  – Desvio padrão da radiância visível,  $\text{W/m}^2/\text{sr}$   
 $\theta_{sat}$  – Ângulo zenital do satélite, radianos  
 $\theta_{sol}$  – Ângulo zenital do Sol, radianos  
 $\theta$  - Temperatura Potencial  
 $\epsilon_{a(\text{cloudless})}$  - Emissividade do céu sem nuvens  
 $\rho_{wv}$  - Densidade do vapor d'água  
 $\Phi$  - Função de ativação  
 $A_c$  - Fração do céu coberta por nebulosidade  
 $C_{eff}$  - Coeficiente de Cobertura Efetiva de Nuvens  
 $e_a$  - Pressão de Vapor  
 $e_s$  - Pressão de Vapor de Saturação  
 $DJ$  – Dia Juliano  
 $H_c$  - Altura da base da nuvem  
 $K$  – Razão entre a Radiação Difusa e a Radiação no Topo da Atmosfera  
 $K_d$  – Razão entre a Radiação Difusa e a Radiação Global  
 $K_t$  - Razão entre a Radiação Global e a Radiação no Topo da Atmosfera  
 $L_{cld}$  -Radiância de céu encoberto  
 $L_{clr}$  - Radiância de céu claro  
 $L_r$  - Radiância medida pelo satélite no canal visível  
 $L_w$  – Radiação de Onda Longa Incidente na Superfície  
 $Min$  – Minuto do dia  
 $P$  - Pressão atmosférica em superfície  
 $P_c$  - Pressão atmosférica na base da nuvem  
 $R_{li(\text{total})}$  = Radiação de onda longa total que chega em superfície  
 $R_{lim}$  = Radiação de onda longa medida em superfície  
 $R_{li(\text{cloudless})}$  = Radiação de onda longa de céu claro em superfície  
 $r$  - Razão de mistura  
 $r_s$  - Razão de mistura de saturação  
 $T_a$  - Temperatura próxima a superfície  
 $T_c$  - Temperatura da base da nuvem  
 $v_j$  - Nível de atividade interna do neurônio  
 $W_i$  - Pesos das entradas da Rede Neural Artificial  
 $X_i$  - Entrada da Rede Neural Artificial  
 $y_j$  - Saída do neurônio  
UR – Umidade Relativa  
Z - Altura



## SUMÁRIO

1	INTRODUÇÃO.....	1
1.1.	Contexto e Justificativas .....	1
1.2.	Objetivos .....	2
2	RADIAÇÃO SOLAR.....	3
2.1.	Aspectos Gerais .....	3
2.2.	Interações entre a Radiação Solar e a Atmosfera Terrestre .....	4
2.3.	Onda Longa Descendente .....	7
3	COBERTURA DE NUVENS.....	11
3.1.	Aspectos Gerais .....	11
3.2.	Determinação da Cobertura de Nuvens por Satélites .....	12
3.3.	Cálculo da fração de cobertura de nuvens a partir de física atmosférica .....	14
4	REDES NEURAIS ARTIFICIAIS (RNAs).....	17
4.1.	Histórico .....	17
4.2.	Conceito e estrutura .....	18
4.3.	<i>Perceptrons</i> de Múltiplas Camadas .....	19
4.4.	Treinamento .....	22
4.4.1.	Algoritmo de Treinamento: <i>Backpropagation</i> (Retropropagação).....	25
4.4.2.	Algoritmo de treinamento: Levenberg-Marquardt .....	27
4.5.	Aplicações .....	28
5	DADOS E METODOLOGIA .....	31
5.1.	Dados Satelitais.....	31
5.2.	Dados Observados em Superfície .....	31
5.3.	Ajustes necessários para o cálculo da fração de cobertura de nuvens .....	33
5.3.1.	Radiação de Onda Longa Descendente de Céu Claro .....	33
5.3.2.	Emissividade de Céu Claro .....	34
5.4.	Determinação da Radiância em condição de Céu Claro .....	37
5.5.	Determinação da Radiância de Céu Encoberto.....	38
5.6.	Treinamento da Rede Neural Artificial .....	39
5.7.	Seleção dos preditores e escolha da estrutura da Rede Neural Artificial .....	40
5.8.	Avaliação dos resultados obtidos.....	41
6	RESULTADOS .....	43
6.1.	Fração de Cobertura de Nuvens.....	43

6.2.	Relação entre Fração de Cobertura de Nuvens e o Coeficiente de Cobertura Efetiva de Nuvens .....	46
6.3.	Influência dos aerossóis nas estimativas .....	50
6.4.	Procedimento de seleção de dados de entrada para a Rede Neural Artificial.....	51
6.5.	Procedimento para definição da arquitetura da Rede Neural Artificial.....	53
6.6.	Análise da estimativa do <i>Ceff</i> com uso de Redes Neurais Artificiais .....	56
7	CONCLUSÕES.....	59
8	TRABALHOS FUTUROS .....	61
	REFERÊNCIAS BIBLIOGRÁFICAS.....	63

# 1 INTRODUÇÃO

## 1.1. Contexto e Justificativas

O papel de cada componente do balanço de energia terrestre e sua correspondente influência no clima da Terra é a chave para se entender o clima e sua variabilidade. A maioria das transferências de energia entre o sistema climático e o espaço é realizada através de fluxos de radiação. Estimativas dos fluxos de radiação em superfície de alta confiabilidade são necessárias para quantificar as trocas de energia entre a atmosfera e a superfície. Investigações detalhadas sobre a influência de diversas condições atmosféricas sobre fluxos radiativos necessitam de uma distinção bem definida entre situações de céu claro e nublado (VIÚDEZ-MORA, 2011).

As nuvens na atmosfera ajudam a moderar a temperatura da Terra. O saldo dos forçantes das nuvens (efeito estufa e albedo) determina se uma classe de nuvens aquecerá ou resfriará a superfície. Nuvens altas e finas, como as do tipo *cirrus*, são semitransparentes em relação à radiação solar e opacas à radiação terrestre, tendendo a aquecer o planeta. Já nuvens baixas, como as *stratocumulus*, têm o efeito oposto, pois refletem a radiação solar. Nuvens convectivas profundas têm um efeito neutro (GRAHAN, 1999).

De acordo com Malek (1997), estimativas de quantidade e altura de nuvens são de grande importância para modelagem climática. Nuvens se formam quando a atmosfera se torna saturada, o que geralmente acontece através do resfriamento adiabático que ocorre quando as parcelas de ar sobem acima de seu nível de condensação por levantamento (LCL). Após sua formação, as nuvens aumentam o fluxo de radiação atmosférica incidente em superfície, pois complementam a radiação emitida pelo vapor de água e dióxido de carbono atmosféricos.

Diversos autores têm investigado a radiação de onda longa descendente (BRUTSAERT, 1975; KIMBAL et al., 1982; MALEK e BINGHAM, 1994) e têm

buscado maneiras de relacionar nebulosidade com a radiação de onda longa emitida pela atmosfera e pelas nuvens (MALEK, 1997; MARTY & PHILIPONA, 2000; ORSINI et al., 2002; DÜRR & PHILIPONA, 2004; VIÚDEZ-MORA, 2011).

Neste contexto, percebe-se que um melhor conhecimento das características da nebulosidade no planeta e sua relação com outras variáveis meteorológicas é de grande importância para entendermos o clima do planeta.

## **1.2. Objetivos**

A presente pesquisa tem como objetivo central desenvolver métodos para estimar parâmetros de nebulosidade utilizando dados observados de irradiação de onda longa incidente, juntamente com dados meteorológicos medidos em superfície, em duas localidades área-teste do Brasil: Brasília (DF) e Petrolina (PE).

Os objetivos específicos do trabalho são:

- Determinação da Fração de Cobertura de Nuvens utilizando um método físico proposto neste trabalho.
- Comparação da Fração de Cobertura de Nuvens com a climatologia de variáveis meteorológicas locais.
- Cálculo do Coeficiente de Cobertura Efetiva de Nuvens a partir de imagens de satélite para comparação com a Fração de Cobertura de Nuvens.
- Treinamento de uma Rede Neural Artificial para a estimativa do Coeficiente de Cobertura Efetiva de Nuvens utilizando Radiação de Onda Longa incidente em superfície e variáveis meteorológicas locais.



## **2 RADIAÇÃO SOLAR**

### **2.1. Aspectos Gerais**

De acordo com Liou (2002), a radiação eletromagnética é o principal mecanismo responsável pela transferência de energia na atmosfera, realizando praticamente toda a troca de energia entre o sistema Terra/Atmosfera e o Universo.

Segundo Lutgens e Tarbuck (2012), a radiação solar fornece 99,9 % da energia que aquece a Terra. Ao ser interceptada, cada comprimento de onda dessa radiação interage de forma diferente com os constituintes atmosféricos, através de complexos processos radiativos de absorção, espalhamento e emissão de radiação. Além disso, essa energia é utilizada para diferentes processos convectivos e condutivos que ocorrem no sistema Terra/Atmosfera.

O saldo de radiação disponível para estes processos depende da radiação solar recebida e perdida em ondas curtas e das entrada e saída da radiação de onda longa (emitida pela Terra). A Figura 2.1 apresenta a intensidade e os comprimentos de onda da radiação emitida pelo Sol e pela Terra. Segundo Peixoto e Oort (1992), apesar da radiação eletromagnética cobrir todo o espectro eletromagnético (Figura 2.2), a porção mais significativa, que está associada à transferência de energia no sistema climático, está compreendida entre o ultravioleta e o infravermelho.

A quantidade total média de radiação solar que atinge a órbita da Terra num plano perpendicular aos raios solares, no topo da atmosfera, é denominada de constante solar, cujo valor é de, aproximadamente,  $1366 \text{ W/m}^2$  (LIOU, 2002).

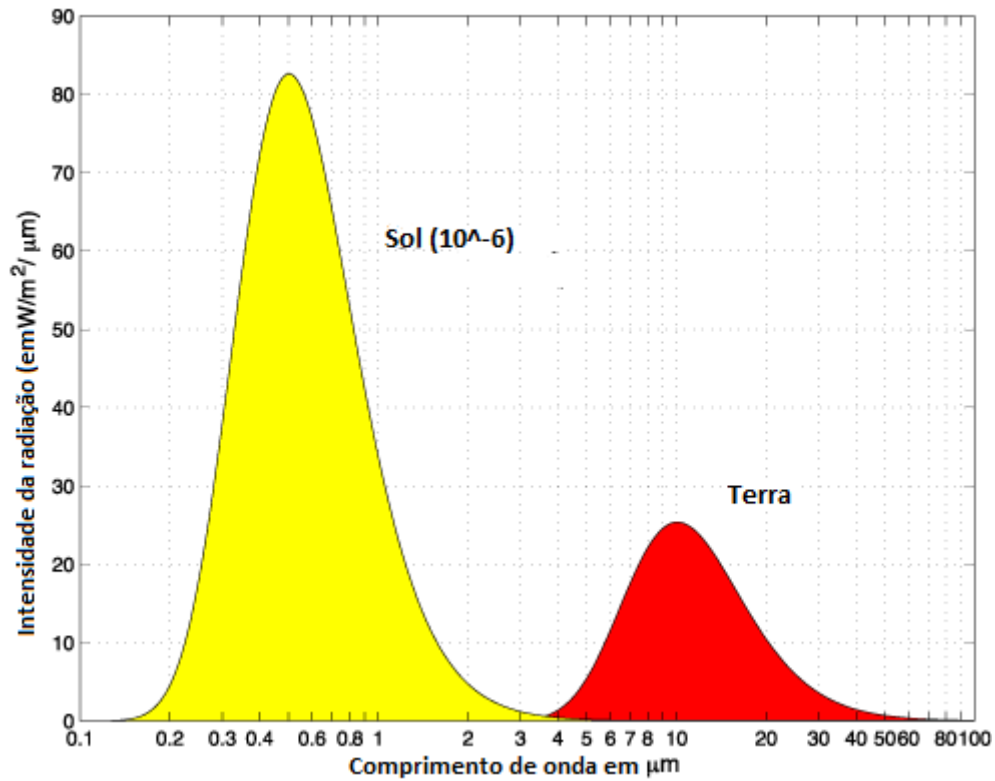


Figura 2.1 – Radiação de corpo negro emitida pelo Sol e pela Terra.  
 Fonte: Adaptado de Kushnir (2000).

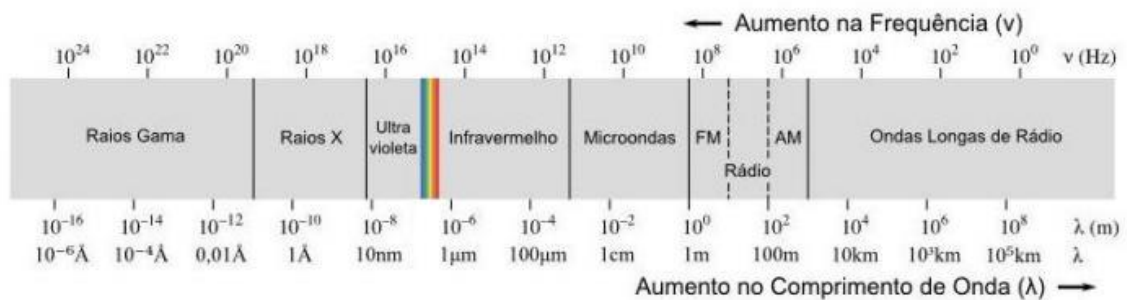


Figura 2.2 - Espectro Eletromagnético.  
 Fonte: Adaptado de Liou (2002).

## 2.2. Interações entre a Radiação Solar e a Atmosfera Terrestre

Mesmo a atmosfera sendo transparente em relação à radiação solar para vários comprimentos de onda, estima-se que apenas 25% da radiação incidente no topo da atmosfera cheguem à superfície terrestre sem sofrer nenhuma interação com os constituintes atmosféricos. Essa radiação que

chega a superfície sem sofrer interações é chamada de radiação solar direta. Os 75% restantes são absorvidos, refletidos em direção ao espaço ou espalhados. Desse montante, a radiação que chega à superfície, normalmente incidindo em uma direção diferente da direção inicial, é chamada de radiação solar difusa. Esses processos, ilustrados na Figura 2.3, dependem do comprimento de onda da radiação e do tamanho e natureza do particulado atmosférico ou da molécula do gás que interage com a radiação solar (LIOU, 2002; GUARNIERI, 2004; FIORIN, 2009).

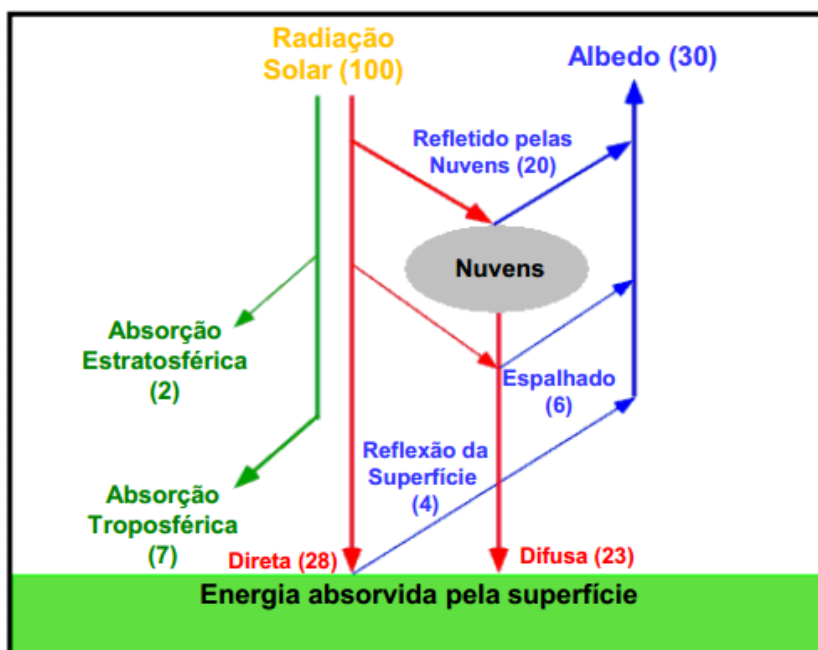


Figura 2.3 - Interação da radiação solar com a atmosfera terrestre.

Fonte: Adaptado de Pidwirny (2006).

O espectro da radiação solar incidente no topo da atmosfera, juntamente com o espectro da radiação solar que chega à superfície terrestre é apresentado na Figura 2.4. Segundo Liou (2002), as diferentes bandas de absorção de um gás em relação à radiação solar e a radiação terrestre são determinadas por suas características físico-químicas, associadas aos diferentes tipos de reações e processos fotoquímicos que as moléculas de gás podem sofrer. Na atmosfera a absorção é realizada principalmente pelo ozônio atmosférico na faixa de radiação ultravioleta, e por vapor d'água e dióxido de carbono no infravermelho próximo.

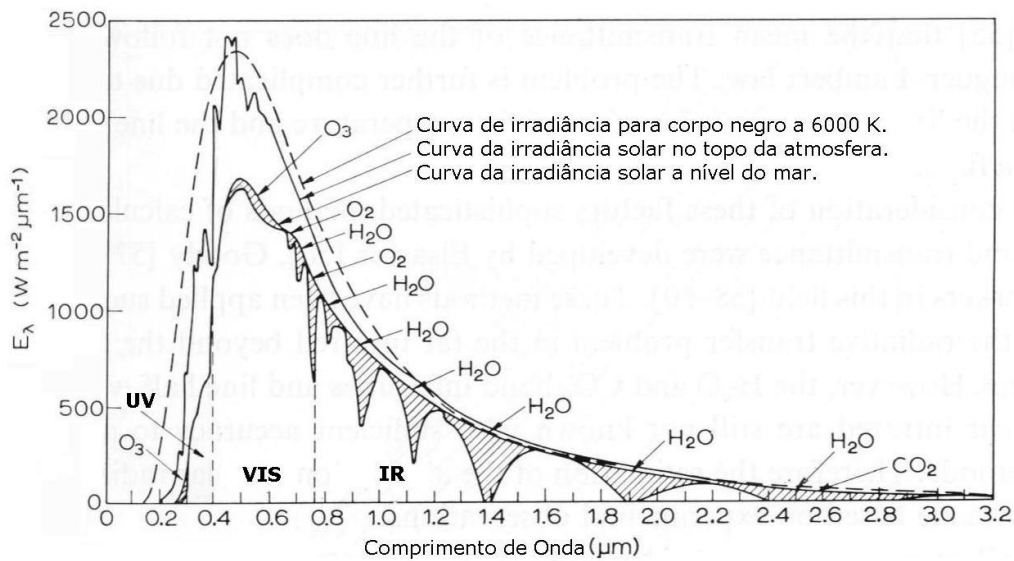


Figura 2.4 - Espectros da radiação solar no topo da atmosfera e incidente na superfície terrestre, ao nível do mar, com o espectro de emissão de um corpo negro a 6000 K.

Fonte: Adaptado de Robinson (1966), citado por Guarnieri (2006).

Já o espalhamento é causado principalmente pela interação entre a radiação solar e moléculas de ar, água e aerossóis. O espalhamento é um processo físico caracterizado pela remoção de energia da onda incidente pelas partículas ou moléculas de gases no seu caminho, dispersando essa energia em todas as direções. O regime de espalhamento é determinado a partir da razão entre o tamanho do espalhador e o comprimento de onda da radiação incidente, através da definição do termo físico chamado parâmetro de tamanho. Para partículas esféricas, o parâmetro de tamanho corresponde à razão entre a circunferência da partícula e o comprimento de onda da radiação ( $x = 2\pi r/\lambda$ ). O regime de espalhamento Rayleigh ocorre quando a partícula espalhadora é muito menor do que o comprimento de onda da radiação incidente ( $x \ll 1$ ), como é o caso do espalhamento da radiação visível realizado pelas moléculas de ar. Para partículas cujos tamanhos são comparáveis ou maiores do que o comprimento de onda da radiação ( $x \gtrsim 1$ ), predomina o espalhamento Lorenz-Mie (LIOU, 2002).

### 2.3. Onda Longa Descendente

A energia proveniente do Sol volta ao espaço a partir do sistema terrestre de duas maneiras: reflexão e emissão. Parte da energia solar que chega à Terra é espalhada pela superfície e atmosfera e refletida de volta ao espaço nos mesmos comprimentos de onda curta em que incidiram na superfície da Terra. A radiação solar absorvida pela Terra faz com que o planeta aqueça até que esteja emitindo tanta energia de volta para o espaço quanto está absorvendo. A Terra absorve uma fração da energia do Sol e emite de volta ao espaço radiação com menor energia, isto é, com comprimentos de onda maiores. Quando uma nuvem ou a atmosfera absorve radiação de onda longa emitida pela superfície da Terra, elas reemitem uma porção dessa energia em direção ao espaço e uma porção retorna à superfície. Essa radiação de onda longa que incide em superfície é chamada radiação de onda longa incidente na superfície (GRAHAN, 1999). Na Figura 2.5 encontra-se um esquema com a interação da radiação de onda longa com a superfície terrestre e a atmosfera.

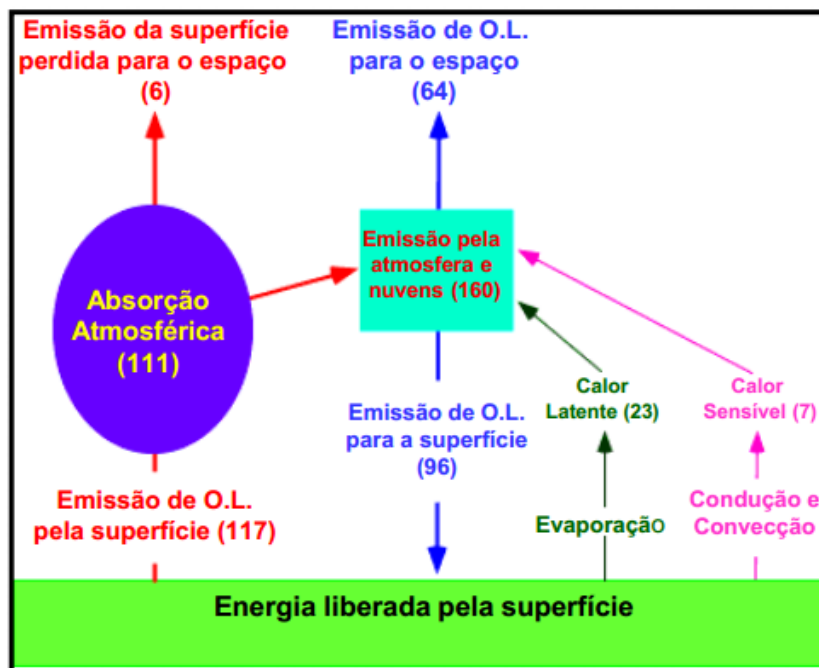


Figura 2.5 - Interação da energia emitida pela Terra com a atmosfera terrestre.

Fonte: Adaptado de Pidwirny (2006).

As medições e formulações da radiação de onda longa descendente continuam a ser uma tarefa de investigação de grande interesse para muitos cientistas. A radiação de onda longa está relacionada com fatores como a temperatura do ar, turbidez atmosférica, umidade atmosférica, nebulosidade, altura da nuvem e temperatura da base da nuvem. Vários métodos de estimativa da radiação atmosférica têm sido propostos usando essas variáveis (BRUNT, 1932; BRUTSAERT, 1975; AASE; IDSO, 1978; MONTEITH; UNSWORTH, 1990; WILD et al., 2001, KRUK et al., 2010).

A intensidade da emissão das nuvens varia diretamente com a sua temperatura e também depende de vários outros fatores, tais como a sua espessura, composição e distribuição de tamanhos das partículas. Mudanças na nebulosidade e nos tipos de nuvem irão desempenhar um papel importante na variabilidade do clima do planeta.

Para ser calculada a intensidade da emissão das nuvens, primeiramente precisa-se calcular a emissividade do céu sem nuvens que, de acordo com Brutsaert (1975), para regiões dos Estados Unidos ela pode ser determinada por:

$$\epsilon_{a(\text{cloudless})} = 1,24(e_a/T_a)^{1/7} = 0,58(\rho_{wv})^{1/7} \quad (2.1)$$

onde  $e_a$  é a pressão de vapor local em hPa,  $T_a$  é a temperatura em Kelvin e  $\rho_{wv}$  é a densidade do vapor d'água em g/m<sup>3</sup> dada por:

$$\rho_{wv} = 216.7 e_a/T_a \quad (2.2)$$

Kimball et al. (1982) indicou que a mesma emissividade, também, pode ser obtida por:

$$\epsilon_{a(\text{cloudless})} = 0,70 + 5,95 \cdot 10^{-4} \cdot e_a \cdot \exp(1500/T_a) \quad (2.3)$$

com  $e_a$  em kPa e  $T_a$  em K.

Malek e Bingham (1994) mostraram que a equação Brutsaert (1975) é mais confiável do que a de Kimball et al. (1982) para o cálculo da emissividade atmosférica do céu sem nuvens.

Monteith e Unsworth (1990) mostraram que a transmissão de radiação de onda longa,  $R_{li(total)}$ , a partir da camada abaixo da base da nuvem com temperatura da base da nuvem  $T_c$  para quaisquer condições de céu pode ser expressa como:

$$R_{li(total)} = \epsilon_{a(cloudless)} \cdot \sigma \cdot T_a^4 + A_c(1 - \epsilon_{a(cloudless)}) \cdot \sigma \cdot T_c^4 \quad (2.4)$$

$$R_{li(total)} = R_{li(cloudless)} + A_c(1 - \epsilon_{a(cloudless)}) \cdot \sigma \cdot T_c^4 \quad (2.5)$$

onde  $A_c$  é a fração do céu com nuvens,  $T_a$  é a temperatura do ar próximo a superfície,  $\epsilon_{a(cloudless)}$  é a emissividade do ar sem nebulosidade,  $\sigma$  é a constante de Boltzmann e  $R_{li(cloudless)}$  é a intensidade da radiação de onda longa incidente em superfície em condições de céu claro.

A intensidade da radiação de céu claro  $R_{li(cloudless)}$  é calculada a partir da Lei de Stefan-Boltzmann que estabelece que a energia radiada por um corpo por unidade de área é proporcional à quarta potência da sua temperatura, multiplicada por sua emissividade e pela constante de Boltzmann.





### **3 COBERTURA DE NUVENS**

#### **3.1. Aspectos Gerais**

De acordo com Ahrens (2009), as nuvens são compostas de agregados visíveis de gotículas de água e cristais de gelo em suspensão dispersas pela atmosfera com diferentes características (forma, textura, altura etc). O mecanismo básico que leva à formação das nuvens é a supersaturação do ar em relação à água líquida ou ao gelo, ocasionada normalmente, pela ascensão de parcelas de ar quente e úmido, acima de seu nível de condensação por levantamento (LCL). As parcelas resfriam ocasionando a condensação do vapor d'água presente nelas. (AHRENS, 2009; WALLACE; HOBBS, 2006).

A classificação de nuvens é estabelecida pelo Atlas Internacional de Nuvens, da Organização Meteorológica Mundial. Nele são definidos dez gêneros mutuamente exclusivos, associados às características observadas com maior frequência em superfície, que podem ser divididos em diferentes espécies de acordo com a altura de sua base. Além disso, os gêneros e espécies podem possuir diferentes variedades, levando em conta a transparência ou o arranjo macroscópico da nuvem (VAREJÃO-SILVA, 2006). Na figura 3.1 encontra-se um esquema representando os tipos básicos de nuvens, a altura de suas bases e seus desenvolvimentos verticais.

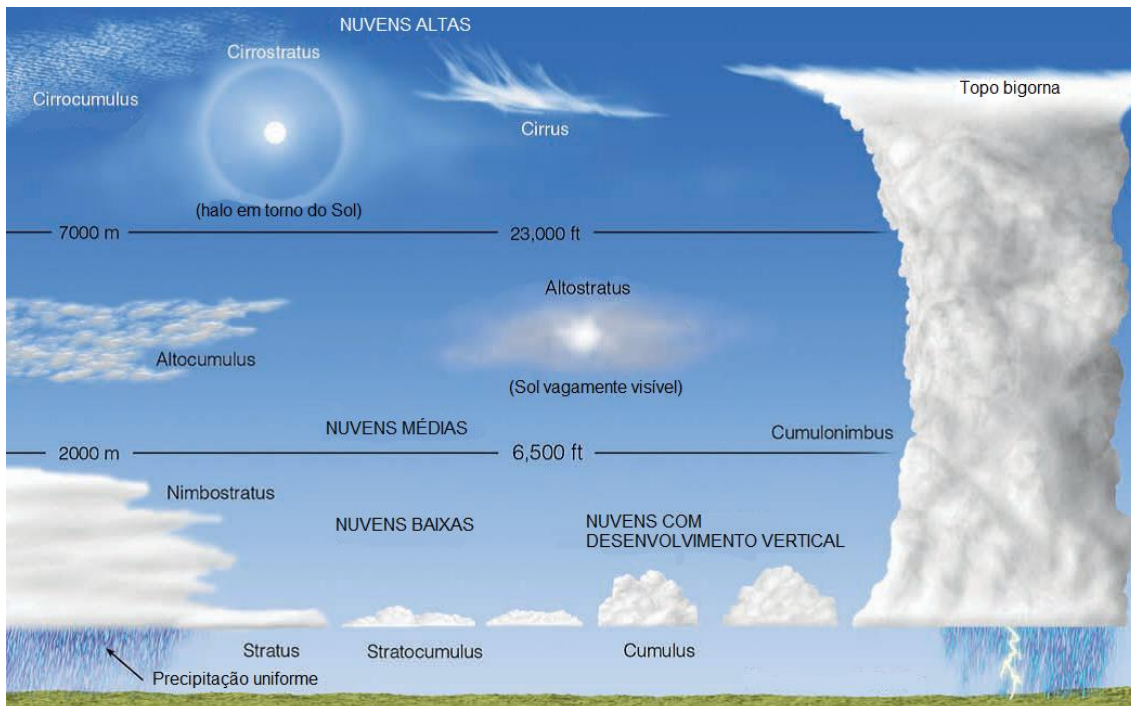


Figura 3.1 – Esquema representando os tipos básicos de nuvens, a altura de suas bases e seus desenvolvimentos verticais.

Fonte: Adaptado de Ahrens (2009).

### 3.2. Determinação da Cobertura de Nuvens por Satélites

De acordo com Martins (2003), tem-se aumentado a qualidade e o detalhamento das informações sobre a cobertura global de nuvens, assim como o papel fundamental que estas desempenham no balanço radiativo do planeta, com o uso de imagens de satélite.

Na detecção de nuvens existem dois tipos principais de satélites em relação às suas órbitas: satélites geoestacionários e satélites de órbita polar. Os satélites geoestacionários orbitam em torno da Terra a uma altura de aproximadamente 36 mil quilômetros, em uma órbita contendo o plano do Equador e se movendo à mesma velocidade angular de rotação da Terra, ou seja, se mantêm fixos em relação a um ponto da superfície terrestre. Já os satélites de órbita polar possuem órbitas perpendiculares ou inclinadas com relação ao Equador a uma baixa altitude (de cerca de 850 km) passando sobre os polos do planeta a cada revolução.

Os satélites GOES-8, GOES-10 e GOES-12 foram desenvolvidos para operar em órbitas geoestacionárias, a uma altitude de 35.790 km. Esses satélites levam a bordo inúmeros instrumentos, sendo que o sensor responsável pelo imageamento dos satélites opera em cinco canais espectrais, conforme a Tabela 3.1.

Tabela 3.1 – Canais espectrais do radiômetro imageador dos satélites GOES.

Sensor	Bandas Espectrais	Resolução Espectral	Resolução Espacial
<b>GOES I-M (Imager Radiometer)</b>	1 – Visível	0.55 - 0.75 $\mu\text{m}$	1 km
	2 - Ondas curtas	3.80 - 4.00 $\mu\text{m}$	4 km
	3 - Vapor d'água	6.50 - 7.00 $\mu\text{m}$	8 km
	4 - IR 1	10.20 - 11.20 $\mu\text{m}$	4 km
	5 - IR 2	11.50 - 12.50 $\mu\text{m}$	4 km

Fonte: Adaptado de NOAA (2013).

A banda do visível obtém informações a partir da energia proveniente do Sol e refletida pelos alvos operando somente durante o dia. Com essa banda pode-se observar nuvens, nevoeiros, presença de corpos de gelo sobre a superfície ou oceanos e o mapeamento de poluentes na atmosfera. A banda do infravermelho obtém informações da energia radiante dos alvos em direção à atmosfera, estando disponível tanto de dia quanto a noite. Com essas imagens podem-se obter variações da temperatura da Terra e dos oceanos, além da temperatura do topo das nuvens. Já a banda do vapor de água que é capaz de detectar o vapor de água presente nas camadas da atmosfera.

Segundo Martins (2003), a cobertura de nuvens pode ser determinada a partir da composição de imagens de céu claro ou encoberto para um período de interesse. Define-se se o Coeficiente de Cobertura Efetiva de Nuvens,  $C_{eff}$ , para cada pixel da imagem, de acordo com a Equação 3.1, em termos da radiância  $L_r$  medida pelo satélite no canal visível, e das radiâncias obtidas da composição de imagens de céu claro ( $L_{ctr}$ ) e encoberto ( $L_{cld}$ ). Conforme explica Martins et al. (2008), os valores de  $C_{eff}$  descrevem tanto a cobertura de nuvens quanto as variações espaciais da profundidade ótica das nuvens, assumindo os valores extremos de 1 para céu completamente encoberto e de zero para céu completamente desprovido de nebulosidade.

$$C_{eff} = (L_r - L_{clr}) / (L_{cld} - L_{clr}) \quad (3.1)$$

Muitos estudos foram realizados com o intuito de desenvolver métodos para estimar a radiância observada pelos satélites geoestacionários em condições de céu claro e encoberto (TARPLEY, 1979; SAUNDERS, 1986; GUTMAN et al., 1987; MATTHEWS e ROSSOW, 1987; SEZE e DESBOIS, 1987; MOUSSU et al., 1989; ROSSOW et al., 1989a,b; SIMPSON e GOBAT, 1995; MINIS e HARRISON, 1984a,b,c; MARTINS et al., 2003; CHEN et al., 2011). Esses métodos podem ser divididos em dois grupos, o primeiro agrupando as técnicas que estabelecem valores limiares para a detecção de nuvens, avaliando pixel a pixel das imagens de um ou mais canais espectrais, e outro se referindo às técnicas que analisam propriedades estatísticas das radiâncias visível e/ou infravermelha em grupos de píxeis ou segmentos de imagens (MARTINS, 2003; ECHER, 2005).

Entretanto, Martins (2001), citando a Sezes e Desbois (1987) e England e Hunt (1985), destaca que todas as técnicas apresentam problemas similares, como a dependência em relação às propriedades da superfície, a cobertura parcial de nuvens em um pixel e a presença de nuvens com emissividade variável.

### 3.3. Cálculo da fração de cobertura de nuvens a partir de física atmosférica

De acordo com Malek (1997), com a análise da Equação 2.5, sempre que a incidência de onda longa ( $R_{li(total)}$ ) é quase igual a  $R_{li(cloudless)}$ , um céu sem nuvens é implícito. Já quando  $R_{li(total)} > R_{li(cloudless)}$  as condições do céu podem ser de parcialmente nublado até nublado. Desta forma, a Equação 2.5 pode ser reescrita como:

$$A_c = (R_{lim} - R_{li(cloudless)}) / ((1 - \epsilon_{a(cloudless)}) \cdot \sigma \cdot T_c^4) \quad (3.2)$$

onde  $A_c$  é a fração do céu com nuvens,  $R_{lim}$  é a radiação de onda longa total medida em superfície ( $= R_{li(total)}$ ),  $T_c$  é a temperatura da base da nuvem,  $T_a$  é a temperatura do ar próximo a superfície,  $\epsilon_{a(cloudless)}$  é a emissividade do ar sem nebulosidade e  $\sigma$  é a constante de Boltzmann.

Segundo Malek (1997), para encontrar a temperatura da base da nuvem  $T_c$ , precisa-se calcular inicialmente a temperatura potencial da parcela de ar em superfície através da Equação de Poisson, dada pela Equação 3.3 abaixo.

$$\theta = (T_a + 273,16) \cdot (1013,25/P)^{0,286} \quad (3.3)$$

onde  $\theta$  é a temperatura potencial em Kelvin,  $T_a$  é a temperatura da superfície em °C e P é a pressão atmosférica na estação em hPa.

Como a temperatura potencial permanece constante durante a ascendência ou descendência da parcela de ar (quantidade conservativa), significa que quando o ar sobe ou desce, a sua temperatura e sua pressão variam de tal maneira que o valor de  $\theta$  continue inalterado. A pressão é relacionada com a altura (Z) de acordo com a Equação 3.4 e a altura da base da nuvem ( $H_c$ ) é dada pela Equação 3.5.

$$P = 1013,25[(288 - 0,01Z)/288]^{3,416} \quad (3.4)$$

$$H_c = Z - \textit{altitude local} \quad (3.5)$$

Outra quantidade conservativa da parcela de ar é a razão de mistura ( $r$ ), que é medida em kg de vapor de água por kg de ar seco, dada pela Equação (3.6) .

$$r = 0,622e_a/P \quad (3.6)$$

onde  $e_a$  é a pressão de vapor atual em hPa e P é a pressão atmosférica em hPa, sendo  $e_a$  dada por:

$$e_a = (UR/100)e_s \quad (3.7)$$

onde UR é a umidade relativa em superfície e  $e_s$  é a pressão de vapor de saturação dada por:

$$e_s = 6,1121 \exp[17,502T_a/(290,97 + T_a)] \quad (3.8)$$

onde  $T_a$  é a temperatura do ar próximo a superfície em °C.

Como a razão de mistura também se mantém constante durante a ascensão do ar, pode-se utilizar a Equação 3.6 juntamente com a Equação 3.8 para estimar o LCL, através da Equação 3.9 abaixo:

$$r_s = r = 3,802 \exp[17,502T_c/(240,97 + T_c)]/P_c \quad (3.9)$$

onde  $r_s$  é a razão de mistura de saturação,  $T_c$  é a temperatura na base da nuvem e  $P_c$  é a pressão da base da nuvem, ou no LCL.

De acordo com a regra de Normand (WALLACE e HOBBS,; MCLLVEEN, 1992 apud MALEK, 1997), num gráfico pseudoadiabático (diagrama termodinâmico), o nível de condensação por levantamento (LCL) de uma parcela de ar está localizado na intersecção da linha de temperatura potencial que passa através do ponto determinado pelo ponto de orvalho local e pressão do ar. Em outras palavras, as Equações 3.3 e 3.9 podem ser reescritas da seguinte forma, respectivamente:

$$P_c = (1013,25/\theta^{3,496})(T_c + 273,16)^{3,496} \quad (3.10)$$

e

$$P_c = (3,802/r) \exp[17,502T_c/(240,97 + T_c)] \quad (3.11)$$

Igualando as equações 3.10 e 3.11 tem-se:

$$\ln(T_c + 273,16) - 5,01T_c/(240,97 + T_c) + [\ln(266.645r/\theta^{3,496})]/3,496 = 0 \quad (3.12)$$

onde  $T_c$  é dado °C (único termo desconhecido),  $r$  em kg vapor d'água/kg de ar seco e  $\theta$  em Kelvin. Desta forma, resolvendo a Equação 3.12 para  $T_c$  (usando o método de tentativa e erro computacional) pode-se encontrar a fração do céu com nuvens e altura da base das nuvens e, assim, o tipo de nuvem (baixa, média ou alta). Com a temperatura da base da nuvem e o cálculo da fração de céu coberto por nuvens pode-se determinar as condições de céu (claro, com  $A_c < 5\%$ ; parcialmente nublado, com  $A_c$  entre 5 e 50%, quase nublado, com  $A_c$  entre 50 e 95%, e nublado,  $A_c > 95\%$  (KARNER e KEEVALLIK, 1993 apud MALEK, 1997).

## 4 REDES NEURAIS ARTIFICIAIS (RNAs)

### 4.1. Histórico

As redes neurais artificiais (RNAs) surgiram como uma ferramenta para representar uma relação entre um conjunto de variáveis de entrada e saída, até então desconhecida, a partir de um conjunto de dados de treinamento. McCulloch e Pitts (1943) introduziram o conceito, descrevendo um modelo simples de neurônio que teria  $n$  entradas  $X_i$  ajustadas por pesos  $W_i$  e comparadas a um valor limiar, avaliando se a sinapse é ou não ativada. Sua saída era, portanto, binária e este primeiro modelo apresentou diversas restrições em sua utilização.

Hebb (1949) mostrou que a plasticidade da aprendizagem de redes neurais é conseguida através da variação dos pesos das entradas dos neurônios. Ele propôs uma teoria para explicar o aprendizado em neurônios biológicos baseada nas ligações sinápticas entre neurônios excitados.

Rosenblatt (1958) introduziu o *perceptron*, um conjunto dos neurônios de McCulloch e Pitts, entretanto dotados de sinapses ajustáveis. Foi proposto um algoritmo para treinar a rede ajustando os pesos de acordo com a saída desejada. Por possuir pesos ajustáveis apenas na camada de saída, o modelo de Rosenblatt é tratado como *perceptron* de uma camada.

Widrow e Hoff (1960) desenvolveram o ADALINE (*ADaptive LInear NEuron*), que, diferentemente do *perceptron* de uma camada, possui saídas binárias bipolares (-1 ou 1) ao invés das saídas unipolares (0 ou 1) e diferenças no algoritmo de aprendizado. O ADALINE adapta seus pesos em função do erro de sua saída analógica, ao invés de comparar com a saída binária do neurônio, que é produzida antes da comparação com o limiar  $\theta$ . A regra de aprendizado do ADALINE é baseada no método do gradiente para minimização do erro, conhecida como regra delta ou regra de Widrow-Hoff (Haykin, 2001).

Minsky e Papert (1969) destacaram a incapacidade do uso do *perceptron* de uma camada na resolução de certos problemas, independentemente do

algoritmo de treinamento. Também foi argumentado que para *perceptrons* com mais de uma camada, os algoritmos de aprendizado não garantiam convergência. Estas observações levaram as RNAs a ser relegadas a segundo plano durante a década de 1970 e início da década de 1980. Segundo Braga et al. (1998), as pesquisas na área foram retomadas, em parte, devido a um trabalho de Hopfield (1982) onde foram destacadas as propriedades associativas das RNAs. A descrição do algoritmo de treinamento backpropagation alguns anos depois por Rumelhart et al. em 1986 mostrou que a visão de Minsky e Papert (1969) sobre o *perceptron* era bastante pessimista e que é possível treinar RNAs de múltiplas camadas para resolver problemas complexos.

#### **4.2. Conceito e estrutura**

As Redes Neurais Artificiais consistem em uma técnica de computação não algorítmica capaz de modelar ou reconhecer padrões a partir deste conjunto de dados apresentados, possuindo inclusive capacidade de generalização para domínios até então desconhecidos (BRAGA et al., 1998).

Do ponto de vista de sua arquitetura, as RNAs são compostas por um conjunto de nodos, mais conhecidos como neurônios, dispostos em camadas, geralmente separadas em uma camada de entrada, uma camada de saída e uma ou mais camadas intermediárias ou ocultas. Em cada neurônio são aplicadas funções matemáticas, geralmente não lineares, sobre os dados de entrada. Estas entradas são ponderadas por pesos, os quais são ajustados de modo a minimizar o erro cometido pela rede no cálculo do resultado final. Seu desenvolvimento passa, necessariamente, por uma fase de treinamento ou aprendizagem e outra de validação, podendo ser considerado, neste sentido, uma técnica de ajuste estatístico.

A escolha da arquitetura de uma RNA está relacionada com o tipo de problemas a ser abordado e é definida por quatro parâmetros principais: número de camadas da rede, número de nodos em cada camada, tipo de conexão entre nodos e a topologia da rede.



Segundo Fiorin (2011), as conexões entre os neurônios podem ser do tipo *feedforward* (acíclica), quando a saída de um nodo somente poderá servir de entrada para nodos de uma camada posterior, ou do tipo *feedback* (cíclica), na qual a saída de um nodo pode servir de entrada para um nodo de uma mesma camada ou de uma camada anterior. Quando ocorre a realimentação da saída nas camadas de entrada, a RNA é dita recorrente.

Entre as principais classes de RNAs, podem-se destacar as redes Perceptron e Adaline, as Perceptrons de Múltiplas Camadas, Memórias Matriciais, Self-Organizing, Processamento Temporal, entre outras.

### 4.3. *Perceptrons* de Múltiplas Camadas

As RNAs do tipo *Perceptrons* de Múltiplas Camadas (*Multilayer Perceptron* - MLP) são redes que apresentam uma ou mais camadas de nodos intermediários ou escondidos. As redes MLP são muito utilizadas por apresentarem maior simplicidade e facilidade de implementação. A Figura 4.1 apresenta um exemplo de MLP com três entradas, duas camadas intermediárias e uma camada de saída com um neurônio, que produz uma única informação de saída.

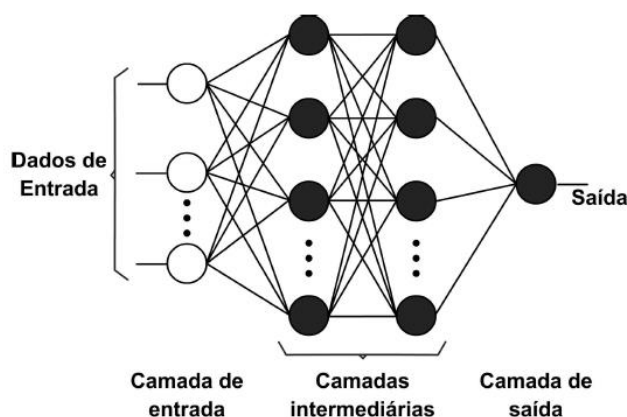


Figura 4.1 - Representação gráfica de uma RNA do tipo MLP com duas camadas intermediárias.

As redes MLP apresentam alto poder computacional, atribuído as suas camadas internas, podendo trabalhar com dados não linearmente independentes. As redes com uma camada intermediária podem representar

qualquer função contínua enquanto as redes que possuem duas ou mais camadas intermediárias podem, teoricamente, representar qualquer função, linearmente separável ou não (CYBENCO, 1988). Generalizando, um alto grau de não linearidade requer um maior número de neurônios e camadas ocultas (BLACKWELL; CHEN, 2009).

Os neurônios de uma rede MLP permitem qualquer valor de saída, ao contrário do sinal de saída binário gerado pela comparação com um limiar. Para isso, desenvolveram-se novos modelos de neurônios artificiais aos quais se aplicam funções de ativação aos valores ponderados da entrada. Essas funções são geralmente não lineares, para que possam representar problemas também não lineares e diferenciáveis. O neurônio apresentado na Figura 4.2 pode ser visto como um neurônio genérico dentro da estrutura de uma rede MLP.

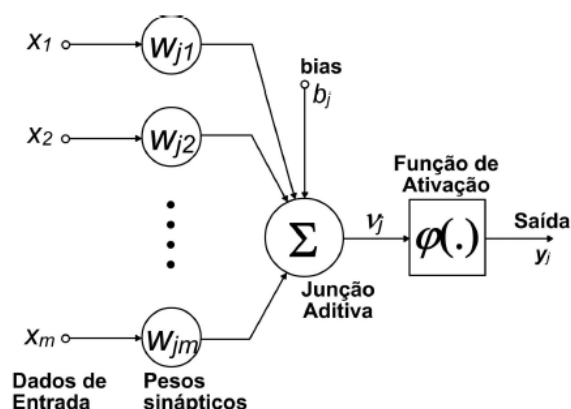


Figura 4.2 - Modelo de um Neurônio Artificial de uma rede MLP.

Fonte: Adaptado de Haykin (2001).

Na rede MLP, o somatório ponderado dos valores das entradas é combinado com outro valor ajustável, denominado bias ( $b_j$ ), que tem a função de expandir ou reduzir a entrada líquida da função de ativação para ajustar o chamado nível de atividade interna do neurônio ( $v_j$ ). A saída do neurônio ( $y_j$ ) é produzida pela aplicação da função de ativação ( $\phi$ ) ao nível de atividade interna do neurônio. Estas relações são descritas pelas Equações 4.1 e 4.2 abaixo:

$$v_j = \sum_{i=1}^m w_{ji} x_i + b_j \quad (4.1)$$

$$y_j = \varphi(v_j) \quad (4.2)$$

As funções de ativação mais utilizadas são a função limiar (degrau), a função linear e as funções sigmóides, logística e tangente hiperbólica. Estas funções são representadas respectivamente pelas Equações 4.3, 4.4, 4.5 e 4.6 e possuem o comportamento de seus sinais de saída esboçados na Figura 4.3.

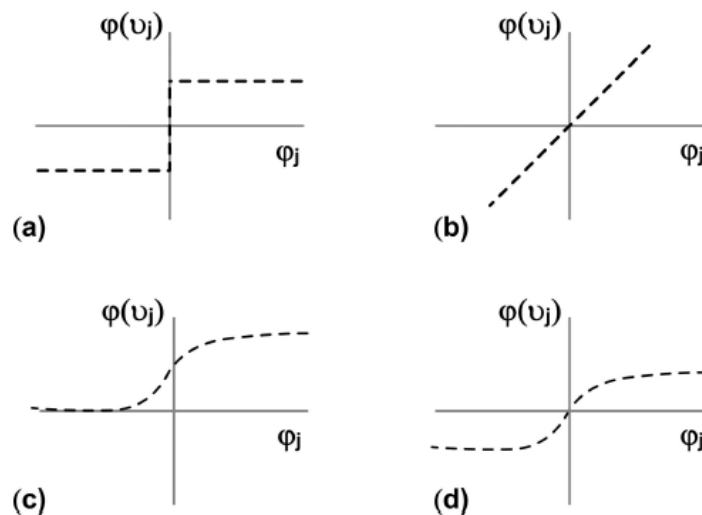


Figura 4.3 - Representação gráfica de diferentes funções de ativação: (a) função degrau; (b) função linear; (c) função logística; (d) função tangente hiperbólica.

Função Limiar:

$$\varphi(v_j) = \begin{cases} +\gamma & \text{se } v_j \geq 0 \\ -\gamma & \text{se } v_j < 0 \end{cases} \quad (4.3)$$

Função Linear:

$$\varphi(v_j) = \alpha \cdot v_j \quad (4.4)$$

Sigmoide Logística:

$$\varphi(v_j) = \frac{1}{1 + \exp(-\alpha \cdot v_j)} \quad (4.5)$$

Sigmoide Tangente Hiperbólica:

$$\varphi(v_j) = \operatorname{tgh} \frac{v_j}{2} = \frac{(1 - \exp(-v_j))}{(1 + \exp(-v_j))} \quad (4.6)$$

De acordo com Fiorin (2011), as funções mais utilizadas em redes MLP são as funções sigmóides. A razão disso está na técnica de treinamento proposta por Rumelhart et al., chamada *backpropagation*. Nela, o ajuste dos pesos se dá pelo gradiente descendente de erro, sendo necessárias funções de ativação contínuas, diferenciáveis e de preferência não decrescentes e não lineares, para permitir que as camadas ocultas interpretem as não linearidades na rede (BRAGA et al., 1998).

Por fim a topologia de uma MLP precisa ser definida de uma forma que otimize o aprendizado e o desempenho da rede. Muitas camadas ou muitos neurônios em cada camada aumentam a flexibilidade da rede, ou seja, têm maior capacidade de representar as variações das entradas. Uma rede muito flexível além de aumentar o custo computacional, passa a modelar o próprio ruído contido nos dados, correndo o risco de perder sua capacidade de generalização e “decorar” as saídas, o que é caracterizado como *overfitting*. Por outro lado uma rede com uma topologia pobre, apesar de mais facilmente treinada pode apresentar-se rígida demais para simular os processos a que se propõe. Este problema é conhecido na literatura como “dilema do viés e da variância” (GEMAN et al., 1992) e envolve a obtenção do melhor compromisso estas duas opções.

#### **4.4. Treinamento**

Segundo Gonçalves et al. (2011), o treinamento consiste no ajuste gradual dos pesos sinápticos para cada entrada de cada neurônio, seguindo uma metodologia definida pelo algoritmo de treinamento. Os algoritmos podem ser divididos entre supervisionados, quando é fornecido um vetor de entradas e um vetor de saídas à rede buscando o menor erro entre a saída alvo e a modelada (ex. *backpropagation*), e não supervisionados, quando não há saídas alvo e a

rede busca reduzir o erro entre padrões de entrada similares. Neste trabalho, é empregado um treinamento supervisionado.

Conforme mencionado anteriormente, existe o risco de „sobre ajuste’ ou *overfitting* da rede para o caso de conjunto de dados extensos em redes muito flexíveis. Para isto evitar esse problema, Reed (1993) propôs que o conjunto de dados fosse dividido em conjunto de treinamento e conjunto de validação. Desta forma, durante o processo de treinamento o erro do conjunto de validação é avaliado paralelamente. O treinamento é então interrompido no momento em que o erro do conjunto de validação começa a crescer, indicando a perda da capacidade de generalização da rede.

O ajuste dos pesos pode ser realizado a cada iteração (treinamento sequencial) ou após a apresentação à rede de todos os exemplos do conjunto de dados de treinamento (treinamento por lote). Para um treinamento supervisionado sequencial, utilizado neste trabalho, considera-se um neurônio de saída  $j$ , a cada iteração  $t$  é produzido um sinal de erro  $e_j(t)$ , obtido pela diferença entre o valor de saída calculado pelo neurônio e o valor alvo (ou, saída desejada,  $d_j(t)$ ):

$$e_j(t) = d_j(t) - y_j(t) \quad (4.7)$$

Com base em  $e_j(t)$ , e objetivando obter um erro menor na próxima iteração ( $t+1$ ), ajustes corretivos são calculados e aplicados aos pesos de  $j$ :

$$w_{ji}(t + 1) = w_{ji}(t) + \Delta w_{ji}(t) \quad (4.8)$$

em que  $w_{ji}(t)$  é o peso da conexão do neurônio  $j$  com o neurônio  $i$  da camada anterior e  $\Delta w_{ji}(t)$  é o ajuste a ser aplicado ao peso, fazendo-o assumir novo valor na iteração seguinte:  $w_{ji}(t + 1)$ . O ajuste é obtido pela minimização da chamada função de custo:

$$E(t) = \frac{1}{2} e_j^2(t) \quad (4.9)$$

A minimização desta função, para o caso particular de um neurônio de saída com função de ativação linear, resulta na já mencionada regra delta (WIDROW; HOFF, 1960) que afirma que o ajuste de um peso é proporcional ao produto entre o erro e a entrada da sinapse ( $x_i$ ) :

$$\Delta w_{ji}(t) = \eta e_j(t) x_i(t) \quad (4.10)$$

em que  $\eta$  é a taxa de aprendizado, que determina a velocidade com que os pesos são ajustados na direção de produzirem o menor erro (Braga et al.,1998). A regra delta pressupõe que o erro seja diretamente mensurável, de maneira que a sua aplicabilidade restringe-se apenas à última camada da RNA (HAYKIN, 2001).

A função de custo constitui uma medida de desempenho do sistema em fase de aprendizado e é uma função dos parâmetros livres do sistema (pesos e bias). Assim, a função de custo pode ser visualizada como uma superfície de erro, com os parâmetros livres como coordenadas. A superfície de erro pode apresentar um único ponto de mínimo, no caso de a rede fazer uso de funções de ativação lineares, ou pode apresentar vários mínimos locais além do mínimo global, se houverem neurônios não-lineares (Braga et al.,1998). Ao longo do aprendizado, sucessivas combinações de parâmetros livres conduzem a pontos sucessivamente mais baixos, em direção a um ponto de mínimo da superfície de erro, sendo esta direção definida através do gradiente da superfície de erro em cada ponto. Assim, a minimização da função de custo que leva à regra delta é chamada de método do gradiente para minimização do erro, em que o ajuste dos pesos deve ser feito sempre no sentido inverso do gradiente:

$$\Delta \vec{w} = -\eta \cdot \nabla E(\vec{w}) \quad (4.11)$$

em que  $\vec{w}$  é um vetor contendo todos os pesos e o bias do neurônio,  $E(\vec{w})$  é a função de custo (função de todos os parâmetros livres do neurônio contidos no vetor  $\vec{w}$ ) e  $\nabla E(\vec{w})$  é o gradiente, que é um vetor de igual dimensão a  $w$ , e onde

cada componente é a derivada parcial de  $E(\vec{w})$  com relação a cada peso em  $\vec{w}$  (Haykin, 2001).

#### 4.4.1. Algoritmo de Treinamento: *Backpropagation* (Retropropagação)

Segundo Rumelhart et al., (1986), o mais difundido e utilizado algoritmo de treinamento supervisionado para redes MLP é o *backpropagation*. Neste algoritmo, ocorre numa primeira fase a propagação do sinal funcional (*feedforward*) e numa segunda fase a retro propagação do erro (*backpropagation*). Na primeira fase, a partir das entradas, o sinal funcional propaga-se pela rede até a geração de uma saída, mantendo-se fixos os pesos das sinapses. Na segunda fase, a saída é comparada com um alvo produzindo um sinal de erro. O sinal de erro propaga-se da saída para entrada, e os pesos são ajustados de maneira a minimizar o erro. O *backpropagation* é baseado na regra delta, entretanto ajustando os pesos dos neurônios de todas as camadas da rede neural e não apenas da camada de saída. A dedução completa do *backpropagation* foge do objetivo desta Dissertação e maiores detalhes podem ser obtidos em Rumelhart et al. (1986), Haykin (2001) ou Braga et al. (1998).

A cada passo  $t$  do treinamento *backpropagation*, o sinal de erro pode ser calculado para cada neurônio  $j$  de saída da rede. Para uma RNA com  $N$  neurônios de saída, a função de custo é redefinida como o somatório dos  $N$  sinais de erro:

$$E(t) = \frac{1}{2} \sum_{j=1}^N e_j^2(t) \quad (4.12)$$

Pelo método do gradiente para minimização do erro, a correção a ser aplicada em cada peso de um neurônio  $j$  de saída é dada pela derivada parcial de  $E(t)$  em relação ao peso em questão, calculada, utilizando-se a regra da cadeia (HAYKIN, 2001):

$$\Delta w_{ji}(t) = -\eta \frac{\partial E(t)}{\partial w_{ji}(t)} = \eta \cdot e_j(t) \cdot \varphi'_j(v_j(t)) \cdot x_i(t) \quad (4.13)$$

onde  $\varphi_j'(v_j(t))$  é a derivada da função de ativação aplicada ao nível de atividade interna do neurônio. O erro  $e_j(t)$  e a derivada da função de ativação são comumente agrupados no chamado gradiente local,  $\delta_j(t)$ :

$$\delta_j(t) = e_j(t) \cdot \varphi_j'(v_j(t)) \quad (4.14)$$

$$\Delta w_{ji}(t) = \eta \delta_j(t) x_i(t) \quad (4.15)$$

Apesar de não ser possível calcular seus erros diretamente, os neurônios ocultos compartilham a responsabilidade pelo erro cometido na saída da rede. Assim, o sinal de erro deve ser retro propagado para que se possam ajustar os pesos das camadas ocultas. Considerando agora que o neurônio  $j$  é um neurônio oculto, conectado a neurônios  $k$  da camada de saída, o método *backpropagation* calcula o gradiente local por:

$$\delta_j(t) = \varphi_j'(v_j(t)) \cdot \sum_k \delta_k(t) w_{jk}(t) \quad (4.16)$$

Desta forma, o gradiente local para um neurônio  $j$  oculto é calculado através do somatório dos gradientes locais de cada neurônio  $k$  da camada seguinte, ponderados pelas ligações sinápticas que ligam cada neurônio  $k$  ao neurônio  $j$ . Portanto, o sinal de erro para um neurônio oculto é uma estimativa determinada recursivamente em termos dos sinais de erro de todos os neurônios da camada posterior. O ajuste dos pesos da camada oculta é realizado pela equação 4.15, utilizando-se a equação 4.16 para  $\delta_j(t)$ .



#### 4.4.2. Algoritmo de treinamento: Levenberg-Marquardt

Segundo Demuth et al. (2005), devido ao comportamento assintótico das funções de ativação sigmóides, suas derivadas assumem valores muito pequenos para argumentos afastados de zero, conduzindo a gradientes locais de pequena magnitude, de maneira que o ajuste de pesos é pequeno mesmo estando afastados de seus valores ótimos. Como redes MLP empregam funções sigmóides nas camadas ocultas, o algoritmo backpropagation é computacionalmente lento e o tempo de convergência é grande. Variantes desse algoritmo de treinamento foram desenvolvidas para aumentar o desempenho e a velocidade de treinamento. Um desses algoritmos é o Levenberg-Marquardt (MARQUARDT, 1963; RIEDMILLER; BRAUN, 1993; HAGAN; MENHAJ, 1994), que foi utilizado no treinamento empregado neste trabalho.

De acordo com Hagan e Menhaj (1994), o algoritmo é uma aproximação para o Método de Newton que diz que, se existe uma função  $E(t)$  que se quer minimizar, então:

$$\Delta t = -(\nabla^2 E(t))^{-1} \nabla E(t) \quad (4.17)$$

Segundo Blackwell e Chen (2009), como a função tem a forma da soma dos erros quadráticos, tem-se que:

$$\nabla E(t) = J^T e \quad (4.18)$$

$$\nabla^2 E(t) = J^T J + S \quad (4.19)$$

Onde  $J$  é a matriz Jacobiana que contém as primeiras derivadas dos erros da rede com respeito aos pesos e bias,  $e$  é o vetor dos erros da rede e

$$S = \sum_{i=1}^N e_i \nabla^2 e_i \quad (4.20)$$

Pelo método de Gauss-Newton (Battiti, 1992) é assumido que  $S$  é aproximadamente zero, tornando a Equação 4.17:

$$\Delta t = -(J^T J)^{-1} J e \quad (4.21)$$

A modificação de Levenberg-Marquardt para o método de Gauss-Newton é

$$\Delta t = -(J^T J + \mu I)^{-1} J e \quad (4.22)$$

Quando  $\mu$  é zero, o método torna-se o método de Gauss-Newton, usando uma aproximação para  $\nabla^2$ . Quando  $\mu$  é grande, o método se torna um método de gradiente descendente com tamanho de passo pequeno, quando  $\mu$  é pequeno, torna-se o método de Gauss-Newton. Assim,  $\mu$  diminui quando o erro diminui e  $\mu$  aumenta quando o erro aumenta.

O algoritmo Levenberg-Marquardt, mesmo utilizando maior quantidade de memória RAM do computador, converge ao menor erro em menor número de interações e, desta forma, segundo Hagan e Menhaj (1994), para redes com até algumas centenas de pesos ajustáveis, tem desempenho computacional mais eficiente, quando comparado com técnicas baseadas no gradiente, como o algoritmo *backpropagation*.

#### 4.5. Aplicações

Dadas as potencialidades da utilização de RNAs para modelagem de processos físicos, têm-se observado um aumento no número de trabalhos na área de geociências empregando esta técnica. Segundo, Guarnieri (2006), apesar de tratar-se de uma ferramenta estatística que considera relações empíricas entre as variáveis meteorológicas, as RNAs tem-se apresentado como um método alternativo com boa destreza frente a problemas não-lineares ou de natureza estocástica, como os complexos processos físicos que influenciam na disponibilidade de energia solar e eólica.

Guarnieri (2006) comparou RNAs e regressões múltiplas para estimativas de radiação solar a partir de previsões fornecidas pelo modelo ETA. Seus resultados demonstraram que há um ganho significativo em relação às saídas do modelo, mas o desempenho das regressões e da RNA foi similar. Uma justificativa seria de que os processos físicos relacionados à determinação da

radiação não apresentariam grandes não-linearidades que justificassem um melhor desempenho das RNAs.

Mendes e Marengo (2009) utilizaram uma rede tipo MLP para o refinamento das saídas de precipitação de modelos climáticos do IPCC sobre a região amazônica, obtendo resultados bem superiores em relação a modelos auto regressivos.

Soares et al., (2004) utilizaram redes MLP de 3 camadas, treinadas com o algoritmo padrão *backpropagation* com momento, para modelar a radiação solar difusa horária na cidade de São Paulo. Os autores constataram que valores medidos de irradiação solar global na superfície, a irradiação solar no topo da atmosfera (TDA), valores de umidade relativa e da irradiação de onda longa são informações relevantes para esta aplicação de RNA. Neste estudo, os autores verificaram que a temperatura do ar e a pressão atmosférica não influenciavam na precisão e confiabilidade das estimativas produzidas e enfatizaram que medidas de irradiação de onda longa podem substituir dados de nebulosidade quando estes não estão disponíveis.

Al-Alawi e Al-Hinai (1998) empregaram uma rede MLP com 15 nodos na camada interna para estimativa de valores médios mensais de radiação solar global, utilizando como dados de entrada os valores diários de pressão, temperatura, umidade relativa, velocidade do vento, duração de brilho do Sol e latitude da estação. O modelo desenvolvido apresentou boa capacidade de generalização, estimando a irradiação solar global para sítios não utilizados no treinamento com precisão da ordem de 95%.

Elminir e al. (2005) utilizaram RNAs do tipo MLP, treinadas com o algoritmo de *Levenberg-Marquardt*, para previsão de valores diários de irradiação solar global, irradiação de onda longa e irradiação ultravioleta utilizando dados de temperatura ambiente, umidade do ar, cobertura de nuvens, direção e velocidade do vento. Os resultados obtidos apresentaram boa correlação entre os valores previstos e medidos, tanto para a estação onde a rede foi treinada,

quanto para uma segunda estação, demonstrando a capacidade de generalização do modelo desenvolvido.

Stetsos e Coonick (2000) testaram diferentes tipos de RNAs, tais como redes MLP, RBF, ANFIS, recorrentes de Elman, além de regressão linear, para a previsão da irradiação solar horária utilizando séries temporais de temperatura, pressão, velocidade e direção do vento. Os melhores resultados foram obtidos empregando a rede do tipo MLP treinada pelo algoritmo de *Levenberg-Marquardt*.

Chevallier et al. (1998), investigou a possibilidade de elaborar uma nova geração de modelos de transferência radiativa com base em técnicas de redes neurais artificiais. Os autores mostram com sucesso a derivação com precisão do balanço radiativo de onda longa. Dois modelos de transferência radiativa são aplicados para o cálculo da parte radiativa do conjunto de dados: um modelo de linha por linha e um modelo de banda. Ambos alcançaram uma precisão comparável ao atual modelo de circulação de transferência radiativa, entretanto, muito mais rapidamente.

Dürr e Philipona (2004) apresentaram um algoritmo de detecção automática da fração de cobertura de nuvens baseados apenas em medidas exatas de radiação de onda longa descendente, temperatura e umidade relativa do ar na altura da estação. O método fornece cobertura de nuvens a cada 10 minutos durante o dia e à noite e é aplicável às estações de radiação sem conhecimento de observações sinóticas de nuvens, com resultados bastante satisfatórios.

## **5 DADOS E METODOLOGIA**

### **5.1. Dados Satelitais**

A determinação do Coeficiente de Cobertura Efetiva de Nuvens foi realizada com base nas radiâncias do canal visível medidas com o satélite geoestacionário da série GOES. No período de estudo, os satélites GOES-8, GOES-10 e GOES-12 estavam operacionais em períodos distintos na posição sobre o Equador com longitude -75 W. As imagens de satélite distribuídas para o Hemisfério Sul apresentam resolução temporal de 15 em 15 minutos e estão disponíveis para o mesmo período que os dados meteorológicos, 2008 até dezembro de 2012. Como os dados de satélite têm uma resolução temporal menor que os dados observados nas estações meteorológicas, foi necessário fazer uma sincronização de modo que se possa adotar uma escala temporal idêntica para ambas bases de dados.

### **5.2. Dados Observados em Superfície**

No desenvolvimento deste trabalho foram utilizados dados de 2 estações de referência do projeto SONDA (Sistema de Organização nacional de Dados Ambientais). Optou-se pela utilização de dados dessas estações, pois nelas estão presentes rastreadores solares necessários para medidas de radiação de onda longa descendente, além da radiação solar difusa e direta. Nessas estações também são feitas medidas de estações meteorológicas convencionais, como temperatura do ar, umidade relativa do ar, pressão atmosférica, precipitação e velocidade e direção do vento. Na Figura 5.1, pode-se observar as estações que estão localizadas nas cidades de Brasília (15° 36' 03" S, 47° 42' 47" O) e Petrolina (09° 04' 08" S, 40° 19' 11" O).



Figura 5.1 - Mapa de estações da Rede SONDA espalhadas pelo território brasileiro com destaque em cor preta nas estações utilizadas nesse estudo.

Fonte: INPE.CCST (2014)

Os dados meteorológicos da rede SONDA possuem resolução temporal de 1 minuto e o período disponível dados das duas estações é de 2008 até dezembro de 2012. Toda a base de dados foi submetida ao programa de controle de qualidade de dados adotados na rede SONDA descrito em (<http://sonda.ccst.inpe.br/infos/validacao.html>). Somente os dados indicados como não suspeitos de erro pelo controle de qualidade foram utilizados no estudo.

Os equipamentos instalados na estação de Brasília e Petrolina são apresentados na Tabela 5.1. O rastreador solar é utilizado para bloquear a radiação direta do sol, tornando possível a medição da componente difusa da radiação solar e da radiação de onda longa.

Tabela 5.1 - Equipamentos utilizados na medição das variáveis na estação da Rede SONDA de Brasília (DF) e de Petrolina (PE).

<b>Equipamento</b>	<b>Marca</b>	<b>Modelo</b>	<b>Variável Medida</b>
<b>Piranômetro</b>	Kipp&Zonen	CM21	Radiação Global
<b>Piranômetro</b>	Kipp&Zonen	CM22	Radiação Difusa
<b>Radiômetro</b>	Eppley	Pir	Radiação de Onda Longa
<b>Barômetro</b>	Vaisala	PTB101B	Pressão Atmosférica
<b>Rastreador Solar</b>	Kipp&Zonen	BD	-
<b>Sensor</b>	Vaisala	HMP45C	Temperatura e umidade

Para alcançar essa escala temporal idêntica, optou-se por adotar os valores médios de cada 15 minutos dos valores observados nas estações de superfície. O procedimento adotado utilizou os valores observados nos 7 minutos anteriores e 7 minutos posteriores ao horário de cada imagem de satélite.

### **5.3. Ajustes necessários para o cálculo da fração de cobertura de nuvens**

Durante uma análise inicial do método proposto no Capítulo 3, observou-se uma superestimativa dos valores da fração de cobertura de nuvens, sendo encontrados valores acima de 100% do céu encoberto. Desta forma, tornaram-se necessários alguns ajustes, apresentados a seguir.

#### **5.3.1. Radiação de Onda Longa Descendente de Céu Claro**

Um dos fatores mais impactantes foi a determinação da definição da radiação de onda longa descendente em condições de céu claro,  $R_{li(cloudless)}$ . O método propunha utilizar o valor mais baixo de radiação de onda longa medido na estação, entretanto, valores de radiação de onda longa durante períodos de céu claro, com temperaturas diferentes, têm emissões também diferentes. Assim, optou-se, neste estudo, por determinar um valor de  $R_{li(cloudless)}$  para intervalos de 5°C de temperatura do ar. A Tabela 5.2 lista os valores médios de  $R_{li(cloudless)}$  para os intervalos de temperatura observados ao longo do período

de 2008 a 2012. Observa-se uma diferença significativa entre os valores de cada intervalo, comprovando a importância dessa separação.

Tabela 5.2 - Média da radiação de onda longa de céu claro de 2008 a 2012, por intervalos de temperatura, em W/m<sup>2</sup>.

Intervalo de Temperatura (°C)	Brasília	Petrolina
10-14	297,12	311,40
15-19	312,97	326,91
20-24	321,49	336,35
25-29	334,00	345,58
30-34	360,82	360,81
35-40	365,05	381,91

### 5.3.2. Emissividade de Céu Claro

Outro fator avaliado foi a validade da Equação 2.1, utilizada para estimar os valores de emissividade em condições de céu claro, para as localidades estudadas. Para essa avaliação, foram feitos testes para validar a equação utilizando a relação das Equações 5.1 e 5.2 a seguir.

$$R_{li(\text{cloudless})} = \epsilon_{a(\text{cloudless})} \cdot \sigma \cdot T_a^4 \quad (5.1)$$

$$\epsilon_{a(\text{cloudless})} = \frac{R_{li(\text{cloudless})}}{\sigma \cdot T_a^4} \quad (5.2)$$

Desta forma, selecionando dias de céu claro é possível encontrar a radiação de onda longa incidente para esses dias, e assim, encontrar a emissividade de céu claro.

A seleção dos dias de céu claro foi realizada através da análise das curvas de irradiação global. Em condições de céu claro as curvas devem ser suaves, sem variações abruptas que indicam a presença ou passagens de nuvens. Abaixo, na Figura 5.2, encontram-se dois exemplos, um para dia de céu claro e outro com variação de nebulosidade. O pico de irradiação solar em condições de céu claro deve ser bastante elevado (maior que 500W/m<sup>2</sup>) a fim de evitar a seleção de dias em condições de céu completamente encoberto



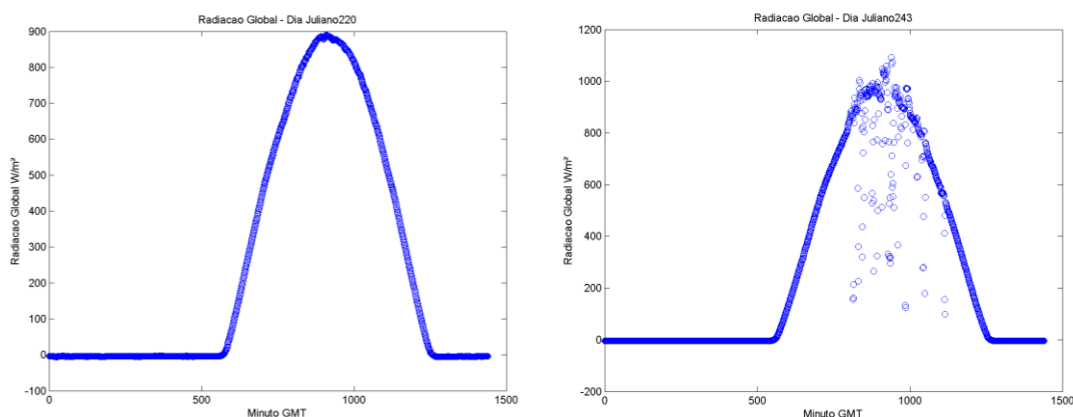


Figura 5.2 – Exemplos de dia de céu claro (lado esquerdo) e céu com variação de nebulosidade (lado direito).

Depois de determinados os dias de céu claro, eles foram separados em dois grupos, um com 70% dos dados foi utilizado na determinação das novas constantes para a Equação 2.1, e outro contendo 30% dos dados para posterior validação do modelo. A determinação das novas constantes foi feita através do Método dos Mínimos Quadrados, sendo que na Tabela 5.1 encontram-se os novos valores, onde A é o fator multiplicante e B o expoente, de acordo com a Equação 5.3 a seguir.

$$\epsilon_{a(\text{cloudless})} = A \cdot (e_a/T_a)^B \quad (5.3)$$

Tabela 5.3 - Novos valores encontrados para as constantes A e B.

Estação	A	B
Brasília	0,9959	0,0900
Petrolina	1,1187	0,1287

Na Figura 5.3 encontra-se o gráfico com o desvio da função encontrada em relação aos dados separados para validação, com  $e_a/T_a$  no eixo X e  $\epsilon_{a(\text{cloudless})}$  no eixo Y para Brasília e Petrolina. Em seguida, na Figura 5.4, encontram-se as dispersões entre os dados destinados para a validação das emissividades de céu claro medidas e estimadas para as duas estações, tomando apenas a parcela dos dados destinados para a validação.

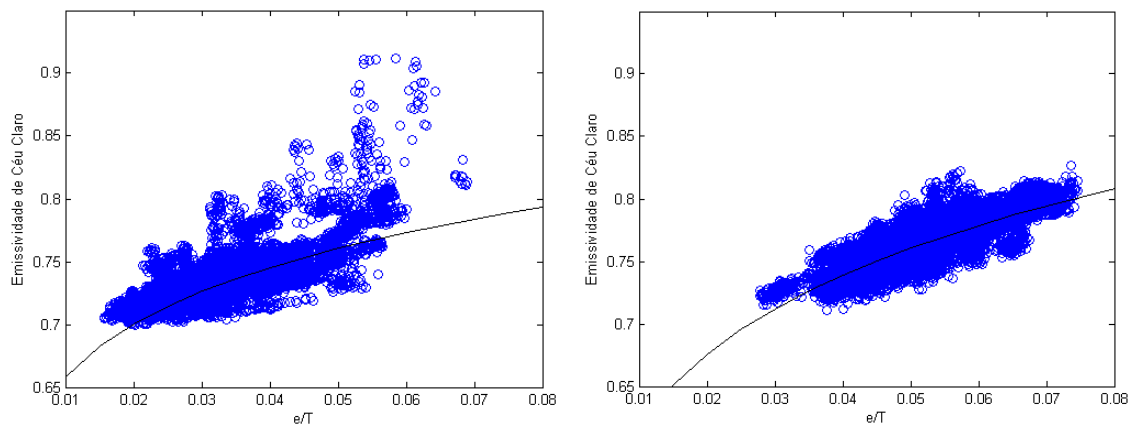


Figura 5.3 - Desvio da função encontrada com os dados destinados para a validação para Brasília (lado esquerdo) e Petrolina (lado direito).

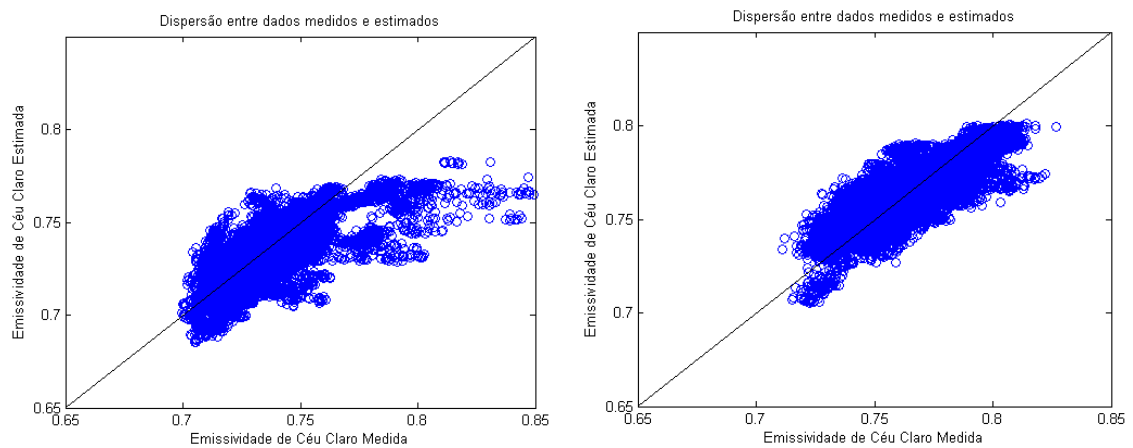


Figura 5.4 - dispersões entre os dados destinados para a validação das emissividades de céu claro medidas e estimadas para Brasília (lado esquerdo) e Petrolina (lado direito).

É observado que em Brasília ocorre uma dispersão maior nos dados. A hipótese considerada para explicar esse fenômeno está relacionada ao grande número de queimadas que ocorrem no entorno da região de Brasília no período em que a maioria dos dias de céu claro foi selecionada – estação seca. Eventos de queima de biomassa lançam uma grande quantidade de aerossóis na atmosfera que modificam a sua composição e, conseqüentemente, sua emissividade. Os dados mais dispersos são, em sua maioria, correspondentes ao ano de 2010 no qual, segundo o site de monitoramento de queimadas do Instituto Nacional de Pesquisas Espaciais (INPE) (<<http://www.inpe.br/queimadas/>>), nesse ano ocorreram os maiores valores no

número de focos de queimadas no Distrito Federal e nos estados mais próximos. O número de focos chegou a valores superiores a 10000 em um mês no estado do Tocantins e 5000 em Goiás.

#### 5.4. Determinação da Radiância em condição de Céu Claro

O método empregado atualmente para a estimativa de radiâncias de céu claro consiste em determinar, pixel a pixel, das imagens do satélite GOES o menor valor da radiância visível medida pelo satélite durante o período de um mês. Entretanto, podem ocorrer casos em que o pixel em questão está sem a presença nebulosidade, mas está sombreado por uma nuvem em algum pixel adjacente. Nesses casos, o menor valor de radiância reflete um valor inferior à maioria dos casos de céu claro.

Por esse motivo, procurou-se desenvolver uma nova técnica de estimativa da radiância de céu claro com o intuito de minimizar tais falhas. Adaptando-se o método de Ceconi (2013), atribui-se como radiância de céu claro o valor mais frequente da radiância visível medida pelo satélite para cada pixel área das imagens para período de um mês, conforme a Figura 5.5.

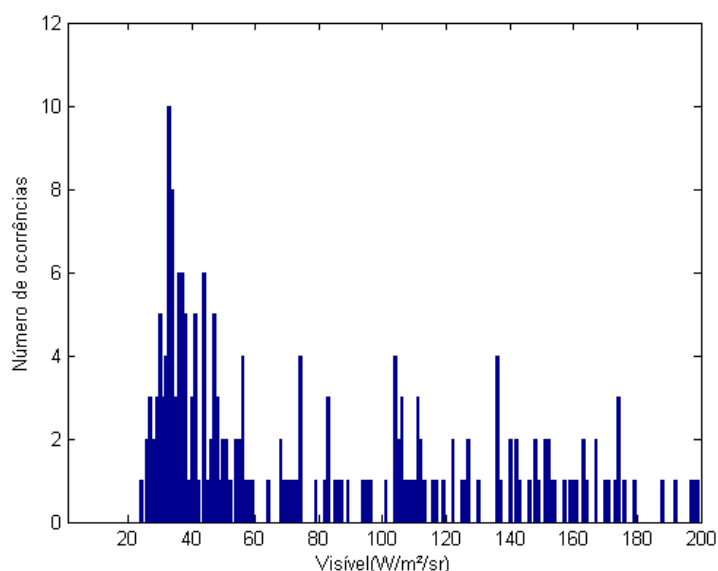


Figura 5.5 – Gráfico relacionando o número de ocorrências de cada classe da radiância visível medida pelo satélite durante janeiro de 2011, no horário 12:30 GMT, sobre a área centrada nas coordenadas geográficas da estação SONDA de Petrolina.

O método supõe que em cada área considerada, durante o período de um mês, ocorram com mais frequência condições de céu claro do que encoberto. Geralmente essa hipótese é válida, com exceção de algumas áreas nas regiões Norte e Nordeste do país, sendo, portanto, necessária a aplicação de uma técnica de homogeneização de seus valores.

### **5.5 Determinação da Radiância de Céu Encoberto**

Da mesma maneira que a radiação de céu claro, a metodologia empregada para determinação da radiância de céu encoberto atualmente utilizada consiste em verificar o maior valor da radiância visível medido pelo satélite durante o período de um mês para cada pixel. Entretanto, essa técnica torna-se falha em meses que não ocorra a condição de céu completamente encoberto sobre um pixel, o que pode acontecer, por exemplo, em algumas regiões áridas do Nordeste do Brasil. Neste caso, estaria sendo atribuído para a radiância de céu encoberto um valor inferior ao esperado, fazendo com que o modelo identificasse erroneamente alguns píxeis como encobertos, superestimando as estimativas do coeficiente de cobertura efetiva de nuvens.

Para contornar essa deficiência na estimativa da radiância de céu encoberto, Ceconi (2013) buscou uma forma de estimá-la tomando como referência a hipótese inicial de que, dada uma geometria Sol-pixel-satélite fixa, a radiância de céu encoberto deve ser a mesma independente da região do país em que se encontra o pixel.

Para a realização de diversos testes, Ceconi (2013) selecionou cinco regiões do território brasileiro que possuem estações de coleta de dados da rede SONDA; São Martinho da Serra (29° 26' 34" S, 53° 49' 23" O), Brasília (15° 36' 03" S, 47° 42' 47" O), Campo Grande (20° 26' 18" S, 54° 32' 18" O), Cuiabá (15° 33' 19" S, 56° 04' 12" O) e Petrolina (09° 04' 08" S, 40° 19' 11" O).

Nos testes foram variados os ângulos zenitais do Sol e do satélite a cada cinco graus, sendo encontrada uma correlação entre o maior valor da radiância visível, com infravermelho indicando temperatura de brilho superior a 280 K. Para se obter a informação sobre o nível de complexidade do topo das nuvens foi calculado o desvio padrão das medidas de radiância visível efetuadas pelo satélite em um grupo de píxeis centrado nas coordenadas de interesse. Desta forma, quanto maior o desvio padrão da radiância visível do grupo de píxeis considerado, maior é a complexidade do topo da nuvem.

Utilizando o método dos Mínimos Quadrados, foi encontrada a função dada pela Equação 5.4, que permite a estimativa da radiância de céu encoberto ( $L_{cld}$ ) a partir de informações sobre a geometria Sol-píxel-satélite (ângulo zenital do Sol, representado por  $\theta_{Sol}$ , e ângulo zenital do satélite, representado por  $\theta_{sat}$ ) e da complexidade do topo da nuvem (informada pelo desvio padrão da radiância visível no período observado, representado por  $\sigma_{vis}$ ). O método apresentou coeficiente de correlação de 0,955 e coeficiente de determinação de 0,912, que demonstram um bom ajuste da equação aos dados.

$$L_{cld} = 12,87 \cos(\theta_{Sol}) - 6,93 \cos(\theta_{sat}) + 6,651 \times 10^{-2} \sigma_{vis} - 2 \times 10^{-5} \sigma_{vis}^2 \quad (5.4)$$

## 5.6. Treinamento da Rede Neural Artificial

Foram empregadas RNAs do tipo *perceptrons multi-camadas* (MLP) devido à sua capacidade de aproximação de qualquer função contínua aliada à capacidade de generalização, sendo nelas utilizado o algoritmo de treinamento de Levenberg-Marquardt.

Todas as redes têm como saída uma única variável que é o Coeficiente de Cobertura Efetiva de Nuvens. Durante o treinamento é utilizado o método proposto por Reed (1993) onde os dados serão divididos em conjunto de treinamento e conjunto de validação, para se evitar o *overfitting*, citado no Capítulo 4. Todos os dados utilizados como entrada da rede foram normalizados, assumindo, assim, sempre valores de 0 a 1. A ferramenta

computacional a ser empregada será o software MATLAB® através do pacote *Neural Network Toolbox*.

### **5.7. Seleção dos preditores e escolha da estrutura da Rede Neural Artificial**

Para evitar problemas como a redundância de informações utilizadas para alimentar a rede neural e, desta forma, diminuir o custo computacional da Rede Neural Artificial, foi realizado um procedimento para a seleção de quais variáveis são relevantes e quais podem ser retiradas do seu treinamento.

Um método mais simplificado seria testar as correlações entre as variáveis, selecionando as mais correlacionadas. A desvantagem desta técnica é que torna difícil o reconhecimento de variáveis redundantes, aumentando a complexidade da rede sem necessidade.

Desta forma, devido a serem poucas as opções de variáveis de entrada, foi possível fazer um estudo inicial incluindo todas as variáveis e, após isso, retirar uma a uma, fazendo variações de combinações de variáveis e, desta forma, encontrar a combinação com o menor número possível de variáveis de entrada que não afete o desempenho da rede.

Após a seleção das variáveis fundamentais para o treinamento da rede, foi necessária a definição de qual topologia de rede melhor se adequava ao objetivo proposto. A definição da arquitetura da rede possui um componente empírico relevante. Neste estudo foram realizados testes com configurações distintas para que o menor erro fosse encontrado de modo a garantir que a RNA apresentasse uma complexidade desnecessária na rede. O método utilizado consistiu na construção de diferentes modelos, inicialmente superdimensionados, com diferentes funções de ativação, diferentes métodos de treinamento, diferentes números de camadas e nodos, tendo como intuito de avaliar a combinação que melhor atende aos requisitos estabelecidos. Buscou-se encontrar um equilíbrio entre a rigidez e a flexibilidade da rede; ela

não deve ser rígida de modo que não modele suficientemente os dados e nem flexível demais, de forma que modele até o ruído nos dados.

### 5.8. Avaliação dos resultados obtidos

Uma vez treinadas as redes para cada estação de coleta de dados, procedeu-se a validação das estimativas por ela fornecidas utilizando a fração da base dados reservada para esse fim. O gráfico dispersão dos dados medidos versus estimados foi realizado para verificar o comportamento da RNA. Os seguintes índices estatísticos foram determinados: o coeficiente de correlação (R), o erro médio (MBE), o erro médio quadrático (MSE) e a raiz do erro médio quadrático (RMSE). As Equações 5.5, 5.6, 5.7 e 5.8 descrevem o método de cálculo de cada um destes índices, onde ( $E$ ) são dados estimados e ( $O$ ) dados observados.

$$R = \frac{\sum_{i=1}^N [(E_i - \bar{E})(O_i - \bar{O})]}{\left[ \sqrt{\sum_{i=1}^N (E_i - \bar{E})^2} \cdot \sqrt{\sum_{i=1}^N (O_i - \bar{O})^2} \right]} \quad (5.5)$$

$$MBE = \frac{1}{N} \sum_{i=1}^N (E_i - O_i) \quad (5.6)$$

$$MSE = \frac{1}{N} \sum_{i=1}^N (E_i - O_i)^2 \quad (5.7)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (E_i - O_i)^2} \quad (5.8)$$





## **6 RESULTADOS**

### **6.1. Fração de Cobertura de Nuvens**

Com o objetivo de verificar a coerência da fração de cobertura de nuvens calculada pelo método físico citado no Capítulo 3, apresenta-se, neste tópico, a comparação entre as médias mensais das estações, com as normais climatológicas da nebulosidade média obtidas pelo Instituto Nacional de Meteorologia (INMET). Normais climatológicas são definidas como os valores médios mensais de uma variável meteorológica calculada para um período com no mínimo trinta anos, de acordo com a Organização Meteorológica Mundial (OMM).

As normais climatológicas da nebulosidade apresentadas são referentes às médias do período de primeiro de Janeiro de 1961 a Dezembro de 1990 geradas pelo INMET para as localidades estudadas. As medidas de nebulosidade (em décimos) são resultado de observações subjetivas realizadas em cada uma das estações nos horários padrões de 12, 18 e 24 GMT. Posteriormente, calcula-se a média aritmética simples dos três horários e se obtêm as médias diárias, utilizadas então no cálculo das médias correspondentes a cada mês. Para mais informações sobre as normais climatológicas utilizadas neste estudo, sugere-se a leitura da publicação “Normais Climatológicas do Brasil 1961-1990” elaborada pelo INMET.

Apresenta-se nas Figuras 6.1 e 6.2 a comparação entre a média mensal dos valores estimados para a fração de cobertura de nuvens ao longo de todo o período de estudo (2008-2012), com a normal climatológica das cidades de Brasília e Petrolina, respectivamente. Os valores das médias mensais para cada ano separadamente são apresentadas no Apêndice A. Alguns meses não estão apresentados devido a não haver dados observados válidos suficientes para representar a média do mês em questão. Foi estipulado que a média mensal seria calculada apenas se 50% dos dados estivessem disponíveis e válidos.

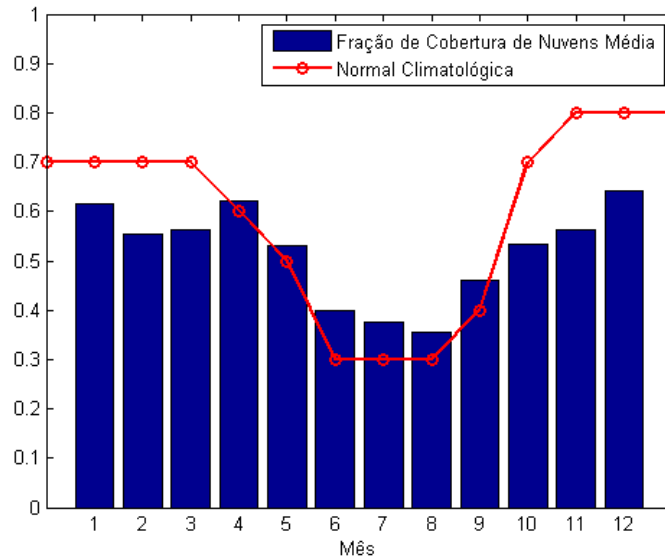


Figura 6.1 – Comparação entre as médias mensais da Fração de Cobertura de Nuvens Estimada, para todo o período de estudo, em Brasília, com a Normal Climatológica.

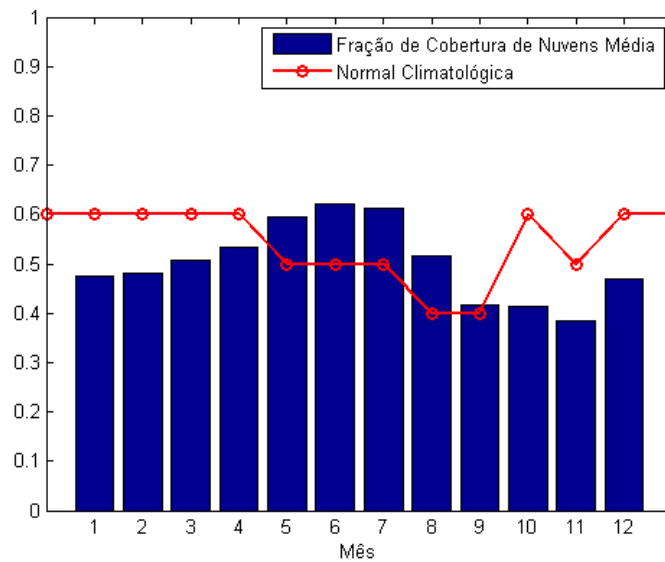


Figura 6.2 – Comparação entre as médias mensais da Fração de Cobertura de Nuvens Estimada dos anos de 2008 a 2012, com a Normal Climatológica, em Petrolina (PE).

A região de Brasília apresenta grande sazonalidade, sendo que, de acordo com Barros e Zavattini (2004), os três meses mais secos do quadro climático regional, são junho, julho e agosto, já que, além da pouca quantidade de chuva que neles é registrada, também ocorrem os totais mensais de evaporação e insolação mais elevados e os valores de umidade relativa do ar e nebulosidade mais baixos. Os três meses mais úmidos são dezembro, janeiro e fevereiro, pois, além do grande volume das chuvas, ainda são meses com os menores totais de evaporação e insolação, e com os maiores valores de nebulosidade e umidade relativa do ar.

Neste contexto, observa-se na Figura 6.1 uma boa representação da sazonalidade anual da estimativa da fração de cobertura de nuvens na estação de Brasília. Outro aspecto importante é que os valores estimados estão próximos às normais climatológicas mensais, principalmente nos meses mais secos do ano (Abril a Setembro). Nos meses mais chuvosos (Outubro a Janeiro) ocorre uma pequena subestimação da estimativa em relação à normal climatológica. Isso pode ser observado quando calculada a média anual de ambos os casos, enquanto que a média da normal climatológica tem um valor de 0,57, a média da fração de cobertura de nuvens tem 0,51.

Petrolina, localizada na bacia do rio São Francisco, está localizada na região semiárida do nordeste brasileiro. De acordo com Teixeira (2010), a região apresenta grande homogeneidade térmica que contrasta fortemente com a heterogeneidade espacial e temporal do regime pluviométrico no polo Petrolina, PE/Juazeiro, BA. Na Figura 6.2, observa-se a boa proximidade entre as médias estimadas e os valores da normal climatológica. Tanto na estação seca quanto na chuvosa, os valores de nebulosidade estimado e observado estão próximos de 0,5. Entretanto, a sazonalidade da média mensal não está bem representada, parecendo inclusive estar fora de fase com a normal.

Adicionalmente a isso, foi comparada a média mensal da fração de cobertura de nuvens estimada de Petrolina com a normal climatológica da radiação global, encontrada em Teixeira (2010). Pode ser visualizado na Figura 6.3 que as duas variáveis estão fora de fase, o que seria o comportamento esperado, já

que com o aumento da nebulosidade ocorre uma diminuição na radiação em superfície.

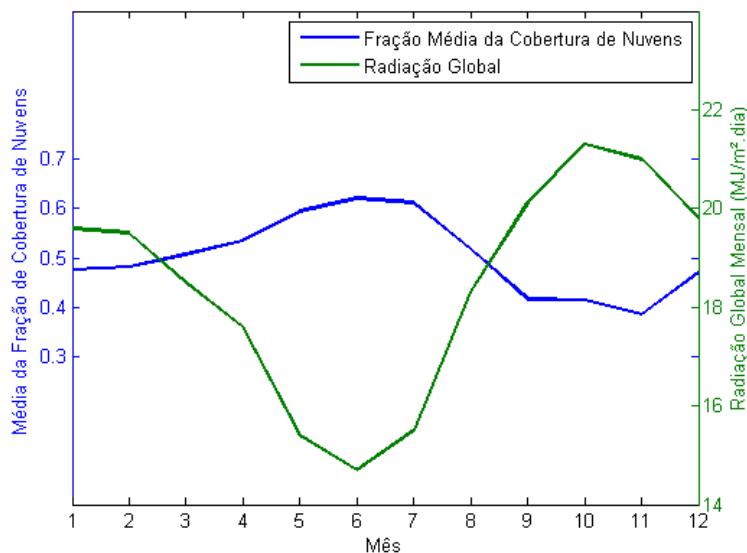


Figura 6.3 – Comparação entre a fração de cobertura de nuvens mensal média estimada e a normal da radiação solar global do período de 1968 a 2009 em Petrolina.

Em ambas as estações a diferença nos valores pode estar não só na diferença do método de estimativa: a normal climatológica de nebulosidade é determinada com base em observações visuais subjetivas e a fração de cobertura de nuvens estimada de forma objetiva a partir de variáveis meteorológicas observadas. Um aspecto relevante está relacionado ao fato de que as médias terem sido determinadas em períodos distintos e com séries temporais de diferentes extensões: a média da fração de cobertura de nuvens estimada neste estudo teve como base apenas cinco anos de dados observados em superfície.

## 6.2. Relação entre Fração de Cobertura de Nuvens e o Coeficiente de Cobertura Efetiva de Nuvens

Em uma comparação direta das duas variáveis, observa-se uma grande dispersão, mesmo que ambas apresentem tendências de crescimento consistentes entre si. Como pode ser analisado nas Figuras 6.3 e 6.4, ocorrem

diferenças inclusive nas relações mês a mês, podendo ser observado uma variação sazonal em ambas as estações. Durante os meses secos, a dispersão dos dados é menor.

Outra análise passível de ser realizada está relacionada à variação temporal da média mensal do Coeficiente de Cobertura Efetiva de Nuvens obtido a partir de imagens de satélite para o período todo e compará-lo com a média da Fração de Cobertura de Nuvens estimada, para o mesmo período. Nas Figuras 6.5 e 6.6 são apresentadas essas relações.

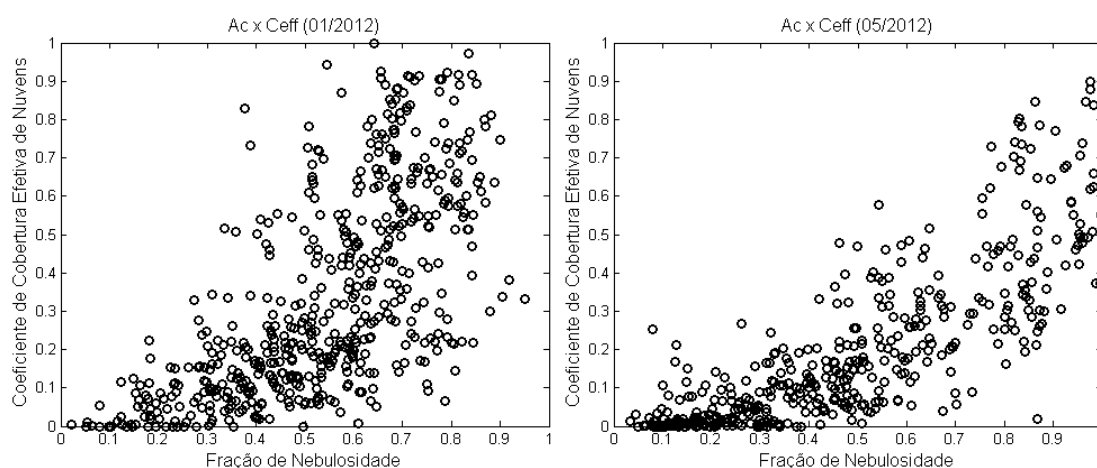


Figura 6.4 – Dispersão entre as medidas da Fração de Cobertura de Nuvens e o Coeficiente de Cobertura Efetiva de Nuvens para os meses de janeiro de 2012 (esquerda) e maio de 2012 (direita) em Brasília.

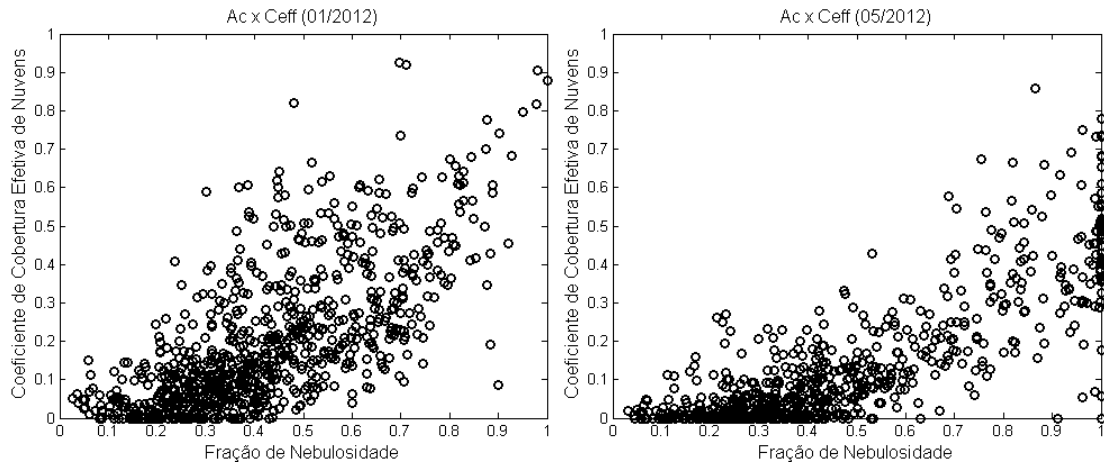


Figura 6.5 – Dispersão entre as medidas da Fração de Cobertura de Nuvens e o Coeficiente de Cobertura Efetiva de Nuvens para os meses de janeiro de 2012 (esquerda) e maio de 2012 (direita) em Petrolina.

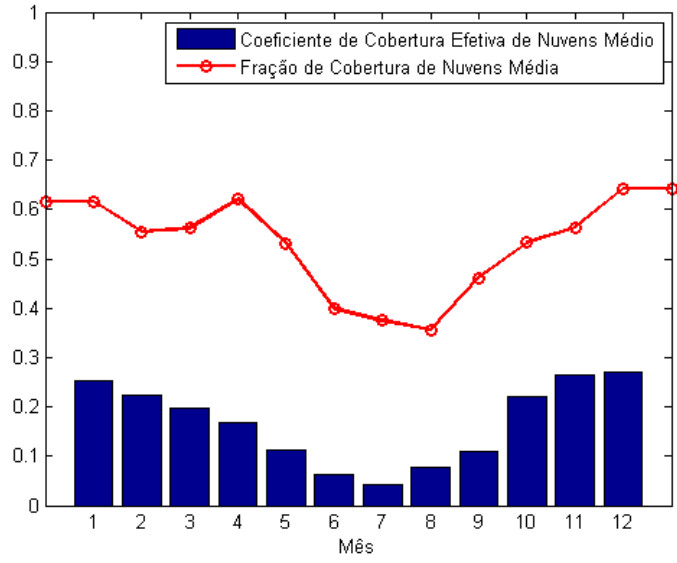


Figura 6.6 - Relação da média mensal do período de 2008 a 2012 do Coeficiente de Cobertura Efetiva de Nuvens com a média mensal da Fração de Cobertura de Nuvens estimada do mesmo período, para Brasília.

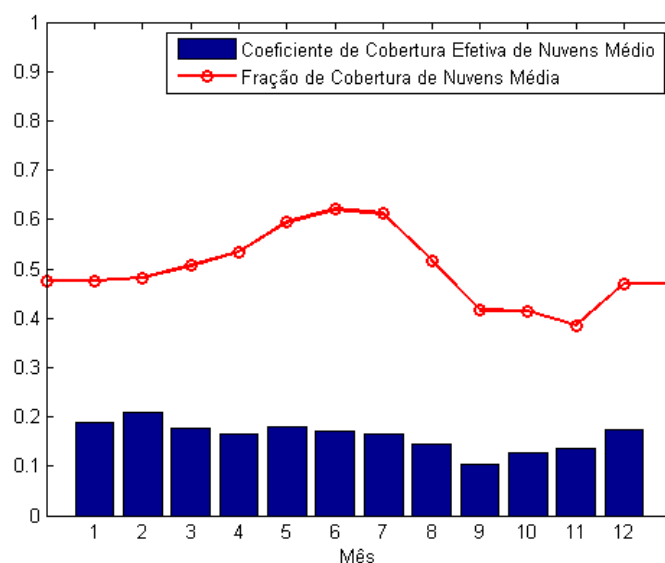


Figura 6.7 - Relação da média mensal do período de 2008 a 2012 do Coeficiente de Cobertura Efetiva de Nuvens com a média mensal da Fração de Cobertura de Nuvens estimada do mesmo período, para Petrolina.

Analisando-se as Figuras 6.5 e 6.6, percebeu-se que as médias mensais de Brasília, principalmente pelo fato da estação estar em uma região com sazonalidade bem definida, as duas variáveis apresentam um comportamento bastante similar. Em Petrolina, entretanto, as médias apresentam comportamentos distintos. A provável causa para este fato é que a fração de cobertura de nuvens seja constituída por nuvens *Cirrus*, que pelo fato de serem transparentes a radiação de onda curta, não são identificadas pelo satélite, o qual identifica somente a radiação de onda curta, no espectro visível, refletida pela nuvem ou superfície.

Além disso, a principal diferença entre as duas variáveis é que a fração de cobertura de nuvens leva somente em consideração a área do céu em que há a presença de nuvens, já o coeficiente de cobertura efetiva leva em consideração também a espessura da nuvem.

### **6.3. Influência dos aerossóis nas estimativas**

Um fator de grande importância que pode contribuir para o aumento na diferença entre a estimativa da fração de cobertura de nuvens e do coeficiente de cobertura efetiva de nuvens é a presença de altas concentrações de aerossóis na atmosfera. Os aerossóis influenciam tanto a radiação solar que chega a superfície, quanto a radiação emitida pela atmosfera. Os aerossóis absorvem e espalham a radiação solar e, quando absorvem, reemitem em comprimentos de onda maiores.

Desta forma, os aerossóis são importantes fontes de erros das estimativas, pois alteram a emissividade de céu claro, para a estimativa da fração de cobertura de nuvens, e também, ao retro espalhar a radiação solar em direção ao espaço, fazem com que o satélite observe radiâncias no canal visível superiores a que seriam observadas se a concentração natural de aerossóis estivesse presente.

A condição de elevada concentração de aerossóis de queimada pode levar à valores de coeficiente de cobertura efetiva de nuvens maiores do que os realmente observados na superfície. A dispersão entre as medidas da fração de cobertura de nuvens e o coeficiente de cobertura efetiva de nuvens, com possíveis erros relacionados aos aerossóis, é apresentada na Figura 6.7. Nestes casos, a dispersão observada foi atribuída aos aerossóis pelo motivo de que esse comportamento ter ocorrido nos meses com números elevados de eventos de queimadas.



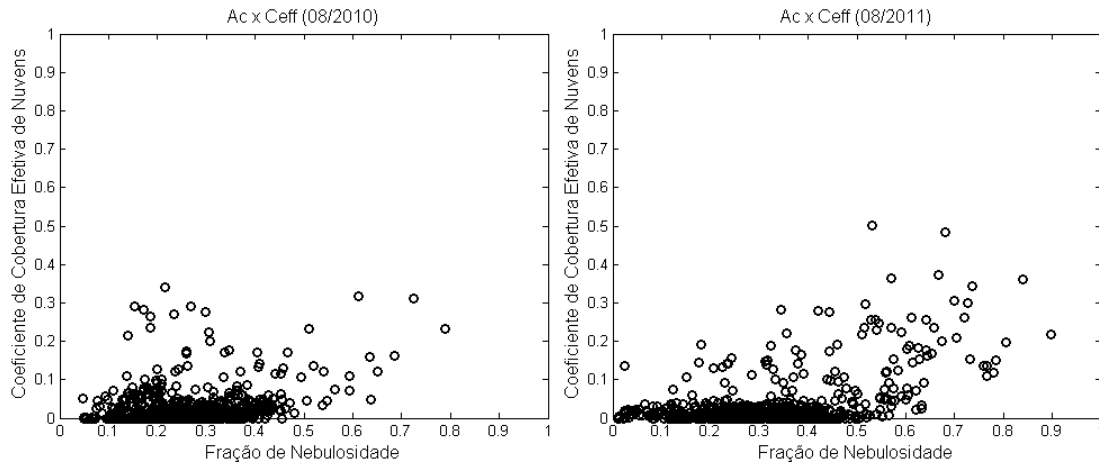


Figura 6.8 - Dispersão entre as medidas da Fração de Cobertura de Nuvens e o Coeficiente de Cobertura Efetiva de Nuvens para o mês de agosto de 2010 e 2011 em Brasília (DF).

#### 6.4. Procedimento de seleção de dados de entrada para a Rede Neural Artificial

A Tabela 6.1 lista as combinações de variáveis utilizadas para alimentar a rede neural no estudo para identificar as variáveis meteorológicas necessárias e suficientes para simular os valores de  $C_{eff}$  para as duas estações utilizando RNA. As seguintes variáveis foram avaliadas no procedimento de seleção: dia juliano ( $DJ$ ), minuto do dia ( $min$ ), cosseno do ângulo zenital ( $\alpha$ ), temperatura ( $T_a$ ), umidade relativa ( $UR$ ), pressão atmosférica ( $P$ ), radiação de onda longa incidente em superfície ( $Lw$ ), fração de cobertura de nuvens ( $Ac$ ), temperatura da base da nuvem ( $T_c$ ) e parâmetros de nebulosidade como as razões entre a radiação global e a radiação no topo da atmosfera ( $Kt$ ), entre a radiação difusa e a radiação no topo da atmosfera ( $K$ ) e entre a radiação difusa e a radiação global ( $Kd$ ). Para o procedimento de seleção foram utilizados dados referentes ao ano de 2011 e uma topologia padrão com uma camada oculta de 15 neurônios e função de ativação tangente hiperbólica.

Os valores médios do Coeficiente de Correlação ( $R$ ) e Desvio Quadrático Médio ( $MSE$ ) para cada conjunto de variáveis de entrada também estão apresentados na Tabela 6.1. Todas as combinações foram realizadas pelo menos 30 vezes. No estudo, todas as simulações com a RNA foram

inicializadas após a separação aleatória dos dados para as etapas de treinamento, validação e teste. Os índices estatísticos foram calculados a partir do conjunto dos dados separados para o teste da RNA.

A primeira simulação foi feita utilizando a totalidade de variáveis disponíveis e é utilizada como parâmetro de comparação para as outras. Nas combinações 2 a 7 são feitas simulações utilizando os parâmetros de nebulosidade. Percebeu-se que não é necessária a utilização dos três parâmetros, desde que estejam presentes a componente difusa, a componente global e a relação com a radiação incidente no topo da atmosfera. Além disso, observa-se uma melhora no coeficiente de correlação de Petrolina ao ser retirado o parâmetro  $Kd$  da entrada da rede. As simulações 8 a 12 têm como objetivo avaliar a influência das variáveis meteorológicas medidas diretamente nas estações e algumas variáveis derivadas delas, como  $Ac$  e  $Tc$ . Nessas simulações é possível perceber que ao utilizarem-se as variáveis medidas diretamente nas estações, torna-se desnecessário utilizar as variáveis derivadas, devido à redundância de informação para a rede. Adicionalmente, nota-se que  $P$  não é um fator de impacto na saída da rede, tornando-o desnecessário.

Na combinação 13 são utilizadas somente variáveis presentes em estações meteorológicas automáticas comuns e na combinação 14 foi adicionado  $Lw$ . Com essas duas simulações pode-se perceber que o Coeficiente de Cobertura Efetiva de Nuvens pode ser determinado a partir de dados coletados em estações meteorológicas automáticas com um erro maior, entretanto a presença de  $Lw$  torna o resultado mais satisfatório. Já nas combinações 15 a 18 são testadas as variáveis que representam a variação temporal com ciclo diário e anual das medidas. Em ambas as estações o erro aumentou em simulações nas quais as variáveis que apresentam uma variabilidade com o ciclo diário não foram consideradas. No entanto, somente em Brasília o erro aumentou ao serem retiradas as variáveis relacionadas ao ciclo anual, representadas por  $Min$  e  $\alpha$ .

Neste contexto, concluiu-se que, com a quantidade de variáveis disponíveis, o arranjo que aperfeiçoou o desempenho da rede neural avaliada em termos dos

desvios apresentados pelas estimativas fornecidas foi *DJ*, *Min*,  $\alpha$ , *Kt*, *K*, *T*, *UR*, e *Lw*, a qual está destacada em negrito na Tabela 6.1.

Tabela 6.1 – Combinações de variáveis para serem utilizadas como entrada na Rede Neural Artificial de Brasília e Petrolina e seus respectivos Coeficientes de Correlação e Erros Quadráticos Médios.

	Dados retirados da entrada da Rede neural Artificial	Coeficiente de Correlação (R)		Erro Quadrático Médio (MSE)	
		BRB	PTR	BRB	PTR
1	Nenhum	0,89	0,89	0,008	0,007
2	<i>Kt</i> , <i>Kd</i> , <i>K</i>	0,87	0,87	0,010	0,008
3	<i>Kt</i>	0,89	0,88	0,008	0,008
4	<i>Kd</i> , <i>K</i>	0,88	0,88	0,009	0,008
5	<i>Kd</i>	0,89	0,89	0,008	0,007
6	<i>K</i>	0,89	0,88	0,008	0,008
7	<i>Kt</i> , <i>K</i>	0,88	0,88	0,009	0,008
8	<i>Kd</i> , $T_a$ , <i>UR</i> , <i>P</i>	0,89	0,88	0,008	0,008
9	<i>Kd</i> , <i>Tc</i> , <i>Ac</i>	0,89	0,89	0,008	0,007
10	<i>Kd</i> , <i>Tc</i> , <i>Ac</i> , $T_a$	0,88	0,88	0,008	0,008
11	<i>Kd</i> , <i>Tc</i> , <i>Ac</i> , <i>Ur</i>	0,88	0,88	0,008	0,007
12	<b><i>Kd</i>, <i>Tc</i>, <i>Ac</i>, <i>P</i></b>	<b>0,89</b>	<b>0,89</b>	<b>0,008</b>	<b>0,007</b>
13	<i>Kd</i> , <i>K</i> , <i>Lw</i> , <i>Tc</i> , <i>Ac</i>	0,85	0,81	0,011	0,012
14	<i>Kd</i> , <i>K</i> , <i>Tc</i> , <i>Ac</i>	0,88	0,87	0,008	0,008
15	<i>Min</i> , <i>Kd</i> , <i>Tc</i> , <i>Ac</i> , <i>P</i>	0,88	0,89	0,008	0,007
16	$\alpha$ , <i>Kd</i> , <i>Tc</i> , <i>Ac</i> , <i>P</i>	0,88	0,89	0,009	0,007
17	<i>DJ</i> , <i>Kd</i> , <i>Tc</i> , <i>Ac</i> , <i>P</i>	0,88	0,88	0,008	0,008
18	<i>Min</i> , $\alpha$ , <i>Kd</i> , <i>Tc</i> , <i>Ac</i> , <i>P</i>	0,88	0,87	0,009	0,008

## 6.5. Procedimento para definição da arquitetura da Rede Neural Artificial

Na Tabela 6.2 encontram-se os vários testes de arquiteturas utilizando as variáveis selecionadas no tópico anterior. São apresentados os coeficientes de correlação (R) e os erros quadráticos médios (MSE) para as estações de

Brasília e Petrolina no ano de 2011. Da mesma forma que anteriormente, cada arquitetura foi treinada 30 vezes, os índices estatísticos apresentados são a média dos valores encontrados nas 30 simulações com cada topologia. Novamente, os índices foram calculados a partir do conjunto dos dados identificado como Teste – dados não utilizados no treinamento ou na validação da RNA.

A notação utilizada na arquitetura da rede foi feita de forma que redes com duas camadas ocultas estão escritas como “X-Y-FUN-FUN”, onde X representa o número de neurônios na primeira camada, Y o número de neurônios na segunda camada e FUN a função de ativação utilizada. Adota-se a seguinte abreviatura para as funções de ativação: função Linear (LIN), função Logística (LOG) e função Tangente Hiperbólica (TAN). Todas as RNAs testadas apresentaram apenas um neurônio na última camada.

Observa-se nos resultados apresentados que uma grande quantidade de neurônios e um aumento no número de camadas internas, a partir uma camada com 14 neurônios, não influenciaram no desempenho da RNA. Na prática, não compensa investir em redes com maior número de camadas e neurônios, pois se obtêm desempenhos muito semelhantes com um aumento do custo computacional desnecessário. Em contrapartida, números muito baixos de neurônios, tornam a rede incapaz de estimar com qualidade o coeficiente de cobertura efetiva de nuvens, como é o caso de arquiteturas com uma camada e menos de seis neurônios. Desta forma, a arquitetura de rede 14-TAN foi a que apresentou os melhores resultados com o menor número de neurônios para ambas as estações de coleta de dados.

Tabela 6.2 - Resultados do treinamento de diferentes arquiteturas para as estações de Brasília e Petrolina.

Arquitetura	Brasília		Petrolina	
	R	MSE	R	MSE
16-8-LIN-LIN	0,83	0,012	0,84	0,010
16-8-TAN-TAN	0,89	0,008	0,89	0,007
16-8-LOG-LOG	0,89	0,008	0,89	0,007
12-6-TAN-TAN	0,89	0,008	0,89	0,007
12-6-LOG-LOG	0,89	0,008	0,89	0,007
10-5-TAN-TAN	0,89	0,008	0,88	0,007
20-TAN	0,89	0,008	0,89	0,007
16-TAN	0,89	0,008	0,89	0,007
16-LOG	0,89	0,008	0,89	0,007
14-LIN	0,84	0,012	0,84	0,010
<b>14-TAN</b>	<b>0,89</b>	<b>0,008</b>	<b>0,89</b>	<b>0,007</b>
14-LOG	0,89	0,008	0,88	0,007
12-TAN	0,89	0,008	0,88	0,008
8-LIN	0,84	0,012	0,84	0,010
8-TAN	0,89	0,008	0,88	0,008
8-LOG	0,88	0,008	0,89	0,007
6-TAN	0,88	0,008	0,88	0,008
6-LOG	0,88	0,009	0,88	0,008
4-TAN	0,88	0,009	0,88	0,008
4-LOG	0,88	0,009	0,88	0,008
2-TAN	0,87	0,010	0,87	0,008
2-LOG	0,87	0,010	0,88	0,008
RLM	0,84	0,061	0,84	0,071

A Tabela 6.2 apresenta também os resultados obtidos com as mesmas variáveis utilizando Regressão Linear Múltipla (RLM). Verifica-se que com o emprego de funções de ativação lineares nas camadas da RNA obtêm-se resultados próximos aos obtidos empregando RLM. Demonstrando que o uso de funções de ativação não lineares permite o modelamento das não linearidades presentes nos processos radiativos que ocorrem na atmosfera. A

Figura 6.8 apresenta a dispersão entre os dados observados e estimados pela RLM, onde se pode observar que o método não conseguiu modelar com qualidade as não linearidades.

### 6.6. Análise da estimativa do *Ceff* com uso de Redes Neurais Artificiais

A Figura 6.9 apresenta a dispersão entre os dados estimados pela RNA e os valores de *Ceff* para Brasília nos anos de 2008 e 2012. Na Figura 6.10, apresenta-se o mesmo gráfico para Petrolina. Os dados apresentados são referentes ao conjunto de dados selecionados para Teste da RNA e a arquitetura utilizada foi "14-TAN". Os anos disponíveis não apresentados tiveram dispersões semelhantes.

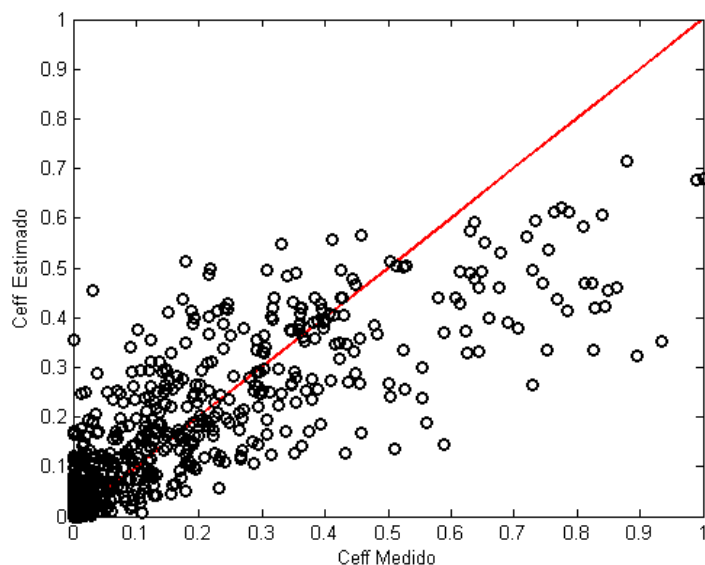


Figura 6.9 - Dispersão entre o Coeficiente de Cobertura Efetiva de Nuvens observado e estimado de Brasília no ano de 2011 utilizando Regressão Linear Múltipla.

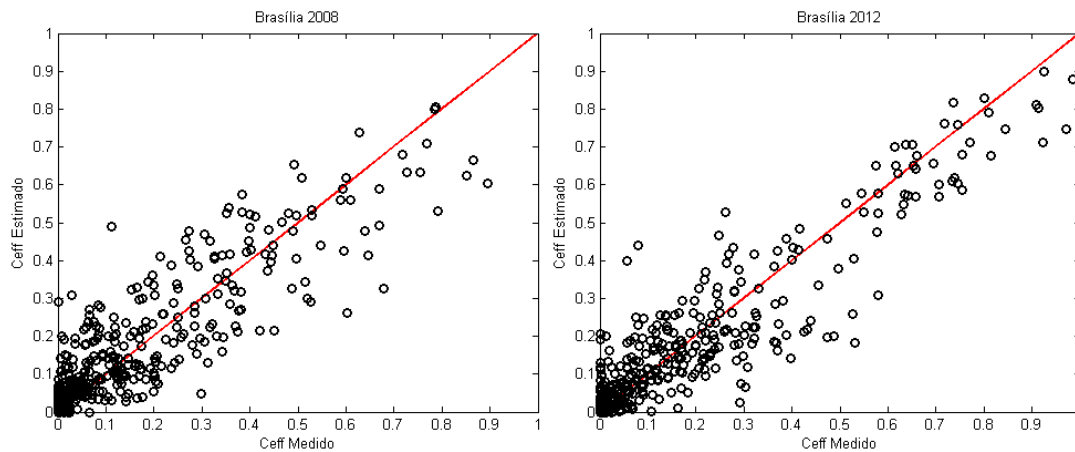


Figura 6.10 – Dispersão entre o Coeficiente de Cobertura Efetiva de Nuvens observado e estimado em Brasília nos anos de 2008 e 2012.

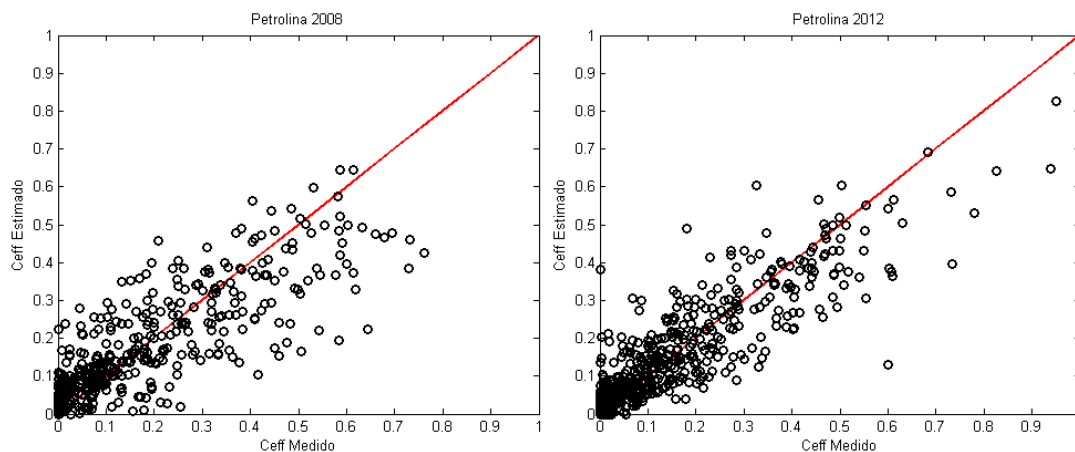


Figura 6.11 – Dispersão entre o Coeficiente de Cobertura Efetiva de Nuvens observado e estimado em Petrolina nos anos de 2008 e 2012.

Pela dispersão dos gráficos é possível perceber que a RNA conseguiu estimar o Coeficiente de Cobertura Efetiva de Nuvens com mais qualidade que a RLM apresentada na Figura 6.8. A RNA conseguiu modelar adequadamente as não linearidades presentes nos processos radiativos da atmosfera, entretanto, ainda com alguma dispersão entre os dados medidos e estimados. Na Tabela 6.3 encontra-se uma comparação, entre os coeficientes de erro, MBE e RMSE e o coeficiente de correlação R, obtidos com o uso de RNA e do modelo RLM. Os coeficientes foram calculados para as duas localidades estudadas no ano de 2011.

Tabela 6.3 – Comparação do desempenho da Rede Neural Artificial com o da Regressão Linear Múltipla para as localidades estudadas.

	Brasília		Petrolina	
	RNA	RLM	RNA	RLM
<b>R</b>	0,89	0,83	0,89	0,84
<b>MBE</b>	0,0003	0,0670	0,0003	0,0170
<b>RMSE</b>	0,091	0,259	0,088	0,274

Com o desvio MBE próximo de zero, é possível concluir que a RNA resultou em pouca superestimação ou subestimação média dos valores. Nota-se que a utilização da RNA refletiu numa redução considerável do desvio apresentado pelas estimativas do coeficiente de cobertura efetiva de nuvens.

A Tabela 6.4 apresenta uma análise da estimativa dividindo-se os dados em meses do ano mais e menos chuvosos para ambas as localidades no ano de 2011.

Tabela 6.4 – Desempenho da RNA para o ano de 2011 dividido em período chuvoso e não chuvoso.

	Brasília		Petrolina	
	Chuvoso	Não Chuvoso	Chuvoso	Não Chuvoso
<b>R</b>	0,86	0,89	0,83	0,92
<b>MBE</b>	0,0019	-0,0004	0,0031	0,0003
<b>RMSE</b>	0,108	0,069	0,105	0,071

Observa-se uma diminuição no desempenho da rede no período chuvoso, quando comparada com os resultados obtidos na análise anual. O período chuvoso apresenta uma complexa variação de nuvens, dificultando a modelagem pela RNA. Já no período não chuvoso há uma melhora no desempenho da RNA. Isso pode ser explicado pela diminuição da complexidade e da variabilidade da nebulosidade no período, sendo que a maior parte dos dias é de céu claro ou com pouca nebulosidade.



## 7 CONCLUSÕES

Esta pesquisa discute a estimativa de parâmetros de nebulosidade utilizando dados de onda longa incidente em superfície juntamente com dados meteorológicos, medidos em estações terrenas, entre os anos de 2008 e 2012, em duas localidades do Brasil, Brasília (DF) e Petrolina (PE).

O primeiro método teve como objetivo estimar a fração de cobertura de nuvens utilizando física atmosférica. Os resultados obtidos apresentaram comportamento semelhante às médias mensais do período analisado com a climatologia em ambos os locais.

Em Brasília, localidade com estações chuvosa e seca bem definidas, o método simulou bem o comportamento anual da normal climatológica da fração de cobertura de nuvens. Entretanto, nos meses mais chuvosos, houve subestimação dos valores, fazendo com que a média anual da fração estimada apresentasse valores inferiores, sendo 0,51 a média anual dos valores estimados e 0,57 a média anual referente à normal climatológica.

Em Petrolina, região que não apresenta uma sazonalidade anual significativa, o método não conseguiu representar bem o comportamento anual da média mensal da normal climatológica, entretanto, apresentou média anual muito próxima, ambas com valores próximos a 0,5. Outro fator a ser destacado é que o método apresentou resultados consistentes com a normal climatológica da radiação global observada em superfície, ou seja, média mensal da fração de cobertura de nuvens baixa nos meses em que a média mensal da radiação global é alta, e vice versa.

A diferença nos valores das estimativas com a normal pode ser devido ao fato de as médias terem sido determinadas em períodos distintos e com séries temporais de diferentes extensões. Além disso, diferença do método de estimativa deve ter influenciado nos resultados, sendo que a normal climatológica de nebulosidade é determinada com base em observações

visuais subjetivas e a fração de cobertura de nuvens estimada de forma objetiva.

A relação da fração de cobertura de nuvens estimada com a cobertura efetiva de nuvens calculada a partir de imagens de satélite apresentou tendências de crescimento consistentes entre si, entretanto, com grande dispersão nas duas localidades. O período seco de ambas as estações apresentou dispersão menor. Em relação ao comportamento anual, Brasília apresentou um comportamento bastante similar da média mensal das duas variáveis. Em Petrolina, entretanto, as médias apresentam comportamentos distintos. A provável causa para este fato é que a fração de nebulosidade seja constituída por nuvens altas, transparentes à radiação de onda curta, não sendo identificadas pelo satélite.

O segundo método proposto discute o uso de Redes Neurais Artificiais para a estimativa do coeficiente de cobertura efetiva de nuvens. Verificou-se que é possível utilizar redes do tipo *multilayer perceptron* (MLP) para a modelagem do coeficiente de cobertura efetiva de nuvens utilizando as variáveis  $DJ$ ,  $Min$ ,  $\alpha$ ,  $Kt$ ,  $K$ ,  $T$ ,  $UR$ , e  $Lw$  em uma rede neural com apenas uma camada intermediária com 14 neurônios. O método apresentou boa correlação com as medições satelitais, com coeficientes de correlação de aproximadamente 0,9, desvios MBE da ordem de  $10^{-4}$  e RMSE abaixo de 0,11 para ambas as localidades. Além disso, o método conseguiu avaliar bem as não linearidades da estimativa, quando comparado com métodos lineares como Regressão Linear Múltipla, a qual apresentou coeficientes de correlação de aproximadamente 0,8, desvios MBE da ordem de  $10^{-2}$  e RMSE da ordem de 0,2.

Com base no que foi exposto acima, os objetivos deste trabalho foram atingidos, tendo-se demonstrado opções confiáveis para a estimativa de parâmetros de nebulosidade, com base em medidas da radiação de onda longa incidente em superfície, juntamente com outras variáveis meteorológicas medidas, também, em estações de superfície.

## 8 TRABALHOS FUTUROS

Ao longo da realização e análise dos resultados deste trabalho, observou-se a necessidade de estudos complementares que poderão levar a um aperfeiçoamento das estimativas dos parâmetros de nebulosidade estudados.

Um dos fatores de grande influência nos desvios apresentados em ambos os métodos propostos é a presença de grande quantidade de aerossóis na atmosfera. Os aerossóis afetam tanto radiância medida pelo satélite, quanto a emissividade da atmosfera medida em superfície no espectro de radiação de onda longa. Eles alteram a emissividade de céu claro e também, ao retro espalhar a radiação solar em direção ao espaço, fazem com que o satélite observe radiâncias no canal visível superiores às observadas com uma concentração natural de aerossóis. Desta forma, pode-se aprofundar no estudo da influência dos aerossóis em ambas as estimativas, para que desvios menores sejam encontrados.

Outro fator possível de ser estudado está relacionado com a altura e tipo da nuvem. Nuvens com alturas diferentes têm influências distintas na radiação de onda longa incidente na superfície, podendo assim, ter sido outro fator importante nos desvios apresentados. Além disso, nuvens altas são praticamente transparentes à radiação solar, e desta forma, não são identificadas pelo satélite. Métodos diferentes na estimativa dos parâmetros de nebulosidade podem ser analisados, para um melhor entendimento da relação com a radiação de onda longa incidente na superfície.



## REFERÊNCIAS BIBLIOGRÁFICAS

- AASE, J.K.; IDSO, S.B. A comparison of two formula types for long wave radiation from the atmosphere. **Water Resour. Res.** 14, p 623-625, 1978.
- AHRENS, C. D. **Meteorology today**: an introduction to weather, climate, and the environment. Belmont, CA: Brooks/Cole, 2009. 621 p.
- AL-ALAWI, S.M. AND AL-HINAI, H.A. An ANN-based approach for predicting global radiation in locations with no direct measurement instrumentation, **Renewable Energy** 14, 199, 1998.
- BARROS, J. R.; ZAVATTINI, J. A. O regime e as excepcionalidades do ritmo pluviométrico no Distrito Federal. In: GERARDI, L. H. O.; LOMBARDO, M. A.(orgs.). **Sociedade e natureza na visão da geografia**. Rio Claro (SP): Programa de Pós-graduação em Geografia - UNESP , 2004. p. 87-102.
- BLACKWELL, W. J.; CHEN, F. W. **Neural Network in Atmospheric Remote Sensing**. Lexington, MA: Massachusetts Institute of Technology, 2009. 215 p.
- BRAGA, A. P.; CARVALHO, A. C. P. F.; LUDERMIR, T. B. **Fundamentos de redes neurais artificiais**. 11a Escola de Computação / Universidade Federal do Rio de Janeiro, 1998. 246 p.
- BRUNT, D. Notes on radiation from the atmosphere. **Quart. L Roy. Meteorol. Soc.**, v. 58, p. 389-418, 1932.
- BRUTSAERT, W.H. On a derivable formula for longwave radiation from clear skies. **Water Resources Research**, v.11, p. 742-744, 1975.
- CECONI, M. **Variabilidade do coeficiente de cobertura de nuvens sobre o Brasil o sua relação com os fenômenos de solar dimming e brightening**, 2013. 182 p. (sid.inpe.br/mtc-m19/2013/09.02.13.29-TDI). Dissertação (Mestrado em Meteorologia) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2013. Disponível em: <<http://urlib.net/8JMKD3MGP7W/3EP8CDP>>. Acesso em: 07 fev. 2014.
- CHEVALLIER, F.; CHÉRUUY, F.; SCOTT, N. A.; CHÉDIN, A. A neural network approach for a fast and accurate computation of a longwave radiative budget. **J. of Applied Meteorology**, v. 35, p. 1385-1397, 1998.
- CHEN, X.; WEI, H.; YANG, P.; JIN, Z.; BAUM, B. An efficient method for computing atmospheric radiances in clear-sky and cloudy conditions. **Journal of Quantitative Spectroscopy & Radiative Transfer**, v. 112, p. 109-118, 2011.
- CYBENKO, G. **Continuous valued neural networks with two hidden layers are sufficient**. Medford, MA: Department of Computer Science, Tufts University, 1988. Technical Report.

DEMUTH, H.; BEALE, M.; HAGAN, M. **Neural network toolbox user's guide** – Version 4 – for use with MATLAB®. The MathWorks Inc. Disponível em: <[http://www.mathworks.com/access/helpdesk/help/pdf\\_doc/nnet/nnet.pdf](http://www.mathworks.com/access/helpdesk/help/pdf_doc/nnet/nnet.pdf)>. Acesso em: 15 ago. 2013.

DÜRR B.; PHILIPONA, R. Automatic cloud amount detection by surface longwave downward radiation measurements. **Journal of Geophysical Research**, v. 109, n. 5, 2004.

ECHER, M. P. S. **Desenvolvimento de um sistema de mapeamento automático de fração de cobertura de nuvens**. 2004. 187 p. (INPE-12562-TDI/1003). Tese (Doutorado em Geofísica Espacial) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2004. Disponível em: <<http://urlib.net/sid.inpe.br/jeferson/2004/07.08.16.19>>.

ECHER, M. P. S.; MARTINS, F. R.; PEREIRA, E. B. A importância dos dados de cobertura de nuvens e de sua variabilidade: metodologias para aquisição de dados. **Revista Brasileira de Ensino de Física**, v. 28, n. 3, p. 341-352, 2006.

ECHER, M. P. S.; PEREIRA, E. B.; BINS, L. S.; Andrade, M. A. R. Simple method for the assessment of the cloud cover state in high latitude regions by a ground based digital camera. **Journal of Atmospheric and Oceanic Technology**, v. 23, p. 437-447, 2006.

ELMINIR H.K.; AREED F.F.; ELSAYED T.S., Estimation of solar radiation components incident on Helwan site using neural networks. **Solar Energy**, v. 79, p. 270, 2005.

EMBRAPA. **Sistemas orbitais de monitoramento e gestão territorial**. GOES - Geoestacionary Operational Environmental Satellite. Disponível em: <<http://www.sat.cnpm.embrapa.br/conteudo/goes.htm>>. Acesso em: 23 dez. 2013.

ENGLAND, C. F.; HUNT, G. A. A bispectral method for the automatic determination of parameters for use in imagin satellite cloud retrievals. **International Journal of Remote Sensing**, v. 6, n. 9, p. 1545-1553, 1985. doi: 10.1080/01431168508948300.

FIORIN, D. V. **Emprego de redes neurais artificiais na análise de parâmetros de radiação solar**. Santa Maria: Universidade Federal de Santa Maria, 2009. 105 p. Relatório de Estágio Supervisionado em Engenharia Química.

FIORIN, D. V. Aplicações de redes neurais e previsões de disponibilidade de recursos energéticos solares. **Revista Brasileira de Ensino de Física**, v. 33, n. 1, p. 1309, 2011.

GEMAN, S.; BIENENSTOCK, E.; DOURSAT, R. Neural networks and the bias-variance dilemma. **Neural Computation**, v.4, p.1-58, 1992.

GONÇALVES A. R. **Refinamento estatístico das previsões de vento do modelo ETA aplicado ao setor eólico-elétrico do nordeste brasileiro**. 2011. 177 p. (sid.inpe.br/mtc-m19/2012/02.27.17.24-TDI). Dissertação (Mestrado em Meteorologia) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2011. Disponível em: <<http://urlib.net/8JMKD3MGP7W/3BEBL32>>. Acesso em: 07 fev. 2014.

GRAHAM, S. **Clouds & radiation**. The earth observatory. NASA Goddard Space Flight Center: EOS Project Science Office. Disponível em: <<http://earthobservatory.nasa.gov/Features/Clouds/>>

GUARNIERI, R. A. **Planejamento e instalação da estação de referência SONDA no Observatório Espacial do Sul**. Santa Maria: Universidade Federal de Santa Maria, 2004. 105 p. Relatório de Estágio Supervisionado em Engenharia Química.

GUARNIERI, R. A. **Emprego de redes neurais artificiais e regressão linear múltipla no refinamento das previsões de radiação solar do modelo ETA**. 2006. 171 p. (INPE-14172-TDI/1089). Dissertação (Mestrado em Meteorologia) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2006. Disponível em: <<http://urlib.net/rep/sid.inpe.br/MTC-m13@80/2006/05.30.18.50>>.

GUTMAN, G.; TARPLEY, D.; OHRING, G. Cloud screening for determination of land surface characteristics in a reduced resolution satellite data set. **International Journal of Remote Sensing**, v. 8, p. 859-870, 1987.

HAGAN, M. T.; MENHAJ, M. B. Training feedforward networks with the marquardt algorithm. **IEEE Transactions on Neural Networks**, v. 5, n. 6, p. 989-993, 1994.

HAYKIN, S. **Redes neurais: princípios e prática**. 2. ed. Porto Alegre: Bookman Companhia Editora, 2001. 900 p.

HEBB, D. O. **The organization of behavior**. New York: Wiley, 1949.

HOPFIELD, J. J. Neural networks and physical systems with emergent collective computational abilities. **Proceedings of the National Academy of Sciences of the United States of America**, v. 79, n. 8, p. 2554-2558, 1982.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). Centro de Ciências do Sistema Terrestre (CCST). **Rede SONDA**. Disponível em: <<http://sonda.ccst.inpe.br/>>. Acesso em: 16 mar. 2014.

KARNER, O.; KEEVALLIK, S. **Effective cloud cover variations**. A. Deepak Publ. Virginia. 1993. 210 p.

KIDDER, S. Q.; VONDER HAAR, T. H. **Satellite meteorology: an introduction**. San Diego: Academic Press, 1995. 466 p.

KIMBALL, B.A.; IDSO, S.B.; AASE, J.K. A model of thermal radiation from partly cloudy and overcast skies. **Water Resources Research**, v.18, 931-936, 1982.

KRUK, N. S.; VENDRAME, I. F.; ROCHA, H. R.; CHOU, S. C.; CABRAL, O.; Downward longwave radiation for clear and all-sky conditions in the Sertãozinho region of São Paulo, Brazil. **Theoretical and Applied Climatology**, v.99, p. 115-123, 2010.

Kushnir, Y. **Solar radiation and the earth's energy balance**. 2000.

Disponível em:

<<http://eesc.columbia.edu/courses/eesc/climate/lectures/radiation/>>. Acesso em: 16 mar. 2014.

LIOU, K. N. **An introduction to atmospheric radiation**. New York: Academic Press Inc., 2002. 583 p.

LUTGENS, F. K.; TARBUCK, E. J. **Earth science**. 13. ed. Upper Saddle River, New Jersey: Pearson Education, Inc., 2012.

MALEK, E.; BINGHAM, G.E. Atmospheric emissivity under cloudless and cloudy skies. In: AGRICULTURAL AND FOREST METEOROLOGY – CONFERENCE, 21, San Diego. **Proceedings...** American Meteorological Society, 1994. p. 16-19.

MALEK E. Evaluation of the effective atmospheric emissivity and parameterization of cloud at local scale. **Atmospheric Research**, v. 45, p. 41-54, 1997.

MARQUARDT, D. W. An algorithm for least-squares estimation of nonlinear parameters. **Journal of the Society for Industrial and Applied Mathematics**, v. 11, n. 2, p. 431-441, 1963.

MARTINS, F. R. **Influência do processo de determinação da cobertura de nuvens e dos aerossóis de queimada no modelo físico de radiação BRASIL-SR**. 331 p. Tese (Doutorado em Geofísica Espacial) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2001.

MARTINS, F. R.; SOUZA, M. P.; PEREIRA, E. B.. Comparative study of satellite and ground techniques for cloud cover determination. **Advances in Space Research**, 32, 11, pp. 2275-2280, 2003. (INPE-11692-PRE/7051).

MARTINS, F. R.; PEREIRA, E. B.; ECHER, M. P. S. Levantamento dos recursos de energia solar no Brasil com o emprego de satélite geoestacionário - o Projeto Swera. **Revista Brasileira de Ensino de Física**, v. 26, n. 2, p. 145-159, 2004. (INPE-11756-PRE/7115).

MARTINS, F. R.; SILVA, S. A. B.; PEREIRA, E. B.; ABREU, S. L. The influence of cloud cover index on the accuracy of solar irradiance model estimates.



**Meteorology and Atmospheric Physics**, v. 99, n. 3-4, p. 169-180, 2008. DOI 10.1007/s00703-007-0272-5.

MARTY C.; PHILIPONA R. The Clear-Sky Index to separate Clear-Sky from Cloudy-Sky Situations in Climate Research. **Geophysical Research Letters**, v. 27, n. 17, p 2649-2652, 2000.

MATTHEWS, E.; ROSSOW, W. B. Regional and seasonal variations of surface reflectance from satellite observations at 0,6  $\mu\text{m}$ . **Journal of Climate and Applied Meteorology**, v. 26, n.1, p. 170-202, 1987.

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

MCLLVEEN, R. **Fundamental of weather and climate**. Chapman and Hall. 1992. 497 p.

MENDES, D.; MARENGO, J. A. Temporal downscaling: a comparison between artificial neural network and autocorrelation techniques over the Amazon Basin in present and future climate change scenarios. **Theoretical and Applied Climatology**, v. 100, n. 3-4, p. 413-421, may 2010. doi: <[10.1007/s00704-009-0193-y](https://doi.org/10.1007/s00704-009-0193-y)>..

MINSKY, M.; PAPERT, S. **Perceptrons: an introduction to computational geometry**. Massachusetts: MIT Press, 1969.

MINNIS, P.; HARRISON, E. F. Diurnal variability of regional cloud and clear sky radiative parameters derived from GOES data. Part I: analysis method. **Journal of Climate and Applied Meteorology**, v. 23, n.7, p. 993-1011, 1984.

MINNIS, P.; HARRISON, E. F. Diurnal variability of regional cloud and clear sky radiative parameters derived from GOES data. Part II: Nov. 1978 cloud distributions. **Journal of Climate and Applied Meteorology**, v. 23, n.7, p. 1012-1031, 1984.

MINNIS, P.; HARRISON, E. F. Diurnal variability of regional cloud and clear sky radiative parameters derived from GOES data. Part III: Nov. 1978 radiative parameters. **Journal of Climate and Applied Meteorology**, v. 23, n.7, p. 1032-1051, 1984.

MONTEITH, J.L.; UNSWORTH, M.H. **Principles of environmental physics**. New York: Edward Arnold,1990.

MOUSSU, G.; DIABATE, L.; OBRECHET, D.; WALD, L. A method for the mapping of the apparent ground brightness using visible images from geostationary satellites. **International Journal of Remote Sensing**, v. 10, n.7, p. 1207-1225, 1989.

NATIONAL OCEANIC AND ATMOSPHERIC ADMINISTRATION (NOAA). **NOAA satellite information system**. Disponível em: <<http://noaasis.noaa.gov/NOAASIS/ml/imager.html>>. Acesso em: 16 mar. 2014.

OFFICE OF SATELLITE OPERATIONS. **GOES 12 Spacecraft Status Summary**. Disponível em: <<http://www.oso.noaa.gov/goesstatus/>>. Acesso em: 18 abr. 2013.

OHMURA, A.; LANG, H. Secular variation of global radiation over Europe. In: LENOBLE, J.; GELEYN, J.F. (eds.). **Current problems in atmospheric radiation**. Hampton, VA: Deepak, 1989. p. 98– 301.

ORGANIZAÇÃO METEOROLÓGICA MUNDIAL (OMM). **Atlas internacional de nuvens – atlas resumido (1956)**. Lisboa: Organização Meteorológica Mundial/Serviço Meteorológico Nacional, 1970.

ORSINI A.; TOMASI C.; CALZOLARI F.; NARDINO M.; CACCIARI A.; GEORGIADIS T. Cloud cover classification through simultaneous ground-based measurements of solar and infrared radiation, **Atmospheric Research**, v. 61, p. 251-275, 2002.

PEIXOTO, J. P.; OORT, A. H. **Physics of climate**. New York: American Institute of Physics (AIP) Press, 1992. 520 p.

PEREIRA, E. B.; MARTINS, F. R.; ABREU, S. L.; RÜTHER, R. **Atlas brasileiro de energia solar**. São José dos Campos: INPE, 2006. 60 p. ISBN(85-17-00030-7).

PIDWIRNY, M. Net radiation and the planetary energy balance. **Fundamentals of physical geography**, 2. ed. 2006. Disponível em: <<http://www.physicalgeography.net/fundamentals/7i.html>>. Visualizado em 27 de janeiro de 2014.

REED, R. Pruning algorithms – a survey. **IEEE Transactions on Neural Networks**, v.4, n.5, p. 740-746, 1993.

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

ROSSOW, W. B.; BREST, C. L.; GARDER, L. C. Global, seasonal surface variations from satellite radiance measurements. **Journal of Climate**, v. 2, n. 3, p. 214-247, 1989.

ROSSOW, W. B.; GARDER, L. C.; LACIS, A. L. Global, seasonal cloud variations from satellite radiance measurements. Part I: Sensitivity of Analysis. **Journal of Climate**, v. 2, 5, p. 419-457, 1989.

RUMELHART, D. E.; HINTON G. E.; WILLIAMS, R. J. Learning representations by backpropagation errors. **Nature**, v. 323, p. 533-536, 1986.

- SAUNDERS, R. W. An automated scheme for the removal of cloud contamination from AVHRR radiances over western Europe. **International Journal Remote Sensing**, v. 7, p. 867-886, 1986.
- SEZE, G.; DESBOIS, M. Cloud cover analysis from satellite imagery using spatial and temporal characteristics of the data. **Journal of Climate and Applied Meteorology**, v. 26, p. 287-303, 1987.
- SFETSOS A.; COONICK A.H. Univariate and multivariate forecasting of hourly solar radiation with artificial intelligences techniques. **Solar Energy**, v. 68, p.169, 2000.
- SIMPSON, J. J.; GOBAT, J. I. Improved cloud detection in GOES scenes over land. **Remote Sensing Environment**, v. 52, p. 36-54, 1995.
- SOARES J.; OLIVEIRA A.P.; BOZNAR M.Z.; MLAKAR P.; ESCOBEDO J.F.; MACHADO, A.J. Modeling hourly diffuse solar-radiation in the city of São Paulo using a neural-network technique. **Applied Energy**, 79, 201-214, 2004.
- TARPLEY, J. D. Estimating incident solar radiation at the Earth's surface from geostationary satellite data. **Journal Applied Meteorology**, v. 18, p. 1172-1181, 1979.
- TEIXEIRA, A. H. C. **Informações agrometeorológicas do Polo Petrolina, PE/Juazeiro, BA – 1963 a 2009**. Embrapa Semiárido. Documentos, 233. 2010. 21 p.
- VAREJÃO-SILVA, M. A. **Meteorologia e climatologia**. Versão Digital 2. Recife: [s.n.], 2006. 449 p.
- VIÚDEZ-MORA A. **Atmospheric downwelling longwave radiation at the surface during cloudless and overcast conditions** - measurements and modeling. Tese. p. 24-26 (Programa de Doctorat en Medi Ambient). Universitat de Girona, 2011.
- WALLACE, J. M.; HOBBS, P. V. **Atmospheric science: an introductory survey**. Estados Unidos: Academic Press, 2006. 483 p.
- WIDROW, B.; HOFF, M. E. Adaptive switching circuits. In: Western Electronic Show and Convention (WESCON), 1960, Los Angeles, CA, EUA. **Proceedings of IRE WESCON Convention Record**. Los Angeles: Institute of Radio Engineers - IRE, v. 4, p. 96-104, 1960.
- WILD, M.; OHMURA, A.; GILGEN, H.; MORCRETTE, J.; SLINGO, A.; Evaluation of Downward Longwave Radiation in General Circulation Models. **Journal of Climate**, v.14, p. 3227–3239. 2001.
- WILKS, D. S. **Statistical methods in the atmospheric sciences**. [S.I.]: Elsevier, 2006, 649 p.

**YAMASOE, M. A. Estudo das propriedades ópticas de partículas de aerossóis a partir de uma rede de radiômetros.** 1999. 273 p. Tese (Doutorado em Ciências) – Universidade de São Paulo, São Paulo, 1999.



## APÊNDICE A – COMPARAÇÃO ENTRE AS MÉDIAS MENSAIS DA FRAÇÃO DE COBERTURA DE NUVENS ESTIMADA E A NORMAL CLIMATOLÓGICA.

Neste apêndice, apresentam-se as comparações entre as médias mensais da fração de cobertura de nuvens estimada dos anos de 2008 a 2012 e a normal climatológica em Brasília (DF) e Petrolina (PE).

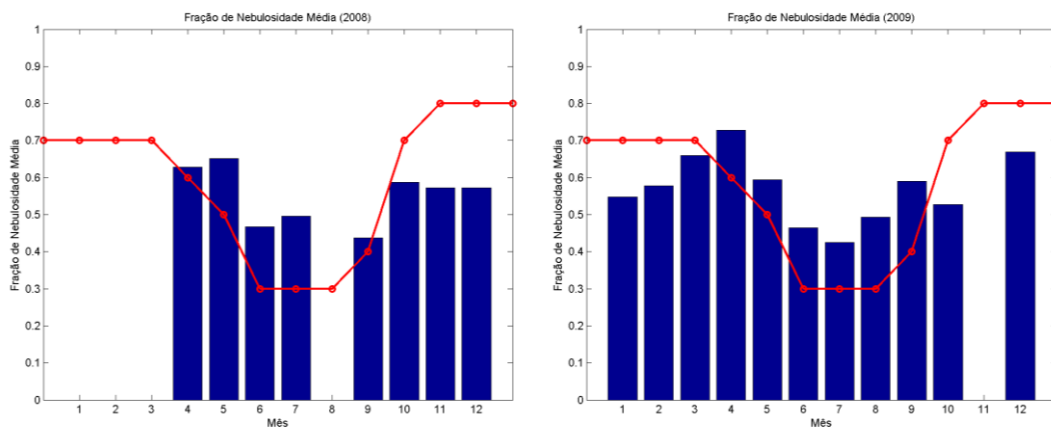


Figura A1 – Comparação entre as médias mensais da fração de cobertura de nuvens estimada dos anos de 2008 e 2009 e a normal climatológica em Brasília (DF).

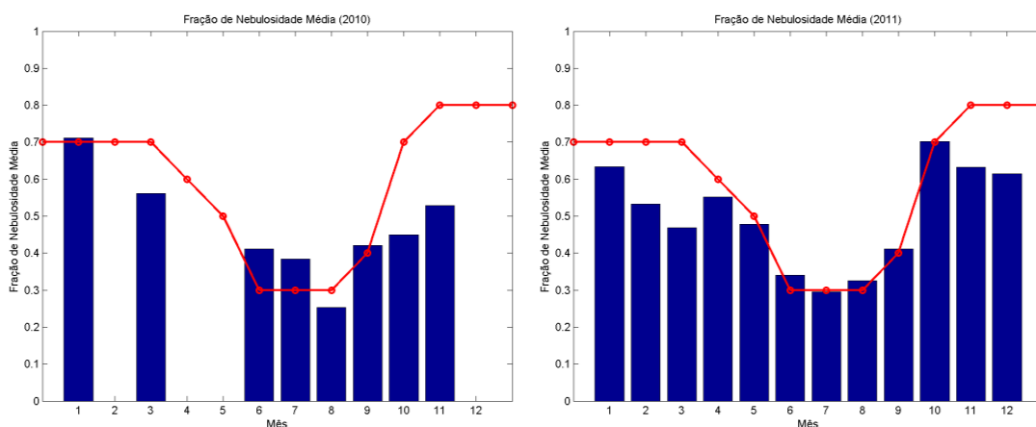


Figura A2 – Comparação entre as médias mensais da fração de cobertura de nuvens estimada dos anos de 2010 e 2011 e a normal climatológica em Brasília (DF).

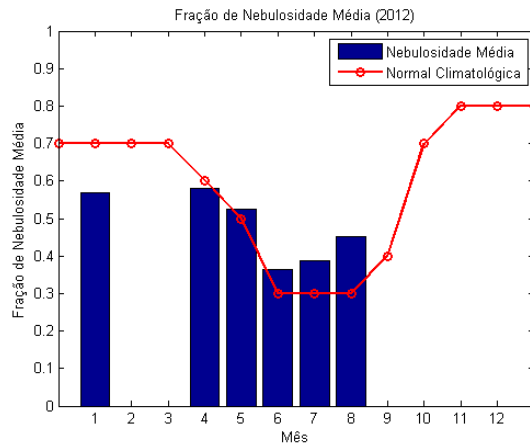


Figura A3 – Comparação entre as médias mensais da fração de cobertura de nuvens estimada de 2012 e a normal climatológica em Brasília (DF).

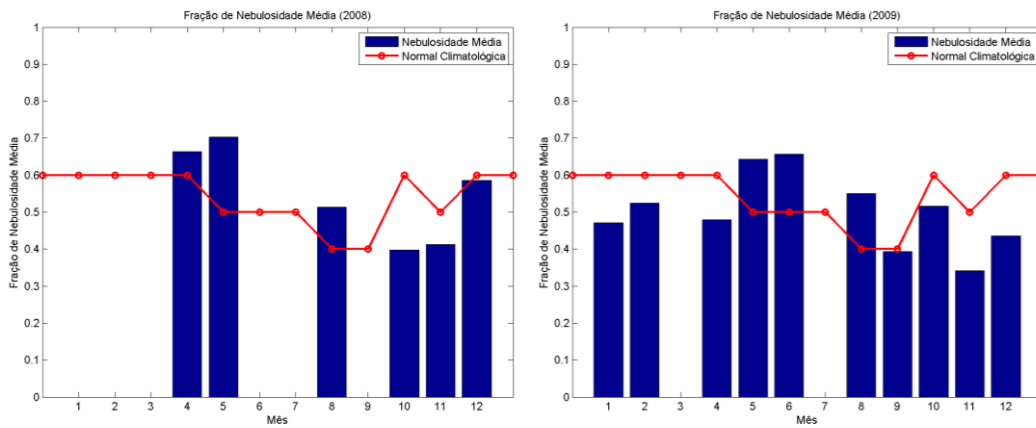


Figura A4 – Comparação entre as médias mensais da fração de cobertura de nuvens estimada dos anos de 2008 e 2009 e a normal climatológica em Petrolina (PE).

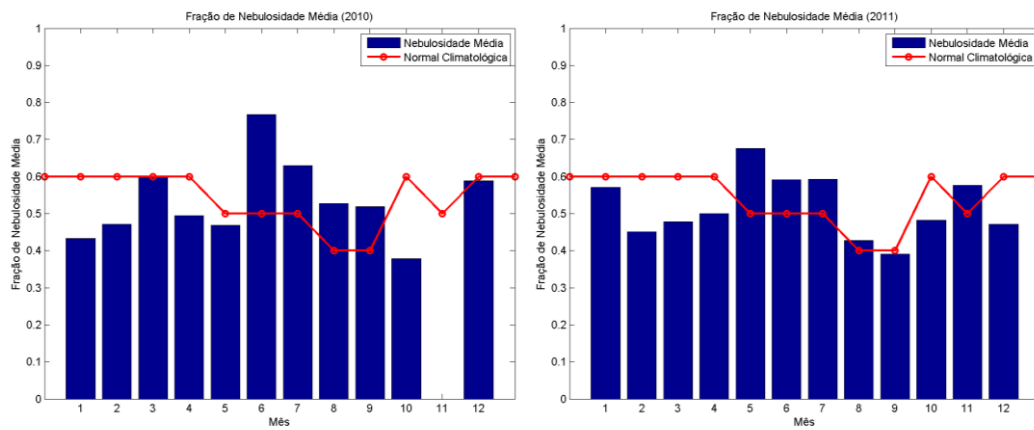


Figura A5 – Comparação entre as médias mensais da fração de cobertura de nuvens estimada dos anos de 2008 e 2009 e a normal climatológica em Petrolina (PE).

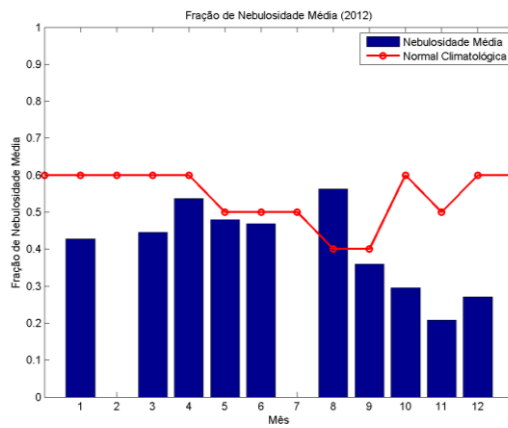


Figura A6 – Comparação entre as médias mensais da fração de cobertura de nuvens estimada do ano de 2012 e a normal climatológica em Petrolina (PE).