



MINISTÉRIO DA CIÊNCIA E TECNOLOGIA
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

AVALIAÇÃO DO POTENCIAL SOLAR DO SUL DO BRASIL

RELATÓRIO FINAL DE PROJETO DE INICIAÇÃO CIENTÍFICA (PIBIC/CNPq/INPE)

PROCESSO N° 103081/2011-9

Luiz Felipe Kremer – Bolsista PIBIC/INPE – CNPq/MCT
Laboratório de Recursos de Energia Renováveis
LRER/CRS/CCR/INPE – MCT
Centro Regional Sul de Pesquisas Espaciais
CRS/CCR/INPE – MCT
E-mail: luiz.kremer@lacesm.ufsm.br

Dr. Fernando Ramos Martins
Orientador
Centro de Ciência do Sistema Terrestre
CCST/INPE – MCT
Instituto Nacional de Pesquisas Espaciais
INPE – MCT
E-mail: fernando.martins@inpe.br

Santa Maria, Junho de 2011



Relatório Final de Atividades, 2011

**RELATÓRIO FINAL DE INICIAÇÃO CIENTÍFICA DO
PROGRAMA: PIBIC/INPE – CNPq/MCT**

PROJETO

AVALIAÇÃO DO POTENCIAL SOLAR DO SUL DO BRASIL

PROCESSO: 103081/2011-9

**Relatório elaborado por LUIZ FELIPE KREMER, em substituição a
MARCIO CECONI, relativo ao período de Agosto de 2010 a Julho de 2011
de execução das atividades:**

Luiz Felipe Kremer – Bolsista PIBIC/INPE – CNPq/MCT

E-mail: luiz.kremer@lacesm.ufsm.br

Período: Fevereiro de 2011 a Julho de 2011

Marcio Ceconi – Ex-bolsista PIBIC/INPE – CNPq/MCT

E-mail: ceconi@lacesm.ufsm.br

Período: Agosto de 2010 a Janeiro de 2011

Dr. Fernando Ramos Martins – Orientador

Centro de Ciência do Sistema Terrestre

CCST/INPE – MCT

E-mail: fernando.martins@inpe.br

Dr. Nelson Jorge Schuch – Co-Orientador

Centro Regional Sul de Pesquisas Espaciais – CRS/CCR/INPE – MCT

E-mail: njschuch@lacesm.ufsm.br

Dr. Enio Bueno Pereira – Co-Orientador

Centro de Ciência do Sistema Terrestre

CCST/INPE – MCT

E-mail: enio.pereira@cptec.inpe.br

DADOS DE IDENTIFICAÇÃO

Título:

AVALIAÇÃO DO POTENCIAL SOLAR DO SUL DO BRASIL

Processo CNPq N°: 103081/2011-9

Bolsista no período de Fevereiro/11 a Julho/11:

Luiz Felipe Kremer

Curso de Física Bacharelado

Centro de Ciências Naturais e Exatas – CCNE/UFSM

Universidade Federal de Santa Maria – UFSM

Bolsista no período de Agosto/10 a Janeiro/11:

Marcio Ceconi

Curso de Física Bacharelado

Centro de Ciências Naturais e Exatas – CCNE/UFSM

Universidade Federal de Santa Maria – UFSM

Orientador:

Dr. Fernando Ramos Martins

Centro de Ciência do Sistema Terrestre – CCST/INPE - MCT

Centro de Previsão do Tempo e Estudos Climáticos – CPTEC/INPE - MCT

Co-Orientadores:

Dr. Nelson Jorge Schuch

Centro Regional Sul de Pesquisas Espaciais – CRS/CCR/INPE – MCT.

Dr. Enio Bueno Pereira

Centro de Ciência do Sistema Terrestre – CCST/INPE – MCT.

Colaboradores:

Bacharel Marcio Ceconi – Bacharel em Física e antigo membro do LRER/CRS/CCR/INPE – MCT.

Alexandre Ceretta Dalla Favera – Bolsista I.C. e Graduando do Curso de Engenharia Química da UFSM.



Relatório Final de Atividades, 2011

Eduardo Weide Luiz – Bolsista I.C. e Graduando do Curso de Meteorologia da UFSM.

Eng. Sylvio Luiz Mantelli Neto – Engenheiro responsável pela implantação das estações do Projeto SONDA.

Eng. Jorge Luiz Nogueira – Engenheiro responsável pelas estações do Projeto SONDA.

Locais de Trabalho/Execução do Projeto:

Laboratório de Recursos de Energias Renováveis – LRER/CRS/CCR/INPE – MCT

Observatório Espacial do Sul – OES/CRS/CCR/INPE – MCT

Trabalho desenvolvido no âmbito da Parceria: INPE/MCT – UFSM, através do Laboratório de Ciências Espaciais de Santa Maria – LACESM/CT – UFSM.



AGRADECIMENTOS

Agradeço ao Dr. Nelson Jorge Schuch por ter sido aceito no Grupo de Pesquisa e pela indicação como bolsista de Iniciação Científica PIBIC/INPE – CNPq/MCT.

Agradeço ao Dr. Fernando Ramos Martins pela orientação técnica e científica, apoio e correções durante o trabalho de pesquisa.

Agradeço aos colegas de Laboratório, Alexandre, Eduardo, Paulo e Marcio Ceconi, ex-integrante do LRER.

RESUMO

O objetivo do Projeto de Pesquisa é avaliar o potencial de energia solar no Sul do Brasil, estudando sua variabilidade espacial e temporal e a influência de variáveis climatológicas sobre a incidência de irradiação solar em superfície. O trabalho de pesquisa consiste na utilização de Redes Neurais Artificiais (RNAs), na criação de modelos computacionais que possam tornar-se operacionais na previsão de irradiação solar global para curtos períodos de tempo (até 72 horas de antecedência). As principais variáveis radiométricas e meteorológicas medidas na estação SONDA-SMS, no Observatório Espacial do Sul, foram utilizadas como preditores em modelos de RNAs do tipo *Perceptron* de Múltiplas Camadas (MLP), de acordo com as correlações observadas entre as mesmas e os dados de irradiação global. Diversos experimentos com diferentes combinações de variáveis e topologias de MLPs foram realizados, para os tempos de previsão 24h, 48h e 72h, visando a identificação do melhor conjunto preditores/MLP que apresentasse as previsões com maior confiabilidade. A avaliação, das previsões foi realizada através da análise de parâmetros estatísticos que avaliam o desvio entre as previsões fornecidas pelas MLPs e os valores efetivamente medidos. Os resultados obtidos para os tempos de previsão 24h e 48h foram similares no que tange à qualidade das estimativas, com desvios RMSE% próximos a 36%. Para as previsões com 72h de antecedência, observou-se má representatividade dos modelos de RNAs em suas respostas frente às entradas fornecidas, tendo-se considerado que o tempo de previsão é inadequado diante da metodologia adotada. Em todos os tempos de previsão, as respostas obtidas pelas MLPs mostraram-se coerentes quanto às flutuações sazonais da série de dados de irradiação solar, porém subestimando os valores máximos e sobreestimando os valores mínimos característicos da série.

SUMÁRIO

SIGLAS E ABREVIATURAS.....	12
CAPÍTULO 1.....	14
INTRODUÇÃO.....	14
CAPÍTULO 2.....	17
INFRA-ESTRUTURA UTILIZADA	17
2.1 – O Projeto SONDA.....	17
2.2 – Estação de Referência do Projeto SONDA instalada no Observatório Espacial do Sul – OES/CRS/CCR/INPE – MCT, em São Matinho da Serra – RS .	19
2.3 – O Laboratório de Recursos de Energia Renováveis do Centro Regional Sul de Pesquisas Espaciais – LRER/CRS/CCR/INPE – MCT.....	21
CAPÍTULO 3.....	22
A RADIAÇÃO SOLAR E A ATMOSFERA TERRESTRE.....	22
3.1 – A Radiação Solar.....	22
3.2 – A Atmosfera Terrestre	26
3.3 – Interações da Radiação Solar com a Atmosfera Terrestre	27
CAPÍTULO 4.....	30
REDES NEURAIS ARTIFICIAIS	30
4.1 – Inteligência Artificial e Redes Neurais Artificiais: Aspectos Básicos	30
4.2 – Arquiteturas das RNAs.....	32
4.4 – Perceptrons de Múltiplas Camadas (MLP).....	32
4.5 – O Modelo de um Neurônio Artificial.....	33
4.6 – Aprendizado das RNAs.....	36
CAPÍTULO 5.....	40
METODOLOGIA.....	40
5.1 – Seleção das Entradas e Saídas das RNAs	40
5.2 – Qualificação dos Dados para Emprego com RNAs.....	42



Relatório Final de Atividades, 2011

5.3 – Treinamento das RNAs para Previsão de Irradiação Solar Global..	43
5.4 – Notação para Descrição das RNAs.....	47
5.5 – Parâmetros Estatísticos Empregados na Validação das estimativas fornecidas pelas RNAs.....	48
CAPÍTULO 6.....	51
ATIVIDADES OPERACIONAIS DESENVOLVIDAS	51
6.1 – Revisão Bibliográfica.....	51
6.2 – Manutenção dos Equipamentos da Estação SONDA – SMS.....	51
6.3 – Coleta, Qualificação e Análise dos Dados da Estação SONDA – SMS	52
6.4 – Participação de eventos com apresentação de Trabalhos.....	52
CAPÍTULO 7.....	54
RESULTADOS	54
7.1 – RNAs com Tempo de Previsão Prev24h.....	54
7.2 – RNAs com Tempo de Previsão Prev48h.....	59
7.3 – RNAs com Tempo de Previsão Prev72h.....	64
7.4 – Comparação com Alguns Resultados da Literatura Científica.....	69
CONCLUSÕES	73
REFERÊNCIAS BIBLIOGRÁFICAS.....	74

LISTA DE FIGURAS

Figura 1.1 – Oferta interna de energia elétrica em 2009. Fonte: BEN (2010)....	15
Figura 2.1 – Logotipo da Rede SONDA.....	17
Figura 2.2 – Estações de coleta de dados do Projeto SONDA no Território Brasileiro, planejadas e em funcionamento. Fonte: (SONDA, 2010).....	18
Figura 2.3 – Plataforma com os equipamentos da Estação SONDA – SMS junto ao Prédio 1 do Observatório Espacial do Sul OES/CRS/CCR/ INPE – MCT.....	20
Figura 2.4 – Torre anemométrica instalada no Observatório Espacial do Sul OES/CRS/CCR/INPE – MCT, com destaque para os anemômetros instalados a 10, 25 e 50 metros de altura.....	21
Figura 3.1 – Foto do Sol obtida pelo Observatório Heliosférico e Solar.	22
Fonte: SOHO/NASA (2003).....	22
Figura 3.2 – Regiões a características do Sol.....	23
Fonte: SOHO/NASA.	23
Figura 3.3 – Espectro eletromagnético. Fonte: (Grimm, 2003).	23
Figura 3.4 – Variação da constante solar ao longo das últimas décadas. Fonte: (Goddard Space Flight Center – GSFC/NASA, 2003).	25
Figura 3.5 – Interações entre a radiação e a atmosfera. Fonte: (Gambi, 1998). .	27
Figura 4.2 – Esquema de uma MLP com duas camadas ocultas. Fonte: Haykin (2001).....	33
Figura 4.3 – Modelo de um neurônio artificial para uma rede MLP.....	34
Fonte: (Haykin, 2001).....	34

Relatório Final de Atividades, 2011

Figura 4.4 – Comportamento dos sinais de saída das funções de ativação: (a) função limiar; (b) função linear; (c) função logística; (d) função tangente hiperbólica. Fonte: Haykin (2001).	35
Figura 5.1 – Comparação dos valores de “Global 1” e “Global 2” aceitos no procedimento de qualificação das medidas adotado no Observatório Espacial do Sul. .	43
Figura 5.2 – Aplicação de uma MLP para previsão de séries temporais. Fonte: Paoli (2009).	46
Figura 7.1 – Desvios MSE do grupo de teste para as diferentes topologias de redes neurais MLP com uma camada interna.	56
Figura 7.2 – Desvios MSE do grupo de teste para as diferentes topologias de redes neurais MLP com duas camadas internas.	56
Figura 7.3 – Desempenho da melhor topologia obtida na previsão de irradiação global.	58
Figura 7.4 – Previsão da série temporal de irradiação global normalizada para o conjunto de validação, obtidos pela rede “3-5-3-1 LOG LIN”.	58
Figura 7.5 – Desvios MSE do grupo de teste para as diferentes topologias de redes neurais MLP com uma camada interna.	61
Figura 7.6 – Desvios MSE do grupo de teste para as diferentes topologias de redes neurais MLP com duas camadas internas.	61
Tabela 7.8 – Desempenho das melhores topologias iniciais de MLPs com a alteração das funções de ativação de suas camadas internas e de saída.	62
Figura 7.7 – Valores medidos e previstos pela melhor RNA para Prev48h.	63
Figura 7.8 – Previsão da série temporal de irradiação global normalizada para o conjunto de validação, obtidos pela rede “16-3-1 TAN TAN”.	63
Figura 7.9 – Desvios MSE do grupo de teste para as diferentes topologias de redes neurais MLP com uma camada interna.	66
Figura 7.10 – Desvios MSE do grupo de teste para as diferentes topologias de redes neurais MLP com duas camadas internas.	66

Relatório Final de Atividades, 2011

Figura 7.11 – Valores medidos e previstos pela melhor RNA para Prev72h.	68
Figura 7.12 – Previsão da série temporal de irradiação global normalizada para o conjunto de validação, obtidos pela rede “8-7-1 LOG LOG”.	68
Figura 7.13 – Comparação entre os valores reais (linha contínua) e as previsões (pontos vermelhos) de irradiação global obtidos por Paoli et al. (2009), juntamente com os erros de previsão (linha tracejada). Fonte: Paoli et al. (2009).	69
Figura 7.14 – Correlação entre os valores reais (eixo das abscissas) e as estimativas (eixo das ordenadas) de irradiação global obtida por Paoli (2009).	70
Fonte: Paoli et al. (2009).....	70
Figura 7.15 – Comparação entre os valores medidos e previstos de irradiação solar obtidos por Tseles et al. ([20--?]). Fonte: Tseles et al. ([20--?]).	70
Figura 7.16 – Correlação obtida por Tseles et al ([20--?]) entre os valores reais (eixo das abscissas) e as previsões (eixo das ordenadas). Fonte: Tseles et al. ([20--?]).	71
Figura 7.17 – Diagrama de dispersão das previsões da integral diária de irradiância solar para São Martinho da Serra/RS obtida por Guarnieri (2006). Fonte: Guarnieri (2006).	72
Figura 7.18 – Refinamento das previsões da integral diária de irradiância solar obtidas por Guarnieri (2006) para com o uso de RNAs. Fonte: Guarnieri (2006).	72

SIGLAS E ABREVIATURAS

ADALINE – *ADaptative Linear NEuron*

AERONET – *Aerosol Robotic Network*

BEN – Balanço Energético Nacional

BSRN – *Baseline Surface Radiation Network*

CCST/INPE – Centro de Ciências do Sistema Terrestre

CO₂ – Dióxido de Carbono

CPTEC/INPE – Centro de Previsão do Tempo e Estudos Climáticos

CRS/CCR/INPE – MCT – Centro Regional Sul de Pesquisas Espaciais

CT-ENERG – Fundo Setorial de Energia

EPE – Empresa de Pesquisa Energética

FINEP/MCT – Financiadora de Estudos e Projetos

IA – Inteligência Artificial

INPE – Instituto Nacional de Pesquisas Espaciais

IPCC – *Intergovernmental Panel on Climate Change*

IV – Infravermelho

$J s^{-1}$ – Joules por segundo

K – Kelvins

K⁺ – Potássio

km – Quilômetros

LACESM/CT – UFSM – Laboratório de Ciências Espaciais de Santa Maria

LIN – Função de ativação linear

LOG – Função de ativação sigmóide logística

LRER/CRS/CCR/INPE – MCT – Laboratório de Recursos de Energia Renováveis

MBE – *Mean Bias Error*

MCT – Ministério da Ciência e Tecnologia

MLP – *Perceptron* de Múltiplas Camadas

MSE – *Mean Square Error*

mV – Milivolts

Na⁺ – Sódio

Relatório Final de Atividades, 2011

N₂ – Nitrogênio

NNTool – Neural Network Toolbox (MATLAB)

O₂ – Oxigênio

O₃ – Ozônio

OES/CRS/CCR/INPE – MCT – Observatório Espacial do Sul

PMOA – Programa de Monitoramento do Ozônio Atmosférico

Prev24h – Previsão para 24 horas à frente

Prev48h – Previsão para 48 horas à frente

Prev72h – Previsão para 72 horas à frente

R – Coeficiente de correlação

R² - Coeficiente de Determinação

RBF – Radial Basis Function

RMSE – Root Mean Square Error

RNA – Rede Neural Artificial

RNAs – Redes Neurais Artificiais

RS – Rio Grande do Sul

SONDA – Sistema de Organização Nacional de Dados Ambientais

SONDA-SMS – Estação SONDA do Observatório Espacial do Sul

TAN – Função de ativação sigmóide tangente hiperbólica

Tb – *Terabits*

UFSM – Universidade Federal de Santa Maria

UV – Ultravioleta

VIS – Visível

W – Watts

Wm⁻² – Watts por metro quadrado

WMO – *World Meteorological Organization*

CAPÍTULO 1

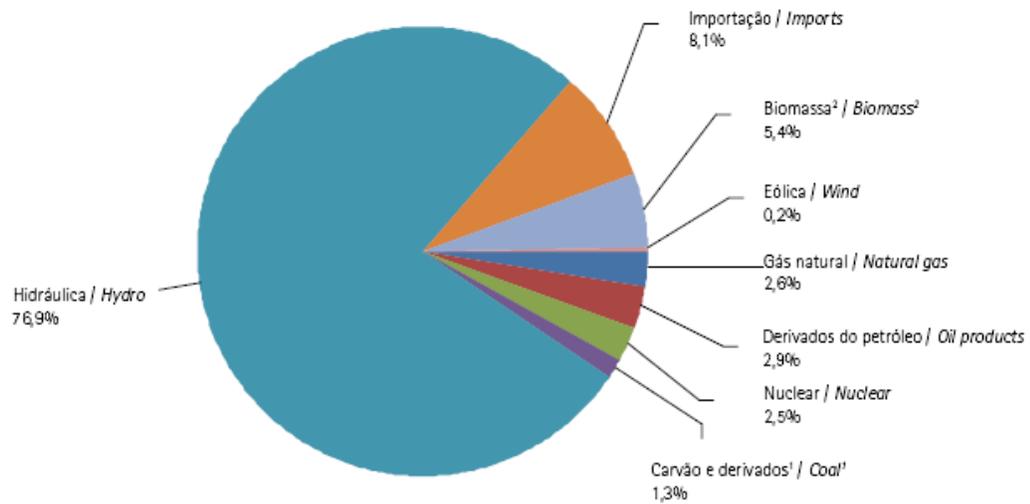
INTRODUÇÃO

Um bom planejamento do setor energético é determinante para o desenvolvimento de um País. No entanto, o contraste entre o aumento do consumo de energia, decorrente principalmente do crescimento econômico dos países em desenvolvimento e o esgotamento dos recursos energéticos mais utilizados atualmente, bem como a preocupação com a degradação ambiental gerada pela própria extração e aplicação desses recursos, tem incentivado a busca por fontes alternativas de energia, principalmente solar e eólica.

Nas palavras de Tomalsquim et al. (2007):

Desde a Revolução Industrial, a competitividade econômica dos países e a qualidade de vida de seus cidadãos são intensamente influenciadas pela energia. Em um mercado global e em face das crescentes preocupações com o meio ambiente, essa influência se mostra cada vez mais decisiva. Nesse contexto, as economias que melhor se posicionam quanto ao acesso a recursos energéticos de baixo custo e de baixo impacto ambiental obtêm importantes vantagens comparativas. Nas próximas décadas, essa questão se apresenta para o Brasil a um só tempo como um desafio e uma oportunidade. Desafio, porque o desenvolvimento econômico e social demandará uma expressiva quantidade de energia e com isso um alto grau de segurança e de sustentabilidade energéticas. Oportunidade, porque o Brasil dispõe de condições muito favoráveis no que diz respeito aos recursos energéticos renováveis e à tecnologia para transformar suas riquezas naturais em energia e dessa forma agregar valor à sua produção de riqueza (Tomalsquim et al., 2007).

O Balanço Energético Nacional (BEN), desenvolvido pela Empresa de Pesquisa Energética (EPE) é o documento que divulga, através de extensa pesquisa, a contabilidade referente à oferta e ao consumo de energia no Brasil. A mais recente edição do estudo, “Balanço Energético Nacional 2010 – Ano Base 2009”, que pode ser acessada através do endereço eletrônico <https://ben.epe.gov.br/>, traz a Figura 1.1 como gráfico da oferta interna de energia elétrica por fonte em 2009.

Relatório Final de Atividades, 2011

Notas / Notes:

1 Inclui gás de coqueria / Includes coke gas.

2 Biomassa inclui lenha, bagaço de cana, lixívia e outras recuperações / Biomass includes firewood, sugar cane bagasse, black liquor and other wastes.

Figura 1.1 – Oferta interna de energia elétrica em 2009. Fonte: BEN (2010).

Pode-se observar que o Brasil apresenta uma matriz de geração elétrica predominantemente renovável, com a geração interna hidráulica respondendo por um montante superior a 76% de oferta (BEN, 2010). No entanto, conforme destaca Guarnieri (2006):

[...] a energia hidroelétrica possui papel central na matriz energética brasileira no que diz respeito à geração de energia elétrica. Trata-se de uma forma de energia limpa quanto à emissão de poluentes para a atmosfera, embora a construção dos reservatórios ocasione alagamento de grandes áreas, afetando a fauna e a vegetação locais, e modificando o micro-clima regional. Porém, além desses impactos ambientais ainda não adequadamente avaliados, a dependência dessa forma de energia ao regime de chuvas cria vulnerabilidades em épocas de estiagem, como ocorreu no período de 1999 a 2001. Visando sustentar a oferta de energia a longo prazo e aumentar a confiabilidade do sistema, a reestruturação energética nacional atualmente em curso prevê a inclusão de recursos alternativos aos atualmente empregados (Guarnieri, 2006, p. 28).

Diante do exposto, torna-se necessário o estudo da disponibilidade dos recursos energéticos renováveis para diferentes localidades e em diferentes épocas do ano, em virtude das diferenças regionais e sazonalidade apresentada por essas fontes,

Relatório Final de Atividades, 2011

viabilizando investimentos na área e propiciando o desenvolvimento de novas tecnologias de aplicação.

Adicionalmente, “o conhecimento da irradiação solar incidente em superfície tem inúmeras aplicações em meteorologia, climatologia e para as atividades econômicas como a agropecuária, a arquitetura e a construção civil, principalmente no que diz respeito ao conforto térmico e à eficiência energética” (Pereira et al., 2006, p. 13).

Com esse intuito, o objetivo central desta pesquisa de iniciação científica é a avaliação da tendência futura de energia solar em superfície a partir da base de dados da estação de referência do Projeto SONDA (Sistema de Organização Nacional de Dados Ambientais) instalada no Observatório Espacial do Sul – OES/CRS/CCR/INPE – MCT, em São Martinho da Serra – RS (doravante denominada estação SONDA-SMS).

O estudo emprega o uso de modernas técnicas de Inteligência Artificial (IA), conhecidas como Redes Neurais Artificiais (RNAs), para o desenvolvimento de modelos computacionais para previsão, em curto prazo (até 72 horas), da integral diária de irradiância solar global medida em superfície.

São realizadas investigações das topologias de RNAs do tipo *Multilayer Perceptron* (MLP – *Perceptron* de Múltiplas Camadas) para obtenção dos resultados que melhor se adaptem como modelos de previsão de irradiação solar global.

CAPÍTULO 2

INFRA-ESTRUTURA UTILIZADA

2.1 – O Projeto SONDA

A Rede SONDA (Sistema de Organização Nacional de Dados Ambientais), cujo logotipo é apresentado na Figura 2.1, é coordenado e executado pelo Centro de Ciência do Sistema Terrestre (CCST/INPE), em parceria com o Centro de Previsão do Tempo e Estudos Climáticos (CPTEC/INPE) do Instituto Nacional de Pesquisas Espaciais – INPE/MCT,.



Figura 2.1 – Logotipo da Rede SONDA.

O objetivo da rede SONDA é a implantação de uma infra-estrutura física e de recursos humanos destinada à coleta, qualificação e análise de dados meteorológicos, eólicos e solarimétricos de alta qualidade, voltados para o desenvolvimento de pesquisas e conhecimento científico da disponibilidade dos recursos energéticos renováveis, em especial solares e eólicos, e validação de modelos climáticos.

O Projeto SONDA mantém diversas estações de coleta de dados de superfície espalhadas pelo território brasileiro, conforme apresentado na Figura 2.2. Essas estações são classificadas em Estações Solares, Anemométricas e Solares/Anemométricas, de acordo com os equipamentos instalados e o tipo de dados coletados.

As Estações Solares/Anemométricas são dotadas de um conjunto completo de equipamentos para monitoramento da radiação solar e dos ventos. Os sensores instalados nessas estações coletam dados das seguintes variáveis:

Relatório Final de Atividades, 2011

- (a) Medidas solares: irradiância solar global, irradiância solar difusa, irradiância solar direta normal ao plano de incidência, iluminância e radiação fotossinteticamente ativa;
- (b) Medidas eólicas: velocidade e direção dos ventos e temperatura nas alturas de 10 m, 25 m e 50 m a partir da superfície.
- (c) Medidas Meteorológicas: temperatura e umidade relativa do ar, pressão atmosférica e precipitação em superfície.

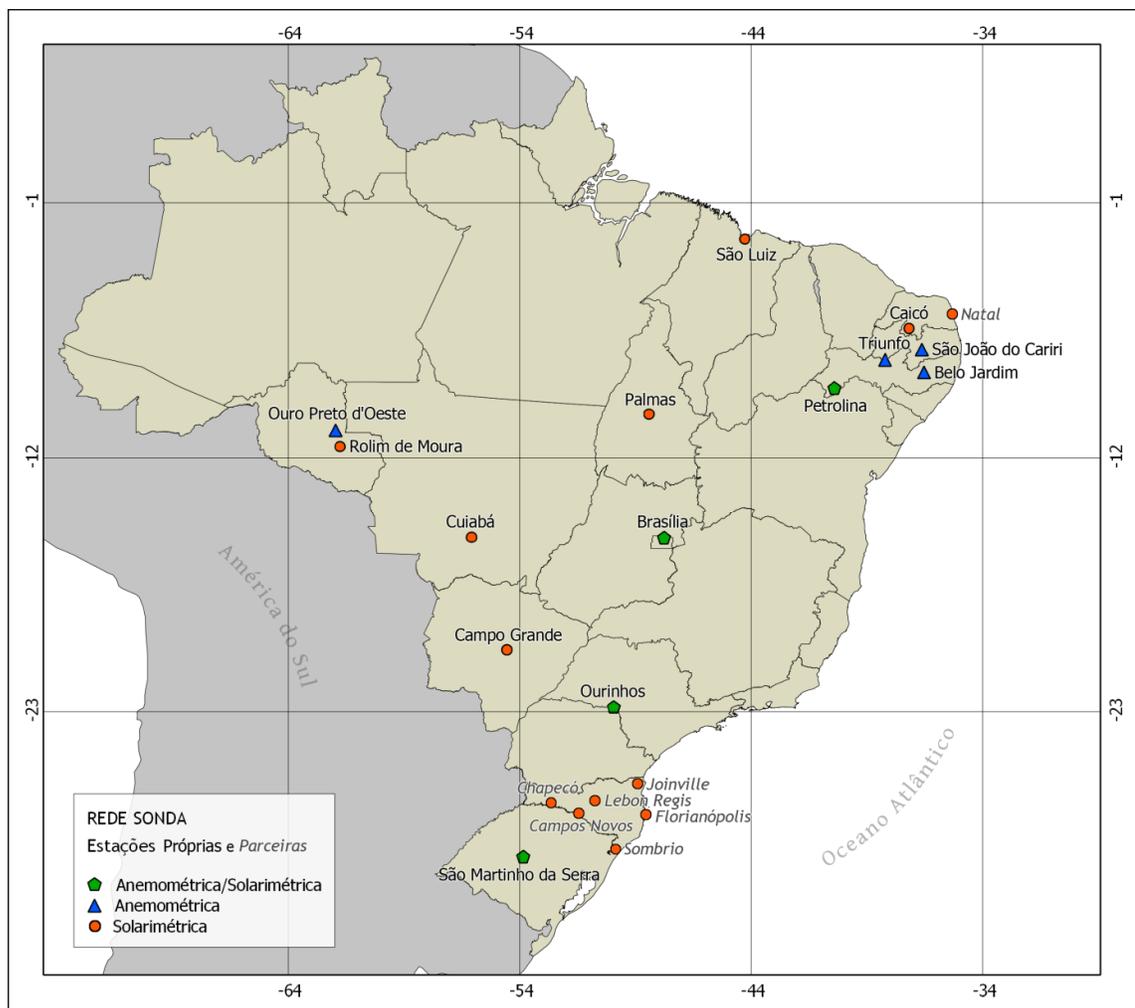


Figura 2.2 – Estações de coleta de dados do Projeto SONDA no Território Brasileiro, planejadas e em funcionamento. Fonte: (SONDA, 2010).

Relatório Final de Atividades, 2011

As estações Solares contam com sensores para medidas solares e meteorológicas, e as estações Anemométricas apenas com sensores eólicos instalados em torres para aquisição de dados em 3 altitudes em relação ao solo. Maiores informações sobre a rede SONDA, inclusive acesso à base de dados, podem ser obtidas através do endereço eletrônico <http://www.sonda.ccst.inpe.br/>.

2.2 – Estação de Referência do Projeto SONDA instalada no Observatório Espacial do Sul – OES/CRS/CCR/INPE – MCT, em São Matinho da Serra – RS

A estação de referência SONDA – SMS está instalada no Observatório Espacial do Sul (Latitude: 29°26'34" S, Longitude: 53°49'23" O), subunidade do Centro Regional Sul de Pesquisas Espaciais – OES/CRS/CCR/INPE – MCT, em São Matinho da Serra – RS. O Centro Regional Sul de Pesquisas Espaciais está localizado no Campus da Universidade Federal de Santa Maria (UFSM), Bairro Camobi, Santa Maria – RS.

Os principais equipamentos instalados na Estação SONDA – SMS estão listados abaixo:

- Piranômetro CM 21 (*Kipp & Zonen*) – efetua medidas de radiação solar global horizontal na faixa espectral de 0,3 μm a 2,8 μm .
- Piranômetro CM 22 (*Kipp & Zonen*) – efetua medidas de radiação solar difusa horizontal na faixa espectral de 0,2 μm a 3,6 μm .
- Pireliômetro NIP (*Eppley Laboratory, Inc*) – efetua medidas de radiação solar direta num plano normal à incidência da radiação.
- Pirgeômetro PIR (*Eppley Laboratory, Inc*) – efetua medidas de radiação de onda longa, ou radiação terrestre, na faixa espectral de 3,5 μm a 50 μm .
- LUX Lite (*Kipp & Zonen*) – efetua medidas de luz visível, expressando o resultado em iluminância.
- PAR Lite (*Kipp & Zonen*) – efetua medidas de radiação fotossinteticamente ativa (PAR) sob ocorrência natural da luz do dia, na faixa de 400 nm a 700 nm.
- Two Axis Positioner – 2AP (*Kipp & Zonen*) – é um rastreador, ou *tracker*, responsável pelo posicionamento dos ocultadores do disco solar e dos equipamentos.
- Total Sky Imager TSI – 440 (*YES, Inc*) – é um equipamento que captura imagens do céu com uma câmera CCD apontada para o centro de um espelho convexo, que reflete a imagem do céu diretamente para as lentes da câmera.

Relatório Final de Atividades, 2011

- Sensor Temperatura e Umidade do Ar Model 41372 (*R. M. Young Company*) – efetua medidas de temperatura e umidade relativa do ar.
- Sensor Temperatura do Ar Model 41342 (*R. M. Young Company*) – efetua medidas de temperatura do ar através de um sensor de latina.
- Sensor de Pressão Barométrica Vaisala PTB101 – efetua medidas de pressão na faixa de 600 mb a 1060 mb, utilizando um sensor capacitivo.
- Anemômetro Modelo 05106 (*R. M. Young Company*) – mede a velocidade horizontal e a direção do vento de 0 até 60 m/s.



Figura 2.3 – Plataforma com os equipamentos da Estação SONDA – SMS junto ao Prédio 1 do Observatório Espacial do Sul OES/CRS/CCR/ INPE – MCT.

Os equipamentos, juntamente com os equipamentos do Programa de Monitoramento do Ozônio Atmosférico (PMOA), estão instalados em uma plataforma de 3 m de altura ao lado do Prédio Um do Observatório Espacial do Sul (Figura 2.3) e numa torre eólica (Figura 2.4), onde estão instalados três anemômetros a 10, 25 e 50 metros e medidores da temperatura do ar a 1 e 50 metros de altura.

Os dados coletados pelos equipamentos são armazenados, com uma resolução temporal de 1 a 10 minutos, em um Datalogger CR23X Micrologger (*Campbell Sci.*), situado no interior do Prédio 1.

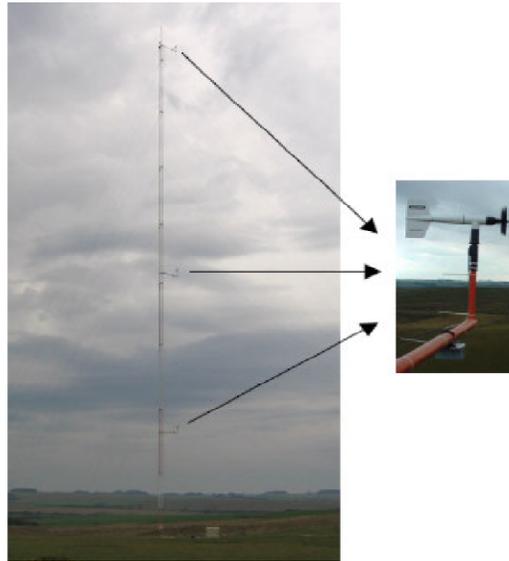


Figura 2.4 – Torre anemométrica instalada no Observatório Espacial do Sul OES/CRS/CCR/INPE – MCT, com destaque para os anemômetros instalados a 10, 25 e 50 metros de altura.

2.3 – O Laboratório de Recursos de Energia Renováveis do Centro Regional Sul de Pesquisas Espaciais – LRER/CRS/CCR/INPE – MCT

O Laboratório de Recursos de Energia Renováveis (LRER), pertencente ao Centro Regional Sul de Pesquisas Espaciais – CRS/CCR/INPE – MCT, foi criado no ano de 2003 pelo Dr. Nelson Jorge Schuch, e está localizado no Campus da Universidade Federal de Santa Maria (UFSM), em Santa Maria – RS.

O LRER, por iniciativa do Dr. Nelson Jorge Schuch, possui uma parceria com o grupo de Meteorologia em Energia que coordena a rede SONDA, desenvolvendo pesquisas na área de energias renováveis com o objetivo de obter o perfil da Região Central do Rio Grande do Sul quanto ao potencial solar e eólico. Os alunos selecionados para a realização de atividades de Iniciação Científica e Tecnológica, I.C.&T., são responsáveis pela manutenção dos equipamentos em operação na estação SONDA instalada em São Martinho da Serra – RS. Os resultados das pesquisas desenvolvidas no Laboratório têm sido apresentados em eventos científicos com amplitude nacional e internacional.

CAPÍTULO 3

A RADIAÇÃO SOLAR E A ATMOSFERA TERRESTRE

3.1 – A Radiação Solar

O Sol é a estrela mais próxima da Terra (Figura 3.1). Seu diâmetro, de aproximadamente 1,4 milhões de quilômetros, o torna uma estrela de tamanho médio. Apesar disso, o Sol está entre os 5 % dos astros mais brilhantes da Via Láctea.

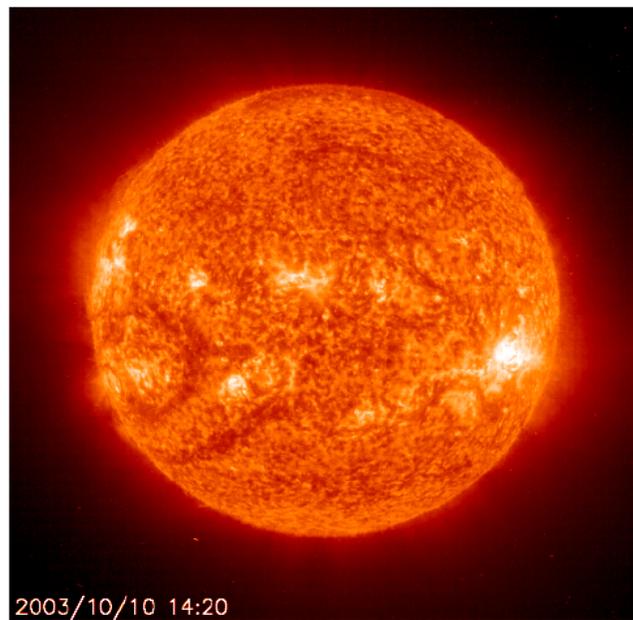


Figura 3.1 – Foto do Sol obtida pelo Observatório Heliosférico e Solar.

Fonte: SOHO/NASA (2003).

O Sol é um corpo de gás incandescente composto principalmente de hidrogênio. Sua estrutura física é complexa, Figura 3.2, mas pode ser considerada como composta das seguintes partes: o núcleo, a zona de convecção, a fotosfera, a camada de reversão, a cromosfera e a coroa (Iqbal, 1983).

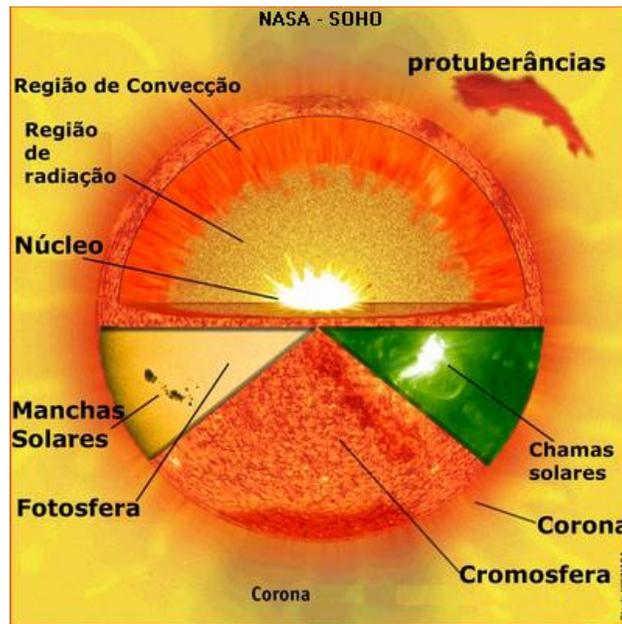


Figura 3.2 – Regiões a características do Sol.

Fonte: SOHO/NASA.

O Sol emite um espectro contínuo de radiação eletromagnética, com uma distribuição espectral similar a da radiação de um de corpo negro a 6000 K, seguindo aproximadamente a lei de Plank para a emissão de radiação (Coulson, 1975; Brasseur e Solomon, 1986; Lenoble, 1993; apud Guarnieri, 2006, p. 31). De acordo com Peixoto et al. (1992), a radiação solar cobre todo o espectro eletromagnético, apresentado na Figura 3.3, mas a contribuição mais significativa, associada com a transferência de energia radiativa no sistema climático, é compreendida entre o ultravioleta e o infravermelho próximo.

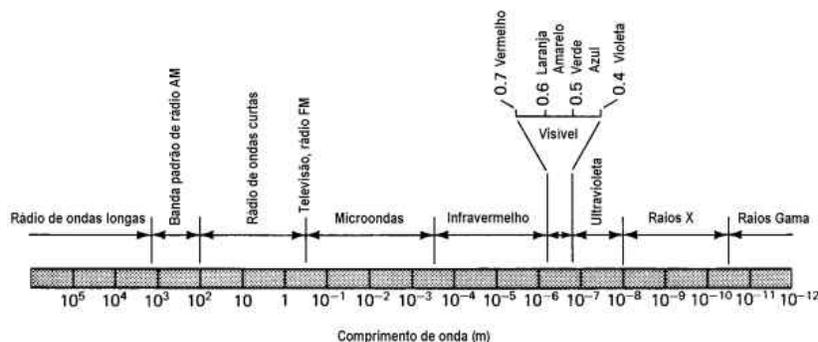


Figura 3.3 – Espectro eletromagnético. Fonte: (Grimm, 2003).

Relatório Final de Atividades, 2011

As regiões do espectro estão divididas em subdivisões não bem definidas, as quais apresentam características e mecanismos específicos de interação com os constituintes atmosféricos. Uma das divisões mais divulgadas na literatura é apresentada na Tabela 3.1.

Tabela 3.1 – Subdivisões das regiões Ultravioleta, Visível e Infravermelho do Espectro Eletromagnético. Fonte: (<http://www.geotec-rs.com.br/espectro.html>).

Região	Comprimento de Onda	Subdivisão	Comprimento de Onda
Ultravioleta (UV)	10 – 400 nm	UV-C	10 – 280 nm
		UV-B	280 – 320 nm
		UV-A	320 – 400 nm
Visível (VIS)	400 – 700 nm	Violeta	400 – 430 nm
		Índigo	430 – 450 nm
		Azul	450 – 500 nm
		Verde	500 – 570 nm
		Amarelo	570 – 590 nm
		Alaranjado	590 – 610 nm
		Vermelho	610 – 700 nm
Infravermelho (IV)	700nm – 1000 μ m	IV Próximo (NIR)	0,7 – 1,5 μ m
		IV de Onda Curta	1,5 – 3,0 μ m
		IV Médio	3,0 – 8,0 μ m
		IV de Onda Longa	8,0 – 15 μ m
		IV Distante	> 15 μ m

“A radiação solar constitui a força motriz para os movimentos atmosféricos e para outros processos térmicos, dinâmicos e químicos que ocorrem na atmosfera e na superfície terrestre” (Brasseur e Solomon, 1986; apud Guarnieri, 2006, p. 33).

A transferência radiativa é o mecanismo pelo qual o sistema Terra-Atmosfera realiza praticamente toda a troca de energia com o resto do Universo (Wallace e Hobbs, 1977). Quando parte da energia proveniente do Sol é interceptada pela Terra, os diferentes comprimentos de onda da radiação interagem de forma diferente com os constituintes atmosféricos, sofrendo processos de absorção e espalhamento.

É importante ter em mente algumas definições importantes para o estudo dos processos radiativos na atmosfera:

Relatório Final de Atividades, 2011

A taxa de transferência de energia pela radiação eletromagnética é chamada de fluxo radiante, expresso em unidades de energia por unidade de tempo: Joules por segundo (Js^{-1}) ou Watts (W). A densidade de fluxo radiante é o fluxo radiante que atravessa uma unidade de área, expressa em Watts por metro quadrado (Wm^{-2}), sendo também denominada emitância ou irradiância, quando representa o fluxo emergindo ou incidindo em uma área (Kidder e Vonder Haar, 1995; apud Guarnieri, 2006, p. 33).

A quantidade de energia radiante que atravessa uma superfície durante certo intervalo de tempo, por unidade de área, é a irradiação (Plana-Fattori e Ceballos, 2005), correspondendo à integração da irradiância durante um intervalo de tempo. A quantidade total média de irradiação que atinge a órbita da Terra, num plano perpendicular aos raios solares, no topo da atmosfera, é denominada constante solar. Seu valor é de aproximadamente 1368 Wm^{-2} . Apesar do nome, a constante solar, na verdade, varia ligeiramente em função da distância Terra-Sol durante o ano e com o ciclo solar, conforme ilustrado na Figura 3.4.

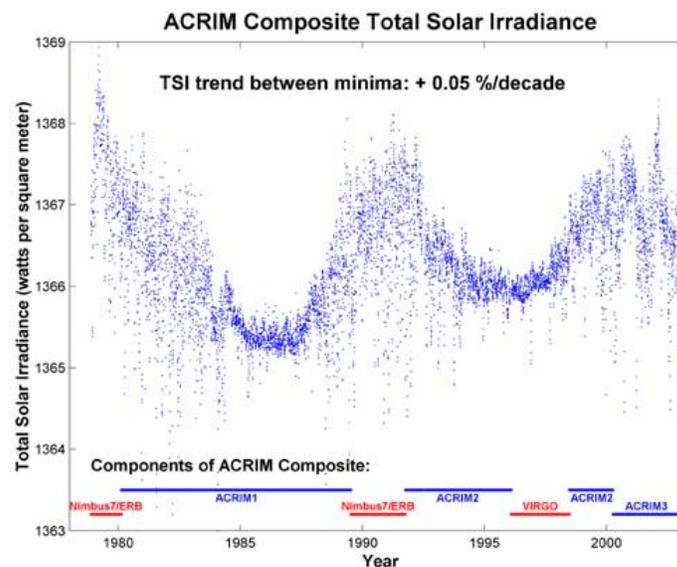


Figura 3.4 – Variação da constante solar ao longo das últimas décadas. Fonte: (Goddard Space Flight Center – GSFC/NASA, 2003).

3.2 – A Atmosfera Terrestre

Wallace e Hobbs (1977) afirmam que atmosfera terrestre é constituída por um grupo de gases com concentração praticamente constante e outro grupo com concentração variável. A fração seca da atmosfera (sem vapor d'água) é formada por 99% de Nitrogênio (N_2) e Oxigênio (O_2) e de 1% de Argônio e outros gases. Os demais constituintes gasosos da atmosfera são os chamados gases-traço, que apesar de sua baixa concentração são importantes nos processos radiativos.

O dióxido de carbono (CO_2), embora constitua apenas 0,03% da atmosfera da Terra, é essencial para a fotossíntese, além de participar do efeito estufa, propiciando a estabilidade da temperatura média da superfície terrestre. Isso se deve à propriedade do dióxido de carbono absorver radiação no infravermelho e reter parte da energia que seria perdida para o espaço, dentro do sistema Terra-Atmosfera. O percentual de dióxido de carbono vem crescente principalmente devido à ação antropogênica com a queima de biomassa e combustíveis fósseis como o carvão, o petróleo e o gás natural, intensificando o seu papel no efeito estufa, o que vem causando um desequilíbrio no sistema (IPCC, 2007).

O vapor d'água é um dos constituintes mais variáveis na atmosfera. Nos trópicos pode representar mais do que 4% do volume da baixa atmosfera, enquanto que sobre os desertos e regiões polares pode representar apenas 1%. O vapor d'água também tem grande capacidade de absorver a radiação disponível, tanto a de onda longa quanto algumas faixas do espectro solar.

Outro importante gás na atmosfera é o ozônio (O_3), que apresenta baixa concentração em relação a outros gases e uma distribuição espacial e temporal não uniforme. O ozônio concentra-se majoritariamente entre 10 km e 50 km de altura, sendo encontrado em concentrações menores na baixa atmosfera. Porém, possui concentração elevada no ar poluído das grandes cidades, onde, segundo Andrade (2006), “é gerado principalmente por processos fotoquímicos envolvendo a radiação solar e gases precursores como os óxidos de nitrogênio e os compostos orgânicos voláteis”. De acordo com Sayao (2008), a concentração de O_3 apresenta valor máximo em torno de 30 km de altitude, na região da estratosfera, e sua distribuição também varia com a latitude, estação do ano, horário, padrões de tempo e variabilidade da atividade solar. A

formação do ozônio na camada entre 10 km e 50 km é resultado de uma série de processos que envolvem a absorção da radiação solar e dissociação do oxigênio molecular em atômico após interação com a radiação solar na faixa do ultravioleta.

A atmosfera mantém em suspensão partículas de aerossóis emitidas por fontes naturais e antropogênicas. O IPCC (*Intergovernmental Panel on Climate Change – 2007*) indica que, uma vez na atmosfera, os aerossóis participam de vários processos, de acordo com suas características físicas e morfológicas, como a formação de gotas de nuvens e nas interações com a radiação solar e terrestre. Com exceção do aerossol inserido na estratosfera, principalmente pela erupção de vulcões, os demais ficam confinados nas primeiras camadas mais densas da atmosfera, principalmente a troposfera (IPCC, 2007).

3.3 – Interações da Radiação Solar com a Atmosfera Terrestre

A radiação solar, no percurso pela atmosfera, sofre processos de absorção e espalhamento (Liou, 1980). Somente em torno de 25% da radiação atinge diretamente a superfície da Terra, sem sofrer nenhum processo físico na atmosfera. Os 75% restante é absorvido, refletido de volta para o espaço ou espalhado atingindo a superfície terrestre em uma direção diferente daquela com que incidiu no topo da atmosfera. Os processos são ilustrados na Figura 3.5, e dependem do comprimento de onda da radiação e do tamanho e natureza do gás ou particulado atmosférico que interage com a radiação solar.

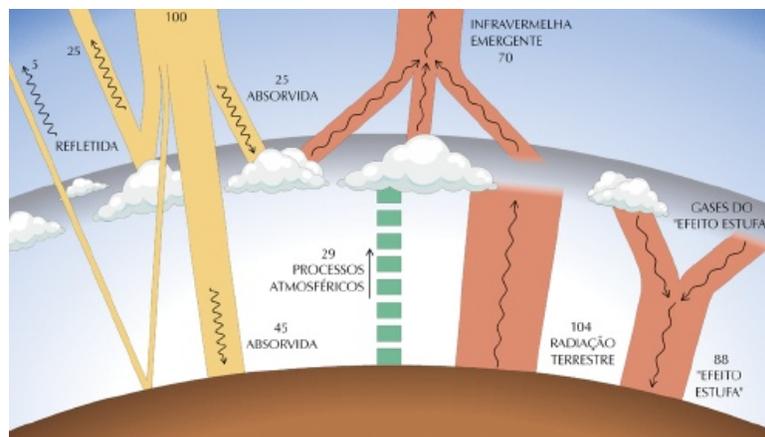


Figura 3.5 – Interações entre a radiação e a atmosfera. Fonte: (Gambi, 1998).

Relatório Final de Atividades, 2011

A absorção da radiação solar na atmosfera é realizada principalmente pelo ozônio atmosférico na faixa de radiação ultravioleta; e por vapor d'água e dióxido de carbono nas bandas do infravermelho. O espalhamento é causado principalmente pela interação da radiação com moléculas de ar, água e poeira.

Segundo Liou (1980), o espalhamento ocorre em todos os comprimentos de onda do espectro eletromagnético. “O espalhamento é um processo físico no qual uma partícula ou molécula gasosa no caminho da onda eletromagnética remove energia da onda incidente e dispersa essa energia em qualquer outra direção” (Peixoto e Oort, 1992). A razão entre o tamanho do espalhador e o comprimento de onda da radiação incidente determina o regime de espalhamento. O regime de espalhamento Rayleigh ocorre quando o espalhador é muito menor do que o comprimento de onda da radiação. Para espalhadores com tamanho comparável ao da radiação incidente ou maiores, o regime é referenciado como espalhamento Mie. Finalmente, se o tamanho do espalhador partícula é muito maior que o comprimento de onda, o espalhamento da radiação incidente é explicado pela ótica geométrica (Liou, 1980). O espalhamento pelo regime Rayleigh é inversamente proporcional à quarta potência do comprimento de onda da radiação. No regime Mie praticamente não há dependência entre o espalhamento e o comprimento de onda da radiação.

“A reflexão é um caso particular de espalhamento, que ocorre na interface entre dois meios diferentes, quando parte da radiação que atinge esta interface é enviada de volta com ângulo de reflexão igual ao ângulo de incidência” (Fiorin, 2009).

Na absorção da radiação solar, as moléculas dos gases adquirem uma parcela da energia incidente, que é transformada em movimento molecular interno detectado pelo aumento da temperatura. Desta forma, aquecimento da atmosfera ocorre preponderantemente devido à presença de gases absorvedores. Esses gases absorvem diferentemente os comprimentos de onda da radiação solar e da radiação terrestre de acordo com as características físico-químicas de cada gás e às diferentes interações possíveis, decorrentes dos diferentes tipos de reações e processos fotoquímicos que as moléculas gasosas podem sofrer.

Normalmente, empregam-se divisões dos feixes de radiação solar que atingem a superfície terrestre em duas componentes: irradiância solar direta e irradiância solar difusa. A irradiância solar direta corresponde à parcela de radiação que chega à

Relatório Final de Atividades, 2011

superfície na mesma direção do disco solar, tendo sofrido nenhuma ou pouca interação com a atmosfera. A irradiância solar difusa engloba a radiação vinda de todas as demais direções, devido aos processos de espalhamento descritos anteriormente.

Para efeitos práticos, costuma-se medir a irradiância solar direta em um plano normal à incidência do feixe de radiação, que é referenciada como irradiância solar direta normal, ou simplesmente irradiância normal. Após aplicada uma correção nessas medidas com a multiplicação pelo cosseno do ângulo zenital, obtém-se a irradiância solar direta horizontal, que neste trabalho será muitas vezes referenciada apenas como irradiância solar direta. A soma das medidas de irradiância difusa e de irradiância direta horizontal constitui a chamada irradiância solar global, que, integrada durante o período do nascer e pôr do Sol fornece a quantidade total de energia solar que chegou à superfície terrestre durante um dia.

CAPÍTULO 4

REDES NEURAIS ARTIFICIAIS

4.1 – Inteligência Artificial e Redes Neurais Artificiais: Aspectos Básicos

De acordo com Ferrari (2005, p. 5), citando resultados obtidos em uma pesquisa *online* por conceitos, a Inteligência Artificial (IA) é uma “área multidisciplinar que engloba ciência da computação, neurociência, filosofia, psicologia, robótica e linguística, dedicada a reproduzir os métodos ou resultados do raciocínio humano e da atividade cerebral”.

No entanto, é difícil definir exatamente o termo Inteligência Artificial (IA). Conforme Ludwig et al. (2007, p. 2), citando Ludwig Wittgenstein, filósofo austríaco reconhecido como um dos maiores pensadores do século XX, a linguagem é uma armadilha que pode nos seduzir a tentar definir o indefinível. Talvez o fenômeno da inteligência seja um destes conceitos indefiníveis. De acordo com Ludwig et al. (2007, p. 2), ao invés de definir o termo Inteligência Artificial, pode-se simplesmente delimitar quais as principais habilidades que uma máquina inteligente deve apresentar:

- Capacidade de realizar inferências e resolver problemas;
- Capacidade de planejamento;
- Capacidade de acumular e manipular conhecimento;
- Compreensão de linguagem natural;
- Capacidade de aprender com ou sem supervisão
- Capacidade de interpretar estímulos sensoriais.

Não serão abordados maiores aspectos do problema, uma vez que não são imprescindíveis para o entendimento do trabalho. Para maiores informações, podem ser consultadas literaturas especializadas no assunto, como Ludwig et al. (2007), Haykin (2001) e Ferrari (2005).

O ser humano é dotado de complexos circuitos neurais cerebrais que constam de variadas conexões entre seus neurônios (sinapses) interagindo entre si de modo a fazer emergir comportamento inteligente. Sendo assim, surge a idéia de que, se conseguirmos

Relatório Final de Atividades, 2011

modelar computacionalmente essas conexões neurais, poderíamos fazer emergir comportamentos também inteligentes em máquinas. Neste contexto, surgem as Redes Neurais Artificiais (RNAs), que são inspiradas na própria natureza das redes de neurônios e sinapses biológicas. Segundo Vieira et al. (19--?), o estudo das Redes Neurais Artificiais tem alta relevância para os pesquisadores de Inteligência Artificial, sendo objeto de crescentes pesquisas e servindo como valiosa ferramenta para diversas aplicações. Conforme Haykin (2001, p.2), as redes neurais artificiais são sistemas paralelos e distribuídos, constituídos de unidades simples denominadas nodos ou neurônios, que computam determinadas funções matemáticas (especialmente não-lineares) a partir de entradas recebidas. “Estas unidades são dispostas paralelamente constituindo camadas e são interligadas com as unidades das camadas vizinhas por conexões geralmente associadas a pesos. Por analogia às interligações dos neurônios no cérebro humano, as conexões entre unidades de uma rede neural são chamadas sinapses, sendo os pesos denominados pesos sinápticos” (Guarnieri, 2006, p. 53).

De acordo com Fiorin (2009), as RNAs apresentam-se como ferramentas capazes de armazenar conhecimento a partir de exemplos, e serem aplicadas em problemas de ajuste de funções, reconhecimento de padrões e outras aplicações. Além disto, as capacidades de generalização, auto-organização e processamento temporal as tornam ativas para a resolução de problemas com diferentes graus de complexidade.

Guarnieri (2006, p. 53) destaca que “a solução de um problema com RNAs passa inicialmente por uma fase de aprendizagem, onde os pesos das conexões são ajustados até proporcionarem à rede a capacidade de representar o problema”. Os pesos sinápticos são então fixados, e a rede passa ser empregada como um modelo, no sentido de estimar saídas a partir de entradas recebidas.

Fiorin (2009) descreve em seu estudo que durante a década de 80, houve uma nova explosão de interesse pelas RNAs, baseada nos avanços da tecnologia, especialmente microeletrônica, e na estagnação nas pesquisas na linha simbolista de Inteligência Artificial.

4.2 – Arquiteturas das RNAs

A escolha da arquitetura de uma RNA está relacionada com o tipo de problemas a ser abordado e é definida por um conjunto de quatro parâmetros principais: o número de camadas da rede, o número de nodos em cada camada, o tipo de conexão entre os nodos e a topologia da rede (Fiorin, 2009).

Em relação ao número de camadas de uma RNA, existem redes de camada única, com somente um nodo entre a entrada e a saída da rede, sendo restritas à solução de problemas linearmente separáveis, e redes de múltiplas camadas, que possuem um conjunto de neurônios de entrada, uma camada de saída e uma ou mais camadas intermediárias, também referenciadas como camadas ocultas ou internas neste trabalho.

As conexões entre os nodos de uma rede neural podem ser do tipo *feedforward* (acíclica) ou *feedback* (cíclica). A diferença básica é que, para a primeira, a saída de um nodo só poderá servir de entrada para um nodo de uma camada posterior, ao contrário da segunda, para a qual a saída de um nodo pode servir de entrada para um nodo de uma mesma camada ou de uma camada inferior. Quando ocorre a realimentação das saídas nas camadas de entrada da rede, ele é dita recorrente.

Entre as principais classes de redes neurais existentes, podem ser destacadas as redes *Perceptron* e *Adaline*, *Perceptrons* de Múltiplas Camadas (MLP), Memórias Matriciais, Redes *Self-Organizin*, Sistemas Neurais Híbridos, Redes Neurais sem Pesos, Redes de Funções de Base Radiais (*Radial Basis Function* – RBF), Redes Construtivas e Redes de Processamento Temporal. Para informações detalhadas sobre cada uma das classes de RNAs, pode-se consultar Haykin (2001).

No Trabalho de Pesquisa, somente são utilizadas redes do tipo *Perceptron* de Múltiplas Camadas (MLP), devido à sua conhecida capacidade de representação de problemas de caráter não-linear, conforme destacado por Cybenko (1988). Essa topologia de RNA é melhor discutida no tópico seguinte.

4.4 – *Perceptrons* de Múltiplas Camadas (MLP)

As RNAs do tipo *Perceptron* de Múltiplas Camadas (*Multilayer Perceptron* – MLP) consistem de um conjunto de unidades sensoriais que constituem a camada de

entrada, uma ou mais camadas ocultas e uma camada de saída. Um exemplo de uma MLP com três entradas, duas camadas ocultas com quatro neurônios cada e uma camada de saída com um único neurônio é apresentado na Figura 4.2.

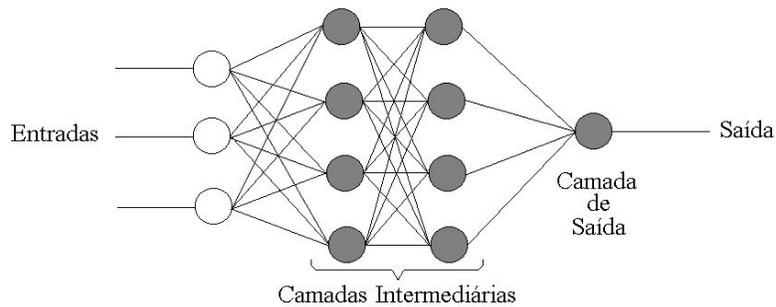


Figura 4.2 – Esquema de uma MLP com duas camadas ocultas. Fonte: Haykin (2001).

Segundo Cybenko (1988; apud Fiorin, 2009, p. 29), as redes MLP apresentam maior poder computacional atribuído às suas camadas internas, sendo aplicáveis a problemas que necessitam trabalhar com dados não linearmente separáveis. Já as redes com uma camada intermediária podem representar qualquer tipo de função contínua, enquanto que as redes com duas camadas intermediárias podem, em princípio, implementar qualquer função, linearmente separável ou não, em que a precisão obtida depende do número de neurônios das camadas intermediárias.

Não há método que predetermine a melhor combinação de camadas e neurônios em uma MLP, pois isso depende do modelo específico, dos processos físicos e do conjunto de dados de treinamento que a rede simulará. Segundo Tymvios et al. (2004), existem na bibliografia algumas relações empíricas para resolver este problema, mas o melhor método até o momento é a construção de vários modelos, escolhendo aquele que atinge um treinamento satisfatório e melhor se ajusta à aplicação abordada (Guarnieri, 2006, p. 56).

4.5 – O Modelo de um Neurônio Artificial

Os neurônios artificiais foram desenvolvidos de forma a manter um princípio de funcionamento similar aos neurônios biológicos. O modelo de neurônio apresentado na

Figura 4.3 pode ser visto como um neurônio genérico dentro da estrutura de uma rede MLP. Os valores das entradas ponderados pelos pesos sinápticos são combinados com outro valor ajustável, denominado bias (b_j) para formar o chamado nível de atividade interna do neurônio (v_j), conforme apresentado na Equação 4.1. A saída do neurônio (y_j) é produzida pela aplicação do nível de atividade interna em uma função de ativação (φ), representada na Equação 4.2.

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

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

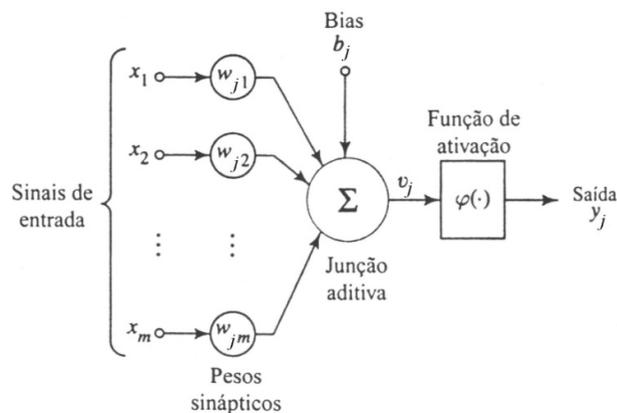


Figura 4.3 – Modelo de um neurônio artificial para uma rede MLP.

Fonte: (Haykin, 2001).

As funções de ativação mais utilizadas, de acordo com Haykin (2001), são a função limiar (degrau), a função linear e as funções sigmóides logística e tangente hiperbólica, apresentadas, respectivamente, nas Equações 4.3 a 4.6, com o comportamento dos seus sinais de saída esboçados na Figura 4.4.

i. Função Limiar:
$$\varphi(v_j) = \begin{cases} +\gamma & \text{se } v_j \geq 0 \\ -\gamma & \text{se } v_j < 0 \end{cases}$$

(4.3)

ii. Função Linear: $\varphi(v_j) = \alpha \cdot v_j$
(4.4)

iii. Função Sigmóide Logística: $\varphi(v_j) = \frac{1}{1+\exp(-\alpha v_j)}$
(4.5)

iv. Função Sigmóide Tangente Hiperbólica: $\varphi(v_j) = \operatorname{tgh}\left(\frac{v_j}{2}\right) = \frac{1-\exp(-v_j)}{1+\exp(-v_j)}$ (4.6)

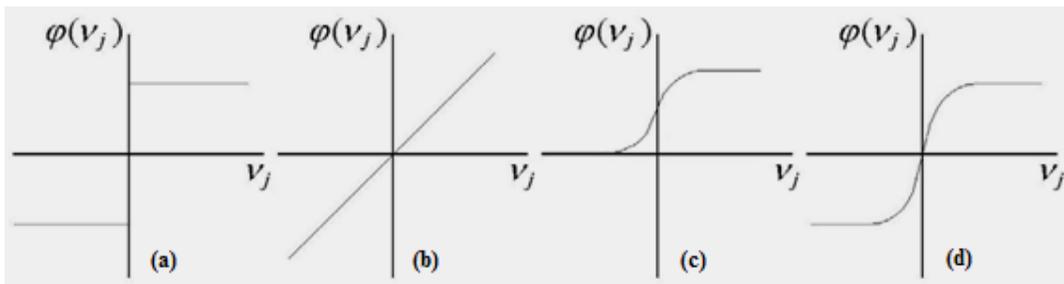


Figura 4.4 – Comportamento dos sinais de saída das funções de ativação: (a) função limiar; (b) função linear; (c) função logística; (d) função tangente hiperbólica. Fonte: Haykin (2001).

A função degrau é geralmente empregada com $\gamma=1$, e pode ser redefinida para que as saídas situem-se dentro do intervalo de 0 a 1 (neurônio de McCulloch e Pitts). A função linear definida com $\alpha =1$ permite que a saída do neurônio seja igual ao nível de atividade interna. As funções logística e tangente hiperbólica são dois tipos de funções sigmoidais, produzindo como saídas valores entre 0 e 1, e entre -1 e 1, respectivamente. Por serem contínuas, crescentes, diferenciáveis e não-lineares, as funções sigmoidais são as mais comumente utilizadas nas camadas ocultas de RNAs tipo MLP (Guarnieri, 2006, p. 58).

4.6 – Aprendizado das RNAs

Na etapa de aprendizado (ou treinamento), a rede neural ajusta seus pesos sinápticos de forma iterativa, a partir de um conjunto de exemplos, até que extraia as características necessárias para representar o problema considerado. Os pesos são fixados e utilizados para gerar novas respostas para o problema, a partir de interpolações e extrapolações de novas entradas, atuando como um modelo (Fiorin, 2009).

Os treinamentos podem ser classificados em supervisionados e não-supervisionados. No treinamento não-supervisionado, são fornecidos à rede somente valores de entrada que, após o ajuste dos pesos sinápticos, são organizados em diferentes classes, de acordo com suas características. Segundo Ludwig et al. (2007), este tipo de treinamento tem por finalidade a classificação dos dados pelo reconhecimento de padrões, ou seja, a detecção de características em comum entre conjuntos de dados. Por esse motivo, o emprego de RNAs com treinamento não-supervisionado não será empregado no trabalho.

No treinamento supervisionado, a cada iteração são apresentados à rede valores de entrada e os valores de saída desejados (vetor alvo). A rede calcula as saídas resultantes das entradas, comparando-as com os alvos. Essa etapa pode ser realizada a cada iteração (treinamento sequencial) ou ao final da apresentação de todos os exemplos do conjunto de dados de treinamento à rede (treinamento por lote). Os pesos são ajustados de maneira que os valores de saída aproximem-se dos alvos, definindo-se um sinal de erro $e_j(t)$ como a diferença entre o valor alvo $d_j(t)$ e o resultado $y_j(t)$ da rede no neurônio de saída j no iteração t , de acordo com a Equação 4.7.

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

A cada etapa de treinamento, são feitas pequenas alterações nos pesos, o que provoca uma minimização incremental dos erros. A forma genérica de alteração dos pesos é apresentada na Equação 4.8, onde η é a taxa de aprendizado, que determina a

taxa com que os pesos são ajustados na direção de produzirem o menor erro, e $x_i(t)$ é o valor de entrada para o nodo j na iteração t .

$$w_{ji}(t + 1) = w_j(t) + \eta e_j(t) x_i(t) \quad (4.8)$$

O ajuste é obtido pela minimização da função de custo, apresentada da Equação 4.9. O parâmetro utilizado para avaliar o desempenho da rede é a soma dos erros quadráticos de todas as saídas.

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

A função de custo pode ser visualizada como uma superfície de erro, com os parâmetros livres do sistema (pesos e bias) como coordenadas. Ela pode apresentar um único ponto de mínimo, quando possui somente funções de ativação lineares, ou pode apresentar vários mínimos locais, além do mínimo global, se houverem nodos não-lineares (Braga et al., 1998; apud Fiorin, 2009, p. 34).

O objetivo do método de aprendizado é que o erro parta de um ponto arbitrário da superfície de erro e se desloque até o mínimo global. No entanto, quando se tem saídas não-lineares, a rede pode estabilizar-se em uma região de mínimo local, com erro maior do que o seu mínimo global. Para garantir que a rede irá encontrar o seu mínimo global, existem algumas técnicas especiais de treinamento, como o algoritmo *backpropagation*, que é o principal algoritmo empregado no treinamento supervisionado de redes MLP (Rumelhart et al., 1986; Fiorin, 2009).

Na primeira etapa do algoritmo de *backpropagation* (retropropagação), o sinal funcional (*feedforward*) propaga-se e, com os pesos sinápticos fixos, gera-se um valor de saída a partir das entradas. Em seguida, ocorre a comparação entre as saídas da rede e os alvos (valores desejados), gerando um sinal de erro que se propaga da saída para as entradas, ajustando-se os pesos de forma a minimizar os erros (retropropagação dos erros).

O algoritmo *backpropagation* é baseado no método do gradiente para minimização do erro para ajuste dos pesos, em que a correção aplicada a cada peso dos

neurônios é dada pela derivada parcial da função de custo em relação ao peso em questão, multiplicada pela taxa de aprendizado adotada. Os ajustes dos pesos tornam-se dependentes do valor do gradiente local $\delta_j(t)$, conforme as Equações 4.10 e 4.11, sendo $\phi(v(t))$ a derivada da função de ativação aplicada ao nível de atividade interna do neurônio.

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

$$\delta_j(t) = e_j(t) \phi'(v(t)) \quad (4.11)$$

“O treinamento *backpropagation* sequencial é geralmente mais rápido e requer menos memória, porém é mais instável, enquanto que o treinamento por lote é mais estável, ao custo de maior tempo computacional e memória” (Braga et al., 1998; apud Fiorin, 2009, p. 35). Em virtude da instabilidade do método sequencial, optou-se por desenvolver todas as RNAs deste trabalho pelo treinamento por lote.

Conforme explica Haykin (2001), no treinamento por lote, a apresentação de todos os exemplos de treinamento à RNA constitui o que se chama de época. Durante cada época, os pesos são mantidos constantes e se define uma nova função de custo como a média das funções de custo para cada exemplo. Ao final da época, os pesos são ajustados, de acordo com a média de todos os ajustes calculados com cada exemplo.

Adicionalmente, conforme melhor descrito por Fiorin (2009), existem alguns algoritmos baseados em técnicas padrões de otimização numérica que não são variantes do algoritmo *backpropagation*, como o algoritmo de *Levenberg-Marquardt*, utilizado no treinamento das RNAs no Trabalho, por motivos que serão explanados nos próximos capítulos.

De acordo com Soares et al. (1999), o algoritmo de *Levenberg-Marquardt* utiliza uma aproximação pelo método de Newton, que é obtida a partir da modificação do método de Gauss-Newton introduzindo-se um parâmetro μ , que funciona como um fator de estabilização do treinamento, ajustando a aproximação de forma a utilizar a rápida convergência do método de Newton, e evitando passos muito grandes que possam levar

Relatório Final de Atividades, 2011

a um erro de convergência. Para maiores informações sobre o algoritmo, recomenda-se a consulta de referências como Hagan et al. (1994) e Demuth et al. (2008).

Outro importante fator a ser considerado no emprego de redes neurais é a capacidade de generalização. “A generalização indica a capacidade da rede de aprender através de um pequeno número de exemplos e, posteriormente, simular valores coerentes para um grupo desconhecido de dados” (Braga et al., 1998; apud Fiorin, 2009, p. 37).

Apesar de a rede atingir um erro mínimo em um treinamento, para algumas situações é possível que a rede não tenha adquirido a capacidade de generalização, que ocorre geralmente quando é empregado um grande número de neurônios nas camadas ocultas. Nestes casos, a utilização de novos valores de entrada poderá resultar em um erro elevado nas estimativas da rede, e então se diz que houve *overfitting* (excesso de ajuste), em que a rede memoriza os dados, ao invés de extrair os seus padrões.

Para evitar problemas com *overfitting*, empregam-se métodos especiais, como a regularização e o treinamento com parada antecipada. No caso da regularização, a função de custo é modificada de forma a não minimizar somente ela, mas também os pesos sinápticos durante o treinamento. No treinamento com parada antecipada, os dados são separados em um conjunto de treinamento e um conjunto de teste. Os pesos são ajustados somente com os valores do conjunto de treinamento, sendo o conjunto de teste utilizado para avaliar a generalização da rede ao longo do treinamento, que é interrompido quando o erro do grupo de teste começa a aumentar.

CAPÍTULO 5

METODOLOGIA

5.1 – Seleção das Entradas e Saídas das RNAs

A estação SONDA-SMS dispõe de um conjunto completo de equipamentos para monitoramento da radiação solar, dos ventos e de variáveis meteorológicas básicas. A totalidade desses dados representa, em princípio, os possíveis preditores e preditandos a serem utilizados nas RNAs.

Diante do que se propôs para esta pesquisa, delimita-se o preditando, que corresponde às saídas esperadas das RNAs, como sendo a integral diária de irradiância solar global em superfície, denominada irradiação solar global diária.

Todas as outras variáveis disponíveis representam as possíveis escolhas como preditandos para a camada de entrada das RNAs. Adotou-se como critério na escolha das variáveis a sua influência em modelos usuais apresentados na literatura, como em Iqbal (1983). Ao todo, foram selecionadas oito variáveis diferentes: irradiação solar difusa, irradiação solar direta normal, irradiação de onda longa (irradiação terrestre), temperaturas média, mínima e máxima do ar, umidade relativa do ar e pressão atmosférica.

Embora a estação SONDA-SMS disponha de outras variáveis influentes na modelagem da irradiação solar, como informações sobre as frações fina e opaca de nebulosidade do céu e velocidade dos ventos, optou-se por mantê-las fora das análises devido à complexidade na aquisição desses dados e da falta de uma metodologia definida para sua qualificação.

No escopo da previsão de valores futuros de irradiação solar com base nos valores passados das variáveis selecionadas, torna-se necessária a adoção de uma notação para referenciar esses diferentes instantes de tempo. Isso foi feito adotando a seguinte representação para as variáveis: “*var_t*”, em que o termo “*var*” deve ser substituído pela notação referente a cada variável, conforme a Tabela 5.1, e o termo “*t*”. O índice *t* correspondente ao tempo, pode assumir os valores 0, -1, -2 ou -3, de tal forma

Relatório Final de Atividades, 2011

que 0 significa o instante futuro para o qual se quer conhecer o valor da variável, -1 refere-se ao valor da variável para um dia anterior, -2 para dois dias anteriores e -3 para três dias anteriores.

Tabela 5.1 – Notação para descrição das variáveis empregadas nas RNAs.

Notação	Variável Correspondente	Unidade de Medida
<i>glob</i>	Irradiação solar global	Joules por Metro Quadrado [J/m ²]
<i>Dif</i>	Irradiação solar difusa	Joules por Metro Quadrado [J/m ²]
<i>dir</i>	Irradiação solar direta horizontal	Joules por Metro Quadrado [J/m ²]
<i>long</i>	Irradiação de onda longa (terrestre)	Joules por Metro Quadrado [J/m ²]
<i>tmed</i>	Temperatura média do ar	Graus Celsius [°C]
<i>tmin</i>	Temperatura mínima do ar	Graus Celsius [°C]
<i>tmax</i>	Temperatura máxima do ar	Graus Celsius [°C]
<i>umid</i>	Umidade relativa do ar (média diária)	Porcentagem [%]
<i>pres</i>	Pressão atmosférica (média diária)	Milibar [mbar]

Os coeficientes de correlação (R) entre as variáveis nos diferentes tempos (0, -1, -2 e -3) e a irradiação solar global, que representam uma medida do grau de significância da variável para seu uso em modelos de previsão, são apresentados na Tabela 5.2. É claramente observável que as correlações entre a irradiação global em um instante futuro são maiores para as variáveis nesse mesmo instante, diminuindo gradativamente de valor para os instantes passados, com exceção de pressão atmosférica e temperatura mínima, que apresentaram leve aumento. Condição que pode ser melhor investigada com a inclusão de mais valores passados, anteriores a três dias.

Tabela 5.2 – Coeficientes de correlação entre a irradiação solar global e cada uma das variáveis selecionadas. O tempo está descrito em dias de antecedência representados pelos valores negativos.

Variável		Coeficiente de Correlação								
		<i>glob</i>	<i>dif</i>	<i>dir</i>	<i>long</i>	<i>tmed</i>	<i>tmax</i>	<i>tmin</i>	<i>umid</i>	<i>pres</i>
Tempo	0	–	-0,053	0,878	0,087	0,397	0,540	0,101	-0,746	0,005
	-1	0,548	-0,008	0,467	0,065	0,171	0,195	0,047	-0,322	-0,020
	-2	0,312	-0,023	0,255	0,059	0,148	0,146	0,096	-0,156	-0,153
	-3	0,255	-0,025	0,201	0,041	0,181	0,157	0,144	-0,107	-0,207

5.2 – Qualificação dos Dados para Emprego com RNAs

Os critérios de qualificação adotados para os dados empregados nas RNAs seguiram as normas da BSRN (*Baseline Surface Radiation Network*) para medidas radiométricas e da WebMet para medidas meteorológicas, os mesmos padrões utilizados pela rede SONDA.

No entanto, adotaram-se somente os dois primeiros algoritmos de qualificação dos dados de irradiação solar adotados pela Rede SONDA, que consistem, respectivamente, na sinalização dos valores quando fisicamente impossíveis e extremamente raros. O terceiro algoritmo foi substituído pela análise conhecida como “Global 1 versus Global 2”, adotada por Fiorin (2009), que consiste na comparação do valor da integral diária de irradiância global, correspondente aos valores efetivamente medidos e chamados “Global 1”, com os valores da “Global 2”, que consistem na soma das integrais diárias das irradiâncias difusa e direta horizontal, corrigida com o ângulo zenital solar.

Após análises da consistência das medidas através do procedimento “Global 1 versus Global 2”, constatou-se que o descarte dos dados que apresentassem uma diferença entre os valores de “Global 1” e de “Global 2” superior a 20% do valor da irradiação global medida seria uma escolha razoável, conforme se pode visualizar no gráfico da Figura 5.1.

Todas as variáveis passaram pelas análises de qualificação, mas somente medidas de irradiação solar (global, difusa e direta horizontal) e temperatura apresentaram problemas, sendo desconsideradas para uso nas RNAs. Ao todo, compreendendo o período de Janeiro de 2005 a Dezembro de 2009, foram considerados aptos para utilização 1004 dias de dados.

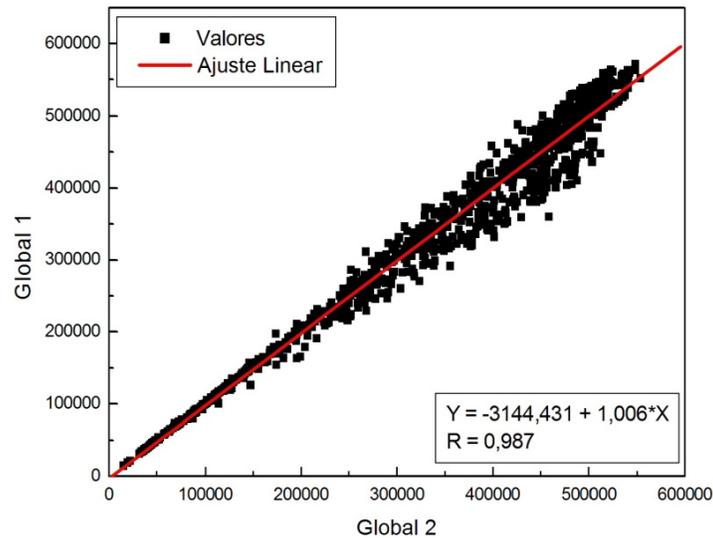


Figura 5.1 – Comparação dos valores de “Global 1” e “Global 2” aceitos no procedimento de qualificação das medidas adotado no Observatório Espacial do Sul.

5.3 – Treinamento das RNAs para Previsão de Irradiação Solar Global

Todas as RNAs apresentadas no Trabalho foram treinadas adotando a mesma metodologia, muito embora tenham sido testadas diversas outras metodologias, entendeu-se, por fim, que esta seria a melhor escolha dos procedimentos de treinamento. Segundo Ludwig et al. (2007), a coleta criteriosa dos dados relativos ao problema é fundamental para o desempenho de uma rede neural. A tarefa requer uma análise cuidadosa dos dados com a finalidade de minimizar ambiguidades e erros. Além disso, os dados devem cobrir amplamente o problema, incluindo as exceções e as condições limites.

Inicialmente agruparam-se as variáveis de entrada com diversas configurações de correlação com a irradiação global, com objetivo de verificar se as maiores correlações apresentaram também os melhores resultados da rede treinada e conseqüentemente os menores erros. Depois de separar as variáveis, a base de dados passou por um processo de normalização simples, segundo a Equação 5.1, com o intuito de manter os valores máximos e mínimos das medidas dentro do intervalo de saída das funções de ativação. Assim, tanto as variáveis de entrada quanto as de saída passam a assumir valores de 0 a 1.

$$valor\ normalizado = \frac{valor - \text{mínimo}}{\text{máximo} - \text{mínimo}} \quad (5.1)$$

Ainda segundo Ludwig et al. (2007), o procedimento de divisão e reordenação aleatória dos dados é recomendável para prevenção de tendências associadas à ordem de apresentação dos dados à rede. Os dados normalizados são divididos aleatoriamente em três conjuntos de dados: treinamento, teste e validação, da seguinte forma:

- 50% para o grupo de treinamento – dados utilizados no treinamento das RNAs, para ajuste dos pesos sinápticos entre as conexões;
- 25% para o grupo de teste – dados utilizados no processo de aprendizado das RNAs, somente utilizados para determinar o fim do treinamento;
- 25% para o grupo de validação – dados não utilizados no treinamento das RNAs, mas somente na validação dos modelos através do cálculo de desvios estatísticos.

A divisão dos dados nos três conjuntos citados acima foi adotada para garantir a generalização das RNAs, através do treinamento com parada antecipada descrito no Capítulo 4.

Após a etapa de qualificação dos dados e sua divisão nos conjuntos de treinamento, teste e validação, cada grupo de dados é adequado ao formato de entrada do *software* utilizado para treinamento das RNAs. Escolheu-se como *software* de trabalho o Matlab6.1®, que dispõe de ferramentas adequadas para aplicações de redes neurais artificiais, conhecida como *Neural Network Toolbox (NNTool)*.

Durante a utilização do *NNTool*, seleciona-se o tipo de RNA, o número de camadas e o número de neurônios de cada camada, o algoritmo de treinamento e as funções de ativação de cada camada.

As únicas opções fixadas durante as análises foram o tipo de RNA utilizada (*feedforward* – MLP) e o algoritmo de treinamento, que foi fixado como sendo o algoritmo de *Levenberg-Marquardt*. O motivo da escolha refere-se a conclusões obtidas por Fiorin (2009) em estudos similares de estimativa de irradiação solar global, que, em comparação com outros algoritmos, percebeu que o de *Levenberg-Marquardt* leva aos menores erros durante o treinamento, apesar do maior tempo de processamento.

Relatório Final de Atividades, 2011

Selecionadas as opções iniciais referentes à topologia e ao treinamento adotado, foram treinadas redes utilizando somente os dados do grupo de treinamento, variando o número de camadas ocultas da MLP (uma ou duas camadas ocultas), o número de neurônios nas camadas ocultas e as funções de ativação de cada camada.

Durante o treinamento, os erros de ambos os grupos (treinamento e teste) de dados estão sendo minimizados, mas somente o grupo de treinamento é fornecido à RNA como exemplo para o aprendizado. O grupo de testes tem seus erros calculados sequencialmente, época à época, e, primariamente, estarão sendo minimizados, pois a rede estará otimizando seus pesos sinápticos no sentido de melhor representar o grupo de treinamento, que, a princípio, possui os mesmos padrões do grupo de teste.

Conforme descrito em Fiorin (2009, p. 67), “o treinamento vai chegar a um ponto em que a rede vai se aprofundar no aprendizado dos padrões do grupo de treinamento de tal forma que irá deixar de minimizar os erros no grupo de teste. Assim, a função de erro do grupo de teste irá ter uma inflexão positiva, passando a aumentar”. Nesse momento, o treinamento é interrompido, antes que o erro no grupo de teste aumente.

A inflexão é um indício de que a RNA está encaminhando-se para uma situação de *overfitting*, discutida no Capítulo 4. Segundo Ludwig et al. (2007, p. 24), a capacidade de generalização da rede começa a degenerar, ou seja, a rede memoriza os dados do conjunto de treinamento e não mais consegue definir uma saída correta para outros dados que estejam fora do padrão de entrada.

Em relação ao conjunto de valores iniciais atribuídos aos pesos e *bias*, etapa conhecida como inicialização da rede, é possível que uma RNA não atinja o melhor resultado e o menor tempo de treinamento para uma primeira tentativa, ou seja, o treinamento começará numa região diferente da superfície de erro da rede, podendo encaminhar-se a diferentes mínimos locais, ou ao próprio mínimo global. Para reduzir esse problema, cada topologia foi treinada cinco vezes, reinicializando-se os valores dos pesos e *bias* para cada treinamento. Somente foi considerada a RNA que apresentou menor erro no grupo de teste nessa fase.

A inicialização dos pesos e *bias* foi realizada com valores aleatórios uniformemente distribuídos, devido à sua praticidade, apesar de haverem métodos de

melhor escolha de seus valores iniciais, como a função encontrada por Nguyen e Widrow (1990).

A metodologia de previsão da série temporal de irradiação global baseia-se no conhecimento de valores passados de variáveis meteorológicas e radiométricas, incluindo medidas da própria irradiação global, para avaliar a tendência futura de seus valores. Um esquema do uso de RNAs do tipo MLP para previsão de séries temporais, empregado por Paoli (2009), é apresentado na Figura 5.2.

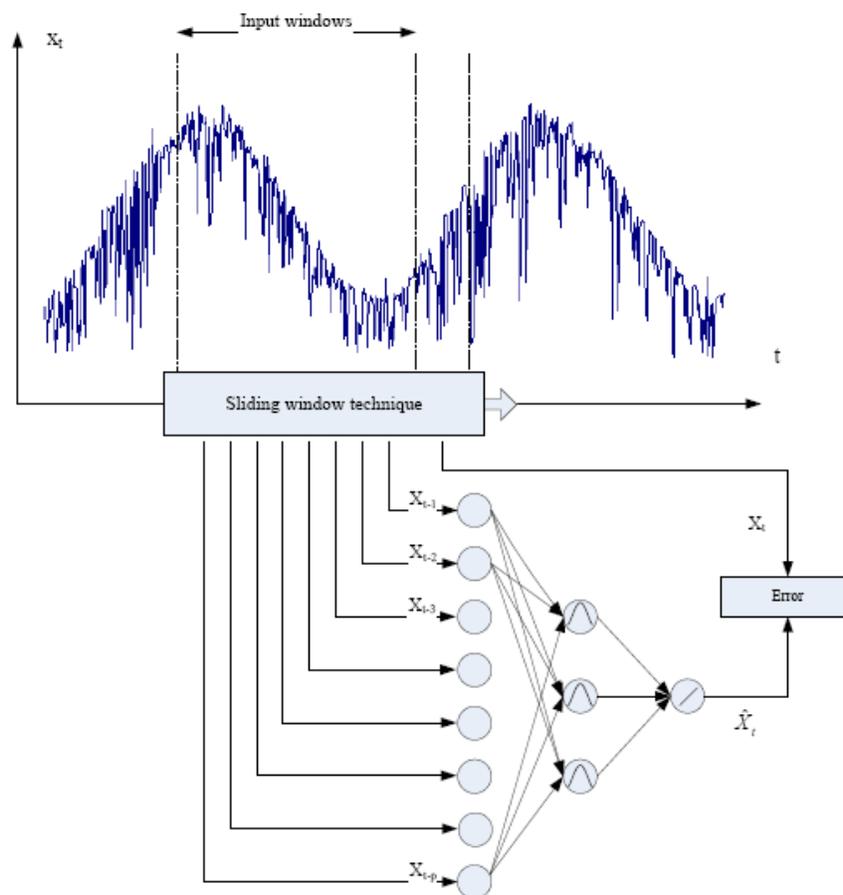


Figura 5.2 – Aplicação de uma MLP para previsão de séries temporais. Fonte: Paoli (2009).

Emprega-se um conjunto limitado de valores passados de uma variável, chamado *Input windows* (janela de entrada) pelo referido autor, como entradas da MLP,

que, após o treinamento, é utilizada para prever alguns valores futuros da variável, numa extrapolação temporal.

Diferentemente da metodologia empregada por Paoli (2009), além de valores passados da variável que se quer prever, foram utilizadas outras variáveis meteorológicas e radiométricas como entradas das RNAs, mencionadas na Tabela 5.1.

5.4 – Notação para Descrição das RNAs

Para simplificar a apresentação e facilitar a compreensão dos resultados obtidos com o emprego das redes neurais artificiais, foi adotada uma notação para sua representação.

As RNAs do tipo MLP com uma camada interna são representadas como “n-X-1”, em que “n” é o número de nodos da camada de entrada, que corresponde ao número de variáveis de entrada da MLP, e “X” é o número de neurônios da camada oculta da rede. O número de nodos da camada de saída é fixo como 1, pois há somente uma variável de saída.

As redes com duas camadas ocultas são representadas com uma notação semelhante, no formato “n-X-Y-1”, onde “n” tem o mesmo significado das redes com uma camada oculta, e “X” e “Y” representam o número de neurônios da primeira e da segunda camadas ocultas, respectivamente.

Quando estiverem em discussão as funções de ativação das camadas das redes, adota-se, após o nome correspondente às RNAs, a inclusão das seguintes abreviaturas: Função Linear (LIN), Função Sigmóide Logística (LOG) e Função Sigmóide Tangente Hiperbólica (TAN).

Para redes com uma camada interna, a primeira sigla representará a função de ativação da camada oculta, e a segunda sigla a função de ativação da camada de saída. Para redes com duas camadas internas, a primeira sigla representará as funções de ativação das camadas ocultas, e a segunda a função de ativação da camada de saída. Embora pudessem ser empregadas funções de ativação diferentes em cada camada interna de uma rede com duas camadas internas, optou-se por não fazê-lo para reduzir a quantidade de análises.

Uma rede descrita como “3-10-5-1 TAN LOG” terá três nodos na camada de entrada, dez nodos na primeira camada oculta, cinco nodos na segunda camada oculta e um nodo na camada de saída, com funções de ativação do tipo sigmóide tangente hiperbólica nas camadas ocultas e sigmóide logística na camada de saída.

Adicionalmente, cada conjunto diferente de dados para emprego nas RNAs será denominado de experimento. Cada experimento está enquadrado dentro de um de três possíveis tempos de previsão: Prev24h, Prev48h ou Prev72h. Nessa notação, Prev24h representa o conjunto de experimentos que utilizam dados de tempos passados para realizar a previsão de irradiação solar global 24 horas à frente, ou seja, previsão um passo à frente, Prev48h representa o conjunto de experimentos para previsão 48 horas à frente (dois passos) e Prev72h o conjunto de experimentos para previsão 72 horas à frente (três passos).

5.5 – Parâmetros Estatísticos Empregados na Validação das estimativas fornecidas pelas RNAs

Coefficiente de Correlação (R): Medida da associação linear entre observações e previsões, definido por:

$$R = \frac{\sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x})}{\sqrt{\sum_{i=1}^n (y_i - \bar{y})^2} \sqrt{\sum_{i=1}^n (x_i - \bar{x})^2}} \quad (5.2)$$

Onde, y_i são os valores previstos e x_i são os valores medidos.

O número, R , é adimensional, podendo variar de -1 a 1, onde 1 indica uma previsão perfeita. Por ser independente da escala e por não levar em conta o viés da previsão, é possível encontrar uma correlação elevada para uma previsão com erros grandes (viés).

Coefficiente de Determinação (R^2): Medida da fração de variância das observações explicada pelas previsões e é definido por:

$$R^2 = \frac{\sum_{i=1}^n (y_i - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (5.3)$$

O parâmetro pode ser calculado elevando o coeficiente de correlação (R) ao quadrado. Trata-se de um adimensional que varia de 0 a 1, indicando que as previsões explicam, respectivamente, 0 a 100% da variância total das observações.

Viés ou Erro Sistemático Médio (MBE – Mean Bias Error): Medida da média dos erros, dada pela Equação 5.4, que permite verificar se a previsão é sistematicamente subestimada ou superestimada. Varia de infinito negativo a infinito positivo e seu valor para previsão perfeita é 0, mas pode atingir esse valor mesmo para uma previsão ruim, caso haja erros compensatórios. Possui a mesma unidade das previsões e observações. O MBE é expresso em MBE%, que equivale ao valor do MBE dividido pela média das observações multiplicado por 100.

$$MBE = \frac{1}{N} \sum_{i=1}^N (y_i - x_i) \quad (5.4)$$

Onde, N é o número de dados, y_i são os valores previstos e x_i são os valores medidos.

Raiz do Erro Quadrático Médio (RMSE – Root Mean Squared Error): Medida da magnitude média dos desvios quadráticos entre previsão e observação. Varia de 0 a infinito, sendo 0 o valor para uma previsão perfeita. Como é uma média quadrática, erros maiores possuem maior influência sobre o valor final do que os erros menores. Possui a mesma unidade das previsões ou observações. O RMSE é expresso em RMSE%, que equivale ao valor do RMSE dividido pela média das observações multiplicado por 100.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - x_i)^2} \quad (5.5)$$

Erro Quadrático Médio (MSE – *Mean Square Error*): Trata-se do valor do RMSE elevado ao quadrado. Ou seja, a média do somatório dos erros elevados ao quadrado. Esta é a variável erro que as RNAs buscam minimizar durante o seu treinamento, e será utilizada para comparar o desempenho de duas RNAs de topologia semelhantes. O melhor treinamento será aquele que conseguir minimizar ao máximo o valor do MSE do grupo de testes no treinamento.

CAPÍTULO 6

ATIVIDADES OPERACIONAIS DESENVOLVIDAS

Durante o período de vigência do Projeto de Iniciação Científica, o Bolsista realizou as atividades descritas nos tópicos seguintes.

6.1 – Revisão Bibliográfica

O Bolsista realizou a leitura de diferentes referências bibliográficas com o objetivo de introduzi-lo no tema de seu Projeto de Iniciação Científica, dentre as quais se destacando a temática de energias renováveis, principalmente no tocante à energia solar e redes neurais artificiais.

6.2 – Manutenção dos Equipamentos da Estação SONDA – SMS

Quinzenalmente, são realizadas visitas à Estação SONDA – SMS instalada no Observatório Espacial do Sul - OES/CRS/CCR/INPE – MCT, com o intuito de fazer as manutenções necessárias à conservação física dos equipamentos e manter a confiabilidade dos dados coletados.

As principais atividades desenvolvidas são a verificação do nível do *tracker* 2AP, a limpeza dos domos dos radiômetros e da câmera do Imageador, o polimento do espelho convexo do Imageador e a troca da sílica gel dos equipamentos.

A verificação do nível do *tracker* é realizada observando-se a localização de um feixe de radiação solar incidente em uma marca no equipamento. Isso é necessário uma vez que o *tracker* é responsável pelo posicionamento do Pireliômetro na direção do Sol e pelo posicionamento dos ocultadores do disco solar sobre os domos do Piranômetro CM22 e do Pirgeômetro.

A limpeza dos domos dos radiômetros e da lente da câmera do Imageador é realizada com um papel, visto que os mesmos são feitos de cristal. A presença de sujeira

Relatório Final de Atividades, 2011

sobre os medidores pode ocasionar medições inferiores às reais, já que a sujeira absorve e espalha parte da radiação incidente.

O espelho convexo do Imageador necessita de um tratamento adicional, limpa-se o espelho com líquido específico para limpeza de vidros, e cera automotiva para polimento, uma vez que sujeiras podem ser confundidas com nuvens.

Os medidores de radiação são sensíveis à umidade, o que faz com que seja necessária a conservação da baixa umidade no seu interior, que é feito pela presença de um dessecador com sílica gel, devendo ser trocada em um período máximo de quinze dias.

6.3 – Coleta, Qualificação e Análise dos Dados da Estação SONDA – SMS

Os dados coletados pelos equipamentos são armazenados em um Datalogger CR23X Micrologger (*Campbell Sci.*), instalado no interior do Prédio Um do Observatório Espacial do Sul - OES/CRS/CCR/INPE – MCT. Os dados ambientais são coletados a cada segundo, sendo a saída dos dados armazenada por valores médios, máximos, mínimos e desvio padrão do minuto. Os dados eólicos são armazenados com uma resolução temporal de 10 minutos.

Os dados armazenados no Datalogger são acessados via internet e descarregados para o computador “*Solar*” do Laboratório de Recursos de Energias Renováveis (LRER), localizado no Prédio Sede do Centro Regional Sul de Pesquisas Espaciais – CRS/CCR/INPE – MCT, no campus da UFSM. As imagens captadas pelo Imageador são armazenadas no computador existente no interior do Prédio Um do Observatório Espacial do Sul, e devem ser copiadas para dispositivos USB ou CDs para sua transferência para o banco de dados do LRER.

Os valores médios das medidas de radiação solar são separados por dia, mês e ano em planilhas eletrônicas. Para cada dia, as medidas são plotadas em *softwares* gráficos e integradas, gerando os valores integrais diários, que são salvos em planilhas mensais.

6.4 – Participação de eventos com apresentação de Trabalhos



Relatório Final de Atividades, 2011

Durante o período de vigência da bolsa o acadêmico participou de um trabalho científico publicado, sendo ele:

Luiz Felipe Kremer, Fernando Ramos Martins, Nelson Jorge Schuch
AVALIAÇÃO DO POTENCIAL SOLAR DO SUL DO BRASIL. In: Simpósio de Iniciação Científica do Centro Regional Sul de Pesquisas Espaciais, 2011, Santa Maria, RS. 2011.

CAPÍTULO 7

RESULTADOS

7.1 – RNAs com Tempo de Previsão Prev24h

Dentre os experimentos realizados para Prev24h, serão apresentadas RNAs que obtiveram os menores desvios MSE entre suas previsões e as medidas de irradiação solar global em superfície pertencentes ao grupo de teste.

O conjunto de variáveis empregadas como preditores e preeditandos que tiveram melhor representação para Prev24h neste experimento é apresentado na Tabela 7.1, conforme a notação de abreviaturas descrita no Capítulo 5.

Tabela 7.1 – Variáveis empregadas no experimento para Prev24h.

	Preditando	Preditores
Experimento	<i>glob_0</i>	<i>glob_-1, glob_-2, glob_-3</i>

Foram inicialmente treinadas várias topologias de redes, com uma e duas camadas ocultas, utilizando função de ativação sigmóide logística para as camadas internas e linear para as camadas de saída, com o emprego do algoritmo de *Levenberg-Marquardt* para treinamento das RNAs. Os resultados obtidos são apresentados na Tabela 7.2 (para redes com uma camada interna) e na Tabela 7.3 (para redes com duas camadas internas).

Relatório Final de Atividades, 2011

Tabela 7.2 – Resultados do treinamento de MLPs com uma camada interna, com destaque para os dois menores desvios MSE no grupo de teste.

TOPOLOGIAS	TREINO		TESTE		VALIDAÇÃO			
	R	MSE	R	MSE	R	MSE	MBE%	RMSE%
3-3-1	0,585	0,0463	0,601	0,0369	0,601	0,0486	-1,58	36,60
3-5-1	0,626	0,0429	0,599	0,0370	0,613	0,0477	-1,07	36,26
3-7-1	0,648	0,0409	0,570	0,0396	0,623	0,0469	-3,10	35,96
3-9-1	0,651	0,0406	0,590	0,0381	0,601	0,0483	-0,609	36,50
3-11-1	0,659	0,0398	0,592	0,0392	0,609	0,0477	2,06	36,24
3-13-1	0,658	0,0399	0,597	0,0377	0,600	0,0484	-1,14	36,53
3-15-1	0,669	0,0389	0,603	0,0473	0,614	0,0473	-2,23	36,11
3-17-1	0,663	0,0398	0,605	0,0370	0,630	0,0458	-2,66	35,53
3-19-1	0,678	0,0380	0,579	0,0393	0,589	0,0497	-2,95	37,01
3-21-1	0,675	0,0386	0,602	0,0409	0,608	0,0486	3,09	36,59
3-23-1	0,677	0,0381	0,573	0,0398	0,580	0,0507	-3,64	37,37
3-25-1	0,699	0,0360	0,578	0,0402	0,625	0,0460	-0,36	35,61

Tabela 7.3 – Resultados do treinamento de MLPs com duas camadas internas, com destaque para os dois menores desvios MSE no grupo de teste.

TOPOLOGIAS	TREINO		TESTE		VALIDAÇÃO			
	R	MSE	R	MSE	R	MSE	MBE%	RMSE%
3-3-3-1	0,601	0,0450	0,622	0,0355	0,553	0,0525	0,43	38,03
3-5-3-1	0,628	0,0427	0,625	0,0352	0,630	0,0457	-1,18	35,50
3-7-3-1	0,654	0,0404	0,583	0,0384	0,585	0,0499	-1,58	37,09
3-9-3-1	0,665	0,0393	0,579	0,0390	0,615	0,0471	-1,11	36,01
3-15-5-1	0,679	0,0381	0,529	0,0420	0,567	0,0516	0,53	37,72
3-20-5-1	0,691	0,0368	0,584	0,0386	0,561	0,0517	0,46	37,77
3-25-5-1	0,705	0,0356	0,614	0,0368	0,573	0,0509	2,01	37,45
3-30-5-1	0,713	0,0348	0,595	0,0318	0,598	0,0486	0,393	36,60
3-35-5-1	0,711	0,0351	0,560	0,0493	0,591	0,0493	-1,99	36,88
3-40-5-1	0,707	0,0395	0,581	0,0394	0,577	0,0512	3,05	37,57
3-45-5-1	0,771	0,0286	0,591	0,0380	0,591	0,0535	-2,28	38,39
3-50-5-1	0,725	0,0335	0,574	0,0404	0,612	0,0473	0,909	36,11

O comportamento gráfico dos valores de MSE do grupo de testes, para MLPs com uma e duas camadas internas, é apresentado nas Figuras 7.1 e 7.2.

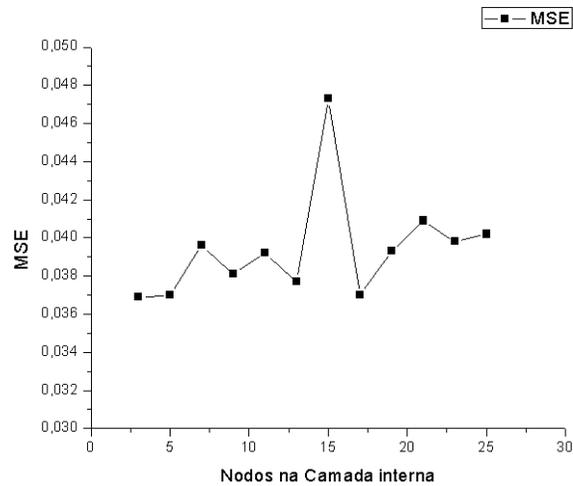


Figura 7.1 – Desvios MSE do grupo de teste para as diferentes topologias de redes neurais MLP com uma camada interna.

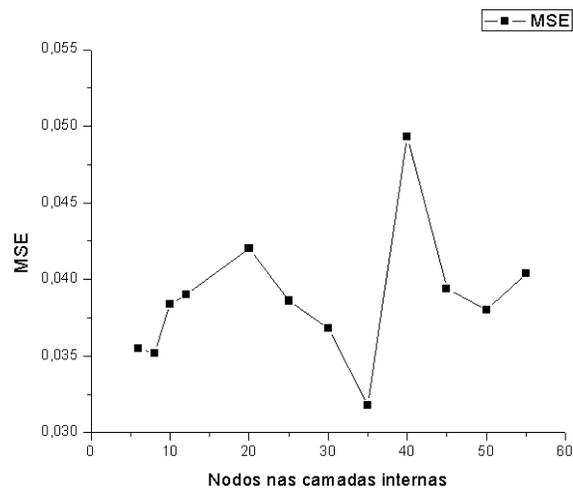


Figura 7.2 – Desvios MSE do grupo de teste para as diferentes topologias de redes neurais MLP com duas camadas internas.

Para as RNAs com uma camada oculta, houve um mínimo de MSE no grupo de teste com 3 neurônios na camada oculta, seguido por uma oscilação e um pico de aumento no MSE com 15, uma queda em 17 neurônios e um aumento a partir disso.

As RNAs com duas camadas ocultas obtiveram melhor êxito nas previsões com 8 e 35 neurônios nas camadas ocultas no MSE do grupo de testes.

Relatório Final de Atividades, 2011

A partir das análises, foram selecionadas as duas melhores topologias com uma camada interna (“3-3-1 LOG LIN” e “3-5-1 LOG LIN”) e as duas melhores topologias com duas camadas internas (“3-5-3-1 LOG LIN” e “3-30-5-1 LOG LIN”), no que se refere aos menores valores de MSE no grupo de teste, para que fossem alteradas as funções de ativação de suas camadas. Os resultados obtidos são apresentados na Tabela 7.4.

Tabela 7.4 – Desempenho das melhores topologias iniciais de MLPs com a alteração das funções de ativação de suas camadas ocultas e de saída.

TOPOLOGIAS	TREINO		TESTE		VALIDAÇÃO			
	R	MSE	R	MSE	R	MSE	MBE%	RMSE%
3-3-1 LOG LIN	0,585	0,0463	0,601	0,0369	0,601	0,0486	-1,58	36,60
3-3-1 LOG LOG	0,588	0,0461	0,590	0,0377	0,603	0,0484	-1,69	36,51
3-3-1 LOG TAN	0,597	0,0453	0,623	0,0353	0,603	0,0484	-2,03	36,53
3-3-1 TAN LIN	0,597	0,0454	0,623	0,0355	0,621	0,0469	-1,56	35,96
3-3-1 TAN LOG	0,595	0,0455	0,623	0,0355	0,610	0,0478	-0,56	36,31
3-3-1 TAN TAN	0,595	0,0455	0,604	0,0366	0,606	0,0482	-1,58	36,47
3-5-1 LOG LIN	0,626	0,0429	0,599	0,0370	0,613	0,0477	-1,07	36,26
3-5-1 LOG LOG	0,607	0,0445	0,624	0,0353	0,590	0,0493	-0,86	36,86
3-5-1 LOG TAN	0,611	0,0441	0,599	0,0370	0,607	0,0482	-1,12	36,47
3-5-1 TAN LIN	0,618	0,0436	0,613	0,0360	0,595	0,0490	-2,22	36,75
3-5-1 TAN LOG	0,636	0,0420	0,622	0,0357	0,618	0,0471	0,48	36,02
3-5-1 TAN TAN	0,628	0,0427	0,608	0,0365	0,624	0,0464	-1,82	35,76
3-5-3-1 LOG LIN	0,628	0,0427	0,625	0,0352	0,630	0,0457	-1,18	35,50
3-5-3-1 LOG LOG	0,647	0,0409	0,606	0,0365	0,626	0,0468	-2,44	35,92
3-5-3-1 LOG TAN	0,619	0,0435	0,614	0,0360	0,613	0,0476	-3,05	36,21
3-5-3-1 TAN LIN	0,633	0,0422	0,618	0,0357	0,611	0,0477	-2,38	36,24
3-5-3-1 TAN LOG	0,610	0,0442	0,619	0,0356	0,604	0,0481	-1,09	36,40
3-5-3-1 TAN TAN	0,643	0,0414	0,605	0,0367	0,593	0,0492	-0,43	36,84
3-30-5-1 LOG LIN	0,713	0,0348	0,595	0,0381	0,598	0,0486	0,39	36,60
3-30-5-1 LOGLOG	0,746	0,0312	0,576	0,0400	0,569	0,0512	-1,36	37,58
3-30-5-1 LOGTAN	0,605	0,0449	0,507	0,0429	0,303	0,0811	-4,77	47,27
3-30-5-1 TAN LIN	0,645	0,0412	0,484	0,0439	0,550	0,0540	-4,03	38,59
3-30-5-1 TANLOG	0,714	0,0345	0,585	0,0391	0,559	0,0520	0,55	37,86
3-30-5-1 TANTAN	0,771	0,0285	0,495	0,0502	0,471	0,0630	0,34	41,68

Relatório Final de Atividades, 2011

Manteve-se como melhor resultado a topologia “3-5-3-1 LOG LIN”, para o grupo de testes, que apresentou desvio RMSE de 35,50% quando aplicado para previsão das medidas de irradiação solar global do grupo de validação. Os valores de irradiação global normalizados previstos pela RNA, em função dos valores de irradiação global normalizados medidos, são apresentados na Figura 7.3.

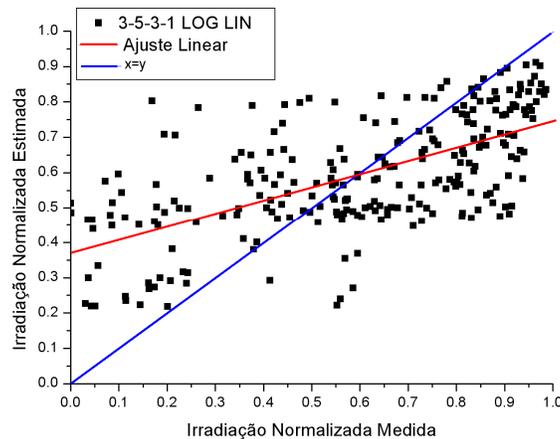


Figura 7.3 – Desempenho da melhor topologia obtida na previsão de irradiação global.

Adicionalmente, o desempenho da topologia pode ser verificado na Figura 7.4, que apresenta os valores medidos e estimados pela RNA (grupo de validação) ordenados no tempo.

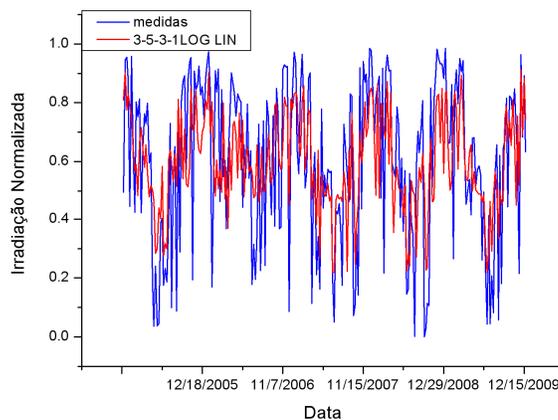


Figura 7.4 – Previsão da série temporal de irradiação global normalizada para o conjunto de validação, obtidos pela rede “3-5-3-1 LOG LIN”.

A análise dos resultados apresentados na Figura 7.4 permite a conclusão de que a rede representou bem as flutuações sazonais apresentadas pela série temporal, porém com desempenho um pouco reduzido na previsão dos valores extremos da série. Novos testes devem ser desenvolvidos com o intuito de reduzir os desvios RMSE e incrementar o fator de correlação R. Os novos experimentos devem considerar o uso de variáveis meteorológicas como precursoras.

7.2 – RNAs com Tempo de Previsão Prev48h

O conjunto de variáveis empregadas como preditores e predictandos que tiveram melhor representação para Prev48h neste experimento é apresentado na Tabela 7.5.

Tabela 7.5 – Variáveis empregadas no experimento para Prev48h.

	Preditando	Preditores
Experimento	<i>glob_0</i>	<i>glob_-2, glob_-3, dir_-2, dir_-3, long_-2, long_-3, tmed_-2, tmed_-3, tmax_-2, tmax_-3, tmin_-2, tmin_-3, umid_-2, umid_-3, pres_-2, pres_-3</i>

Foram inicialmente treinadas várias topologias de MLPs, com funções de ativação sigmóide logística nas camadas internas e linear nas camadas de saída, empregando algoritmo *Levenberg-Marquardt* para aprendizado. Os resultados obtidos para redes com uma camada interna são apresentados na Tabela 7.6, e os obtidos para redes com duas camadas internas são apresentados na Tabela 7.7.

Relatório Final de Atividades, 2011

Tabela 7.6 – Resultados do treinamento de MLPs com uma camada interna, com destaque para os dois menores desvios MSE no grupo de teste.

TOPOLOGIAS	TREINO		TESTE		VALIDAÇÃO			
	R	MSE	R	MSE	R	MSE	MBE%	RMSE%
16-3-1	0,461	0,0555	0,384	0,0497	0,513	0,0561	-2,08	39,33
16-5-1	0,620	0,0435	0,344	0,0535	0,538	0,0547	-4,74	38,81
16-7-1	0,612	0,0441	0,380	0,0526	0,557	0,0536	-6,33	38,44
16-9-1	0,625	0,0432	0,425	0,0499	0,534	0,0540	0,93	38,58
16-11-1	0,704	0,0356	0,373	0,0521	0,510	0,0570	-4,95	39,65
16-13-1	0,662	0,0399	0,348	0,0587	0,424	0,0636	4,19	41,88
16-15-1	0,770	0,0287	0,354	0,0630	0,483	0,0612	-0,11	41,07
16-17-1	0,731	0,0333	0,275	0,0609	0,525	0,0589	-10,56	40,28
16-19-1	0,687	0,0374	0,303	0,0584	0,414	0,0639	-2,51	41,98
16-21-1	0,723	0,0337	0,298	0,0660	0,435	0,0664	2,91	42,79
16-23-1	0,708	0,0357	0,396	0,0501	0,517	0,0554	-0,72	39,08
16-25-1	0,659	0,0400	0,386	0,0513	0,515	0,0557	2,18	39,19

Tabela 7.7 – Resultados do treinamento de MLPs com duas camadas internas, com destaque para os dois menores desvios MSE no grupo de teste.

TOPOLOGIAS	TREINO		TESTE		VALIDAÇÃO			
	R	MSE	R	MSE	R	MSE	MBE%	RMSE%
16-3-3-1	0,505	0,0525	0,393	0,0495	0,557	0,0532	-2,13	38,28
16-5-3-1	0,642	0,0416	0,368	0,0516	0,560	0,0528	-4,25	38,15
16-7-3-1	0,635	0,0412	0,352	0,0533	0,549	0,0530	-2,06	38,22
16-9-3-1	0,658	0,0399	0,365	0,0552	0,529	0,0545	-1,87	38,77
16-11-3-1	0,663	0,0395	0,280	0,0567	0,498	0,0569	-0,85	39,60
16-13-3-1	0,664	0,0395	0,371	0,0511	0,569	0,0516	-2,28	37,73
16-15-5-1	0,694	0,0366	0,327	0,0549	0,570	0,0511	0,36	37,53
16-17-5-1	0,647	0,0410	0,299	0,0565	0,443	0,0616	-4,24	41,21
16-19-5-1	0,675	0,0385	0,310	0,0545	0,529	0,0554	0,002	39,08
16-21-5-1	0,689	0,0372	0,299	0,0573	0,506	0,0575	-5,89	39,81
16-23-5-1	0,679	0,0383	0,355	0,0537	0,473	0,0594	-0,29	40,44
16-25-5-1	0,686	0,0373	0,280	0,0570	0,428	0,0625	-3,55	41,50

Relatório Final de Atividades, 2011

O comportamento gráfico dos valores de MSE para o grupo de teste em função do número de neurônios das camadas internas é apresentado nas Figuras 7.5 e 7.6, para redes com uma e duas camadas internas, respectivamente.

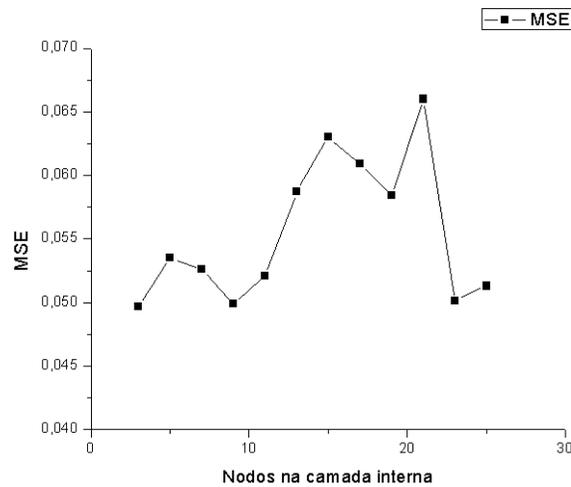


Figura 7.5 – Desvios MSE do grupo de teste para as diferentes topologias de redes neurais MLP com uma camada interna.

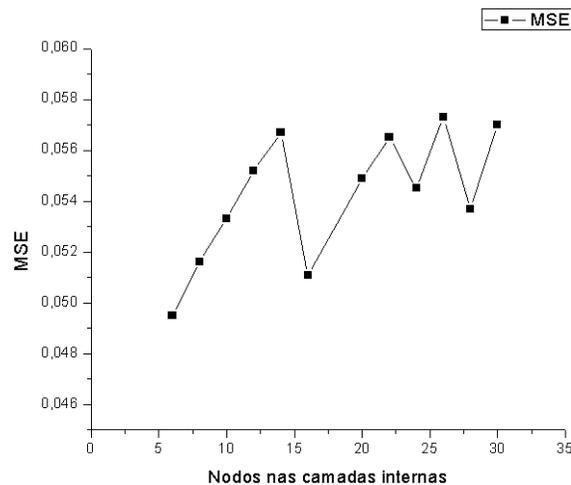


Figura 7.6 – Desvios MSE do grupo de teste para as diferentes topologias de redes neurais MLP com duas camadas internas.

As redes neurais com uma camada interna obtiveram menores desvios MSE no grupo de teste para 3 e 9 neurônios.

Relatório Final de Atividades, 2011

Para RNAs com duas camadas internas, tem-se um mínimo em 6 neurônios e aumento de MSE até 14 neurônios com uma queda em 16 ,voltando a subir chegando a uma flutuação a partir de 24 neurônios.

Partindo dos resultados iniciais, selecionaram-se as duas topologias com uma camada interna (“16-3-1 LOG LIN” e “16-9-1 LOG LIN”) e com duas camadas internas (“16-3-3-1 LOG LIN” e “16-13-3-1 LOG LIN”), que apresentaram os menores desvios MSE para as quais foram alteradas as funções de ativação. Os resultados obtidos são apresentados na Tabela 7.8.

Tabela 7.8 – Desempenho das melhores topologias iniciais de MLPs com a alteração das funções de ativação de suas camadas internas e de saída.

TOPOLOGIAS	TREINO		TESTE		VALIDAÇÃO			
	R	MSE	R	MSE	R	MSE	MBE%	RMSE%
16-3-1 LOG LIN	0,461	0,0555	0,384	0,0497	0,513	0,0561	-2,08	39,33
16-3-1 LOG LOG	0,567	0,0482	0,396	0,0492	0,537	0,0543	-1,94	38,68
16-3-1 LOG TAN	0,522	0,0513	0,383	0,0506	0,505	0,0565	-1,93	39,44
16-3-1 TAN LIN	0,417	0,0549	0,271	0,0536	0,473	0,0594	-3,01	40,45
16-3-1 TAN LOG	0,561	0,0484	0,024	0,0748	0,542	0,0555	-5,39	39,11
16-3-1 TAN TAN	0,551	0,0492	0,408	0,491	0,550	0,0532	-0,50	38,30
16-9-1 LOG LIN	0,625	0,0432	0,425	0,0499	0,534	0,0540	0,93	38,58
16-9-1 LOG LOG	0,625	0,0431	0,424	0,477	0,577	0,0520	-2,76	37,84
16-9-1 LOG TAN	0,643	0,0413	0,331	0,0530	0,504	0,0566	-2,57	39,51
16-9-1 TAN LIN	0,640	0,0416	0,277	0,0567	0,433	0,0619	-2,60	41,32
16-9-1 TAN LOG	0,670	0,0389	0,359	0,0525	0,535	0,0543	1,40	38,67
16-9-1 TAN TAN	0,649	0,0413	0,366	0,0539	0,512	0,566	3,71	39,51
16-3-3-1 LOG LIN	0,505	0,0525	0,393	0,0495	0,557	0,0532	-2,13	38,28
16-3-3-1 LOG LOG	0,550	0,0492	0,378	0,0512	0,515	0,0556	-1,31	39,15
16-3-3-1 LOG TAN	0,495	0,0532	0,365	0,0522	0,5501	0,0534	0,98	38,35
16-3-3-1 TAN LIN	0,469	0,0550	0,365	0,0514	0,556	0,0535	-0,46	38,40
16-3-3-1 TAN LOG	0,500	0,0529	0,370	0,0504	0,489	0,0582	-1,22	40,06
16-3-3-1 TAN TAN	0,470	0,0549	0,299	0,0551	0,460	0,0598	-2,07	40,58
16-13-3-1 LOG LIN	0,664	0,0395	0,371	0,0511	0,569	0,0516	-2,28	37,73
16-13-3-1 LOG LOG	0,690	0,0361	0,376	0,0544	0,537	0,0539	0,56	38,54
16-13-3-1 LOG TAN	0,693	0,0377	0,360	0,0551	0,544	0,0534	-0,96	38,35
16-13-3-1 TAN LIN	0,478	0,0544	0,205	0,0575	0,413	0,0631	-0,56	41,71
16-13-3-1 TAN LOG	0,693	0,0370	0,334	0,0560	0,516	0,0558	-2,74	39,21
16-13-3-1 TAN TAN	0,724	0,0336	0,310	0,0563	0,474	0,0599	-5,98	40,26

Relatório Final de Atividades, 2011

O gráfico de valores medidos e previstos para a topologia que apresentou o menor desvio MSE no grupo de teste (“16-3-1 TAN TAN”) para Prev48h, cujo está apresentado na Figura 7.7.

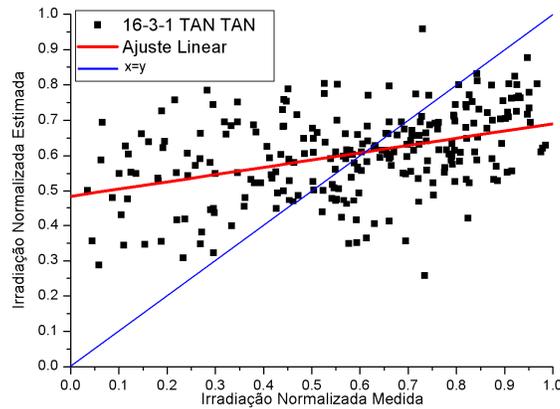


Figura 7.7 – Valores medidos e previstos pela melhor RNA para Prev48h.

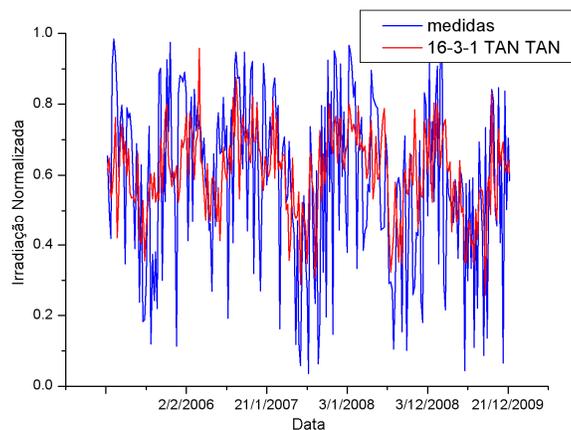


Figura 7.8 – Previsão da série temporal de irradiação global normalizada para o conjunto de validação, obtidos pela rede “16-3-1 TAN TAN”.

A análise do gráfico da Figura 7.8 sugere que as flutuações sazonais que ocorrem com a série temporal são bem modeladas pela melhor RNA, porém a resposta

Relatório Final de Atividades, 2011

obtida para valores extremos (picos e vales) da série não é adequadamente representada pela rede. Mais testes e experimentos devem ser desenvolvidos com o intuito de aumentar o fator de correlação dos valores estimados e observados na estação. Estes testes devem avaliar a quantidade de precursores a serem utilizados. Outros precursores devem ser avaliados.

7.3 – RNAs com Tempo de Previsão Prev72h

Para o tempo de previsão Prev72h, as variáveis empregadas como preditores e preditando que tiveram melhor representação para RNAs estão na Tabela 7.9.

Tabela 7.9 – Variáveis empregadas no experimento para Prev72h.

	Preditando	Preditores
Experimento	<i>glob_0</i>	<i>glob_-3, dir_-3, long_-3, tmed_-3, tmax_-3, tmin_-3, umid_-3, pres_-3</i>

Foram treinadas diversas topologias de MLPs com uma e duas camadas internas, com funções de ativação sigmóide logística nas camadas internas e linear nas camadas de saída, e algoritmo de treinamento de *Levenberg-Marquardt*. Os resultados obtidos são apresentados na Tabela 7.10 (para redes com uma camada interna) e na Tabela 7.11 (para redes com duas camadas internas).

Relatório Final de Atividades, 2011

Tabela 7.10 – Resultados do treinamento de MLPs com uma camada interna, com destaque para os dois menores desvios MSE no grupo de teste.

TOPOLOGIAS	TREINO		TESTE		VALIDAÇÃO			
	R	MSE	R	MSE	R	MSE	MBE%	RMSE%
8-3-1	0,438	0,0570	0,349	0,0522	0,437	0,0615	-2,81	41,16
8-5-1	0,524	0,0511	0,315	0,0538	0,400	0,0651	-6,60	42,34
8-7-1	0,532	0,0506	0,369	0,0510	0,455	0,0610	-5,20	41,00
8-9-1	0,446	0,0564	0,292	0,0544	0,402	0,0638	-3,36	41,92
8-11-1	0,528	0,0509	0,284	0,0578	0,480	0,0585	-3,06	40,16
8-13-1	0,563	0,0481	0,299	0,0548	0,305	0,0703	-2,65	44,03
8-15-1	0,535	0,0503	0,359	0,0517	0,471	0,0593	-3,54	40,43
8-17-1	0,615	0,0444	0,279	0,0573	0,376	0,0661	4,86	42,67
8-19-1	0,589	0,0461	0,284	0,0562	0,427	0,0622	-2,95	41,40
8-21-1	0,542	0,0497	0,313	0,0536	0,419	0,0628	-3,75	41,61
8-23-1	0,585	0,0467	0,338	0,0518	0,448	0,0611	-4,47	41,04
8-25-1	0,634	0,0421	0,340	0,0537	0,364	0,0673	2,39	43,06

Tabela 7.11 – Resultados do treinamento de MLPs com duas camadas internas, com destaque para os dois menores desvios MSE no grupo de teste.

TOPOLOGIAS	TREINO		TESTE		VALIDAÇÃO			
	R	MSE	R	MSE	R	MSE	MBE%	RMSE%
8-3-3-1	0,490	0,0536	0,320	0,0545	0,434	0,0616	-2,67	41,20
8-5-3-1	0,420	0,0581	0,172	0,0564	0,182	0,0745	-5,77	45,32
8-7-3-1	0,530	0,0507	0,348	0,0512	0,456	0,0604	-1,38	40,81
8-9-3-1	0,547	0,0494	0,325	0,0530	0,483	0,0582	-1,79	40,04
8-11-3-1	0,433	0,0573	0,296	0,0531	0,381	0,0651	-3,43	42,34
8-13-3-1	0,564	0,0481	0,375	0,0521	0,466	0,0593	-1,79	40,43
8-15-5-1	0,678	0,0381	0,231	0,0619	0,369	0,0672	-1,59	43,02
8-17-5-1	0,510	0,0522	0,355	0,0506	0,378	0,0663	-6,38	42,74
8-19-5-1	0,613	0,0440	0,288	0,0590	0,370	0,0679	-0,95	43,26
8-21-5-1	0,538	0,0502	0,344	0,0518	0,458	0,0601	0,67	40,69
8-23-5-1	0,592	0,0458	0,316	0,0556	0,427	0,0630	-5,03	41,66
8-25-5-1	0,604	0,0448	0,359	0,0533	0,440	0,0613	0,48	41,09

Relatório Final de Atividades, 2011

Para visualização dos resultados, os gráficos das Figuras 7.9 e 7.10 apresentam, respectivamente, os valores de MSE para o grupo de teste em função do número de neurônios das camadas internas.

Foram selecionadas as duas melhores topologias de MLPs com uma camada interna (“8-7-1 LOG LIN” e “8-15-1 LOG LIN”) e com duas camadas internas (“8-7-3-1 LOG LIN” e “8-17-5-1 LOG LIN”), para alteração das funções de ativação de suas camadas. Os resultados obtidos são apresentados na Tabela 7.12.

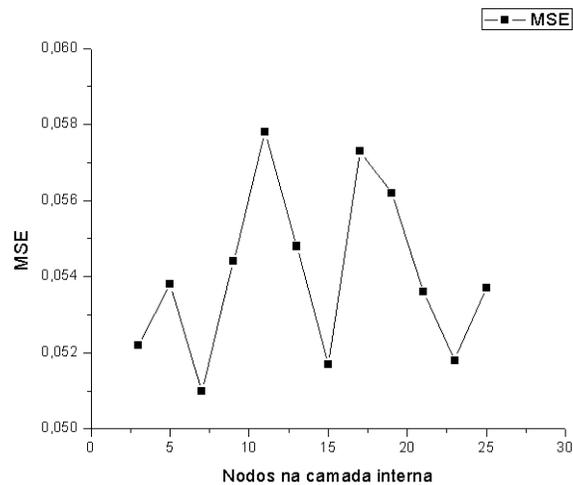


Figura 7.9 – Desvios MSE do grupo de teste para as diferentes topologias de redes neurais MLP com uma camada interna.

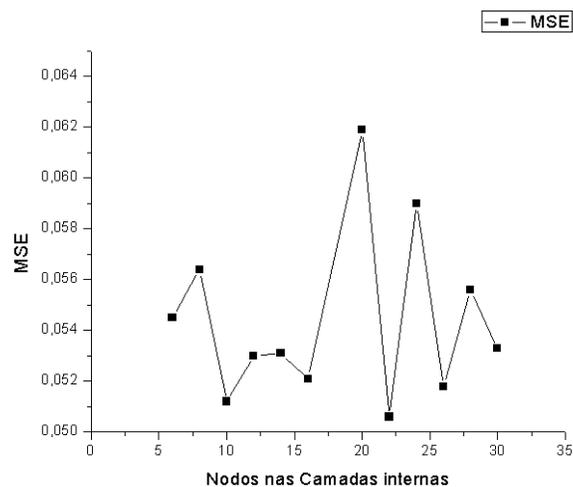


Figura 7.10 – Desvios MSE do grupo de teste para as diferentes topologias de redes neurais MLP com duas camadas internas.

Relatório Final de Atividades, 2011

Tabela 7.12 – Desempenho das melhores topologias iniciais de MLPs com a alteração das funções de ativação de suas camadas internas e de saída.

TOPOLOGIAS	TREINO		TESTE		VALIDAÇÃO			
	R	MSE	R	MSE	R	MSE	MBE%	RMSE%
8-7-1 LOG LIN	0,532	0,0506	0,369	0,0510	0,455	0,0610	-5,20	41,00
8-7-1 LOG LOG	0,494	0,0533	0,364	0,0504	0,508	0,0574	-2,85	39,77
8-7-1 LOG TAN	0,516	0,0517	0,351	0,0517	0,469	0,0607	-6,25	40,91
8-7-1 TAN LIN	0,512	0,0521	0,330	0,0540	0,471	0,0593	-3,56	40,42
8-7-1 TAN LOG	0,413	0,0585	0,325	0,0525	0,464	0,0599	-1,33	40,64
8-7-1 TAN TAN	0,578	0,0469	0,310	0,0584	0,429	0,0637	-3,43	41,88
8-15-1 LOG LIN	0,535	0,0503	0,359	0,0517	0,471	0,0593	-3,54	40,43
8-15-1 LOG LOG	0,517	0,0513	0,724	0,0664	0,006	0,0878	-4,20	49,20
8-15-1 LOG TAN	0,588	0,0461	0,322	0,0540	0,415	0,0626	0,93	41,53
8-15-1 TAN LIN	0,374	0,0606	0,286	0,0541	0,392	0,0646	-3,95	42,20
8-15-1 TAN LOG	0,541	0,0499	0,348	0,0514	0,463	0,0599	-1,44	40,64
8-15-1 TAN TAN	0,517	0,0517	0,274	0,0616	0,318	0,0750	3,13	45,47
8-7-3-1 LOG LIN	0,530	0,0507	0,348	0,0512	0,456	0,0604	-1,38	40,81
8-7-3-1 LOG LOG	0,473	0,0548	0,370	0,0522	0,484	0,0591	3,81	40,36
8-7-3-1 LOG TAN	0,455	0,0561	0,327	0,0524	0,465	0,0604	-5,03	40,81
8-7-3-1 TAN LIN	0,491	0,0536	0,365	0,0509	0,472	0,0598	0,46	40,60
8-7-3-1 TAN LOG	0,542	0,0498	0,351	0,0508	0,456	0,0607	-1,89	40,89
8-7-3-1 TAN TAN	0,278	0,0651	0,232	0,0556	0,205	0,0729	-3,54	44,83
8-17-5-1 LOG LIN	0,510	0,0522	0,355	0,0506	0,378	0,0663	-6,38	42,74
8-17-5-1 LOG LOG	0,590	0,0460	0,278	0,0562	0,408	0,0632	-0,82	41,74
8-17-5-1 LOG TAN	0,536	0,0503	0,285	0,0558	0,422	0,0626	-2,58	41,53
8-17-5-1 TAN LIN	0,386	0,0600	0,300	0,0529	0,331	0,0678	-3,47	43,22
8-17-5-1 TAN LOG	0,558	0,0485	0,364	0,0506	0,471	0,0599	-4,82	40,62
8-17-5-1 TAN TAN	0,632	0,0424	0,272	0,0562	0,325	0,0676	-4,83	43,15

Ao final da análise, obteve-se o menor MSE no grupo de teste com a topologia “8-7-1 LOG LOG” para o tempo de previsão 72h. O comportamento gráfico das previsões da RNA em questão é apresentado nos gráficos das Figuras 7.11 e 7.12. A Figura 7.11 apresenta os valores previstos pela RNA “8-7-1 LOG LOG” em comparação com os valores medidos de irradiação solar global normalizada. A Figura 7.12 expõe o comportamento da previsão da série temporal de irradiação global em comparação com os valores da série temporal efetivamente medidos (e normalizados).

Relatório Final de Atividades, 2011

Para Prev72h, as configurações utilizadas para a rede neural representaram muito fracamente as flutuações sazonais da série temporal de irradiação global, além de não responder adequadamente aos valores extremos (picos e vales) da série. Conclui-se então que, com a metodologia proposta, a realização de previsões três passos à frente (Prev72h) não é viável. Novos experimentos serão realizados adequando os precursores utilizados.

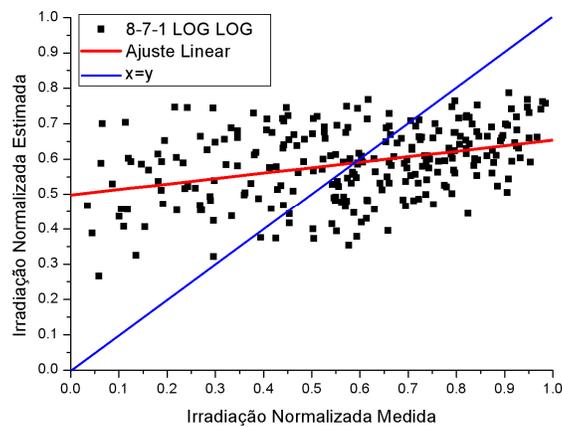


Figura 7.11 – Valores medidos e previstos pela melhor RNA para Prev72h.

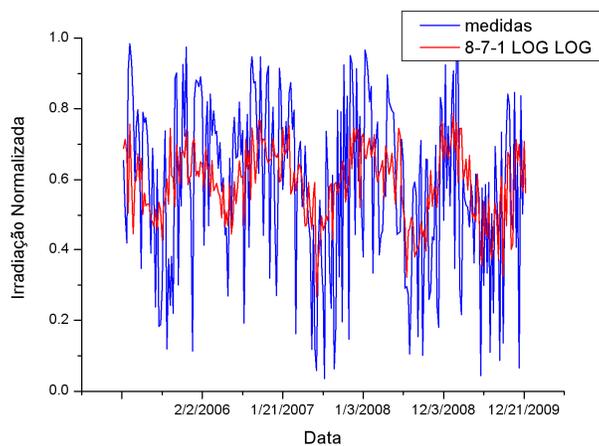


Figura 7.12 – Previsão da série temporal de irradiação global normalizada para o conjunto de validação, obtidos pela rede “8-7-1 LOG LOG”.

7.4 – Comparação com Alguns Resultados da Literatura Científica

Segundo Oliveira et al. (2004), as redes neurais artificiais tem sido utilizadas amplamente no reconhecimento de padrões e na previsão de séries temporais. Inúmeros artigos tem sido publicados em revistas especializadas abordando diferentes aspectos da previsão de irradiação solar com o uso de RNAs, seguindo a tendência observada em vários setores de pesquisa da utilização de métodos alternativos que apresentem boa destreza (Guarnieri, 2006, p. 64).

Guarnieri (2006, p. 65) afirma que a maioria dos estudos envolvendo radiação solar e RNAs tem por meta a estimativa de irradiação solar a partir de variáveis meteorológicas para os mesmos instantes das medidas, e que estudos de previsão de séries temporais de irradiação solar são bem menos frequentes.

Paoli et al. (2009) desenvolveram uma metodologia para a previsão de valores diários de irradiação solar global a partir da utilização de um pré-processamento da série temporal e aplicação em redes neurais do tipo MLP. As previsões obtidas indicaram valores de RMSE de cerca de 21% ($RMSE < 998 \text{ Wh/m}^2$), o que torna suas previsões similares ou melhores do que as obtidas via métodos convencionais, como modelos ARIMA e inferência Bayesiana, conforme destacam os autores. Os resultados gráficos obtidos por Paoli et al. (2009) são apresentados nas Figuras 7.17 e 7.18.

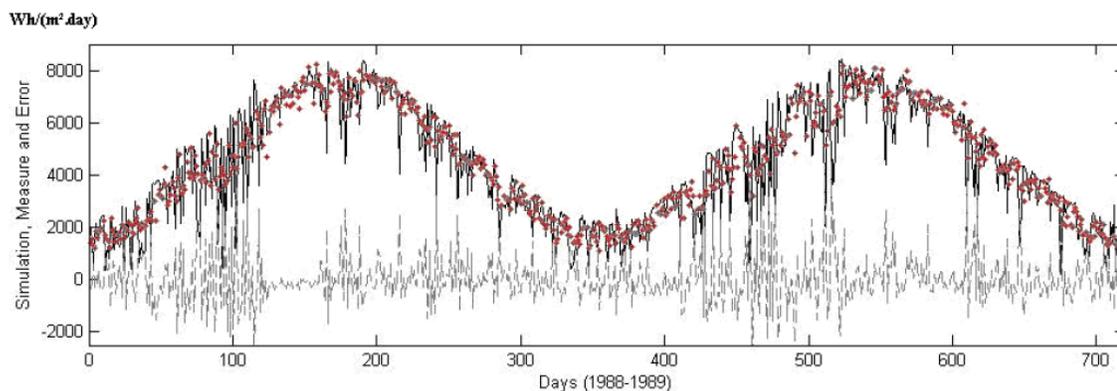


Figura 7.13 – Comparação entre os valores reais (linha contínua) e as previsões (pontos vermelhos) de irradiação global obtidos por Paoli et al. (2009), juntamente com os erros de previsão (linha tracejada). Fonte: Paoli et al. (2009).

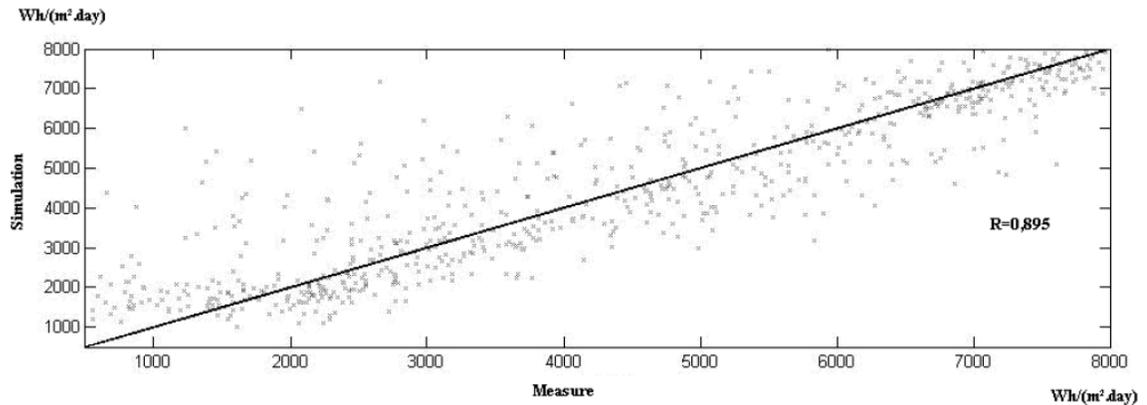


Figura 7.14 – Correlação entre os valores reais (eixo das abscissas) e as estimativas (eixo das ordenadas) de irradiação global obtida por Paoli (2009).

Fonte: Paoli et al. (2009).

Tseles et al. ([20--?]) apresenta um estudo sobre a previsão de valores de temperatura do ar e irradiação solar utilizando diferentes técnicas computacionais e estatísticas, dentre as quais as inúmeras arquiteturas de redes neurais artificiais. O autor obteve como melhor desempenho para previsões da média diária de irradiação solar uma RNA com uma camada interna com quinze neurônios, obtendo erros MSE próximos a 0,011. O comportamento gráfico das previsões obtidas pelos autores está apresentado nas Figuras 7.19.

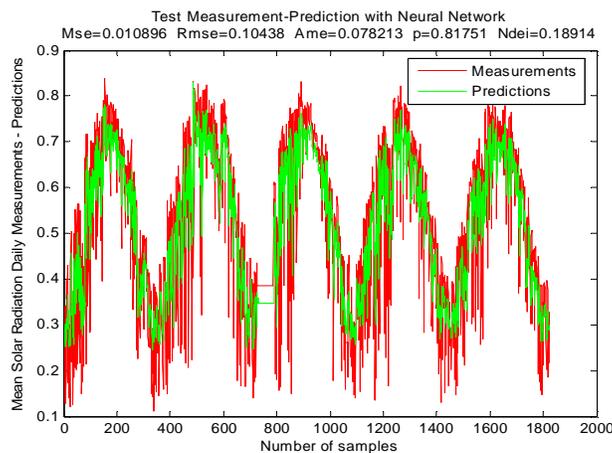


Figura 7.15 – Comparação entre os valores medidos e previstos de irradiação solar obtidos por Tseles et al. ([20--?]). Fonte: Tseles et al. ([20--?]).

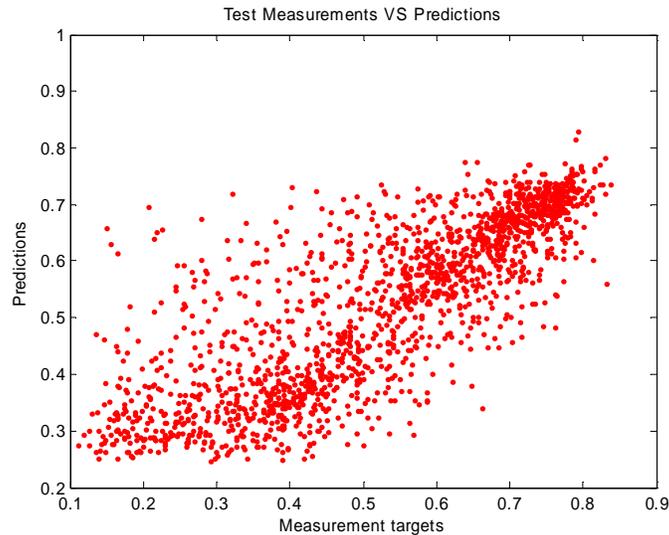


Figura 7.16 – Correlação obtida por Tseles et al ([20--?]) entre os valores reais (eixo das abscissas) e as previsões (eixo das ordenadas). Fonte: Tseles et al. ([20--?]).

Guarnieri (2006) realizou um estudo de refinamento das previsões de irradiação solar obtidas pelo modelo de previsão do tempo ETA/CPTEC operacional no CPTEC/INPE – MCT, a partir da utilização de redes neurais artificiais do tipo MLP, com algoritmo de treinamento Rprop. O autor selecionou 8 entre 36 variáveis de saída do modelo ETA/CPTEC como preditoras para as RNAs, conseguindo ganho significativo para dois sítios brasileiros (São Martinho da Serra/RS e Florianópolis/SC).

A resposta obtida pelo modelo ETA/CPTEC por Guarnieri (2006) para previsões da integral diária de irradiância solar é apresentada na Figura 7.21, cujos valores de RMSE são de 42%, um comportamento similar ao obtido para as RNAs do presente trabalho, que tiveram valores de RMSE muito próximos a esse.

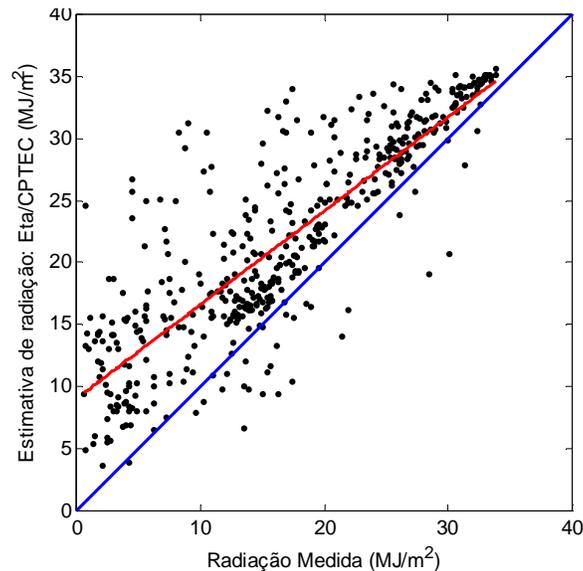


Figura 7.17 – Diagrama de dispersão das previsões da integral diária de irradiância solar para São Martinho da Serra/RS obtida por Guarnieri (2006). Fonte: Guarnieri (2006).

Após o refinamento das previsões do modelo ETA/CPTEC com o uso de RNAs, Guarnieri (2006) obteve valores de RMSE próximos a 26% para as integrais diárias de irradiância solar. O comportamento gráfico das previsões obtidas por Guarnieri (2006) para o caso é apresentado na Figura 7.22.

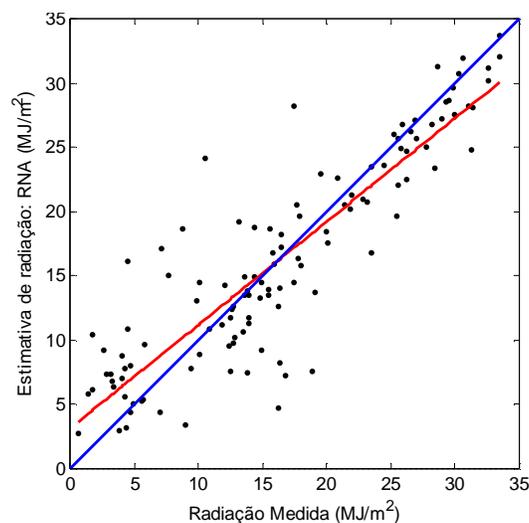


Figura 7.18 – Refinamento das previsões da integral diária de irradiância solar obtidas por Guarnieri (2006) para com o uso de RNAs. Fonte: Guarnieri (2006).

CONCLUSÕES

Durante o período de seis meses correspondente ao período que o atual estudante assumiu o Projeto de Iniciação Científica, o acadêmico teve a oportunidade de realizar revisão bibliográfica de diversas literaturas relacionada com a temática proposta para o Projeto de Avaliação do Potencial Solar do Sul do Brasil, em especial sobre assuntos referentes à parametrização dos processos de transferência radiativa que ocorrem entre a radiação solar e os constituintes atmosféricos e sobre redes neurais artificiais.

Os objetivos propostos para a pesquisa foram alcançados, tendo-se adquirido conhecimento do uso de ferramentas para o desenvolvimento de modelos de redes neurais aplicadas aos dados coletados na estação SONDA-SMS para a previsão de curto prazo da irradiação solar.

De acordo com os resultados preliminares obtidos até o momento, as MLPs para os tempos de previsão Prev24h e Prev48h apresentaram os melhores desempenhos, com desvios estatísticos RMSE%. No entanto, aprimoramentos ainda serão realizados no andamento do Projeto para obtenção de melhores resultados.

Para os três tempos de previsão, observou-se que as melhores RNAs representam corretamente as flutuações sazonais da série de dados, porém não respondendo adequadamente aos valores extremos da série temporal (os máximos e mínimos, ou seja, os picos e vales da série).

REFERÊNCIAS BIBLIOGRÁFICAS

Andrade, M. F. **Caracterização das Fontes de Material Particulado e Ozônio Troposférico na Região Metropolitana de São Paulo**. 2006. Tese (Doutorado) – Instituto de Astronomia, Geofísica e Ciências Atmosféricas (IAG/USP), São Paulo, 2006.

Barreto, J. M. **Introdução às Redes Neurais Artificiais**. Florianópolis: Laboratório de Conexionismo e Ciências Cognitivas – UFSC, 2002, 57p.

Braga, A. P.; Carvalho A. C. P. F.; Ludermir, T. B. **Fundamentos de redes neurais artificiais**. Rio de Janeiro: 11a Escola de Computação/Universidade Federal do Rio de Janeiro, 1998. 246p.

Brasseur, G.; Solomon, S. **Aeronomy of the middle atmosphere**. Dordrecht, Holland: ED. Reidel Publishing Company, 1986, 452p.

Coulson, K. L. **Solar and Terrestrial Radiation: Methods and Measurements**. New York: Academic Press, 1975, 322p.

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 6 – for use with MATLAB®**. The MathWorks Inc, 2008. Disponível em <http://www.mathworks.com/access/helpdesk/help/pdf_doc/nnet/nnet.pdf> e acessado em Outubro de 2010.

Relatório Final de Atividades, 2011

Empresa de Pesquisa Energética (EPE). **Balço Energético Nacional 2010: Ano Base 2009**. Rio de Janeiro, 2010, 276p. Disponível online em <<https://ben.epe.gov.br/>> e acessado em Novembro de 2010.

Ferrari, F. **Introdução à Inteligência Artificial**. *Lectures Notes*, 2005, 57 p. Disponível em <<http://www.ferrari.pro.br/home/documents/FFerrari-Introducao-IA.pdf>> e acessado em Outubro de 2010.

Fiorin, D. V. **Emprego de Redes Neurais Artificiais na Análise de Parâmetros de Radiação Solar**. 2009. 105 p. Relatório de Estágio Supervisionado em Engenharia Química – Universidade Federal de Santa Maria, Santa Maria, 2009.

Gambi, W. **Avaliação de um Modelo Físico Estimador de Irradiância Solar Baseado em Satélites Geoestacionários**. 1998. Dissertação (Mestrado) – Universidade Federal de Santa Catarina, Florianópolis, 1998.

Grimm, A. M. **Meteorologia Básica – Notas de Aula**. Universidade Federal do Paraná. Disponível em <<http://fisica.ufpr.br/grimm/aposmeteo/>>. Acesso em Dezembro de 2003.

GSFC/NASA – *Goddard Space Flight Center. National Aeronautical and Space Administration* (NASA). Disponível em <www.nasa.gov/goddard/>. Acesso em Outubro de 2003.

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. Dissertação (Mestrado) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2006.

Hagan, M. T.; Menhaj, M. B. Training Feedforward Networks with the Marquardt Algorithm. **IEEE Transactions on Neural Networks**, v. 5, n. 6, 1994.

Relatório Final de Atividades, 2011

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

Hebb, D. O. **The Organization of Behavior**. New York: Wiley & Sons, 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.

IPCC 2001 – Intergovernmental Panel on Climate Change. **A plan for a Research Program on Aerosol Radiative forcing and climate change**. Washington, D.C.: National Academy Press, 2001.

IPCC 2007 – Intergovernmental Panel on Climate Change. **Climate Changes 2007: The Physical Sciences Basis**. Whashington D.C.: National Academy Press, 2007.

Iqbal, M. **An introduction to solar radiation**. Toronto: Academic Press Canada, 1983, 390p.

Kidder, S. Q.; Vonder Haar, T. H. **Satellite Meteorology: an introduction**. San Diego: Academic Press, 1995, 466 p.

Liou, K. N. **An introduction to atmospheric radiation**. New York: Academic Press Inc., 1980, 392p.

Ludwig, O.; Montgomery, E. **Redes Neurais: Fundamentos e Aplicações com Programas em C**. Rio de Janeiro: Editora Ciência Moderna Ltda., 2007, 125p.

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

Relatório Final de Atividades, 2011

Martins, F. R.; Pereira, E. B.; Abreu, S. L.; Colle, S. Satellite-derived solar resource maps for Brazil – SWERA project. **Solar Energy**, 81,517-528, 2007.

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**, In press, 2007.

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.

Minsky, M. L.; Papert, S. A. **Perceptrons**. Cambridge, MA: MIT Press, 1988.

Mohandes, M.; Balghonain, A.; Kassas, M.; Rehman, S.; Halawani, T. O. Use of radial basis functions for estimating monthly mean daily solar radiation. **Solar Energy**. v. 68, n. 2, p. 161-168, 2000.

Mohandes, M.; Rehman, S.; Halawani, T. O. Estimation of global solar radiation using artificial neural networks. **Renewable Energy**, v. 14, n. 1-4, p. 179-184, 1998.

Nguyen, D.; Widrow, B. **Improving the Learning Speed of 2-Layer Neural Networks by Choosing Initial Values of the Adaptatives Weights**, Stanford University, Stanford, CA, 1990.

Oliveira, M. A.; Favero, L. P. L. Uma Breve Descrição de Algumas Técnicas para Análise de Séries Temporais: Séries de Fourier, Wavelets, Arima, Modelos Estruturais para Séries de Tempo e Redes Neurais. In: **VI SEMEAD – Seminários em Administração**, São Paulo, 2004.

Paoli, C.; Voyant, C.; Muselli, M.; Nivet, M.L. Solar Radiation Forecasting Using Ad-Hoc Time Series Preprocessing and Neural Networks. **Lecture Notes in Computer Science**, v. 5754, p. 898-907, 2009.

Relatório Final de Atividades, 2011

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: Atlas. Programa das Nações Unidas para o Meio Ambiente, 2006. Disponível em <<http://www.sonda.cptec.inpe.br>>.

Plana-Fattori, A., Ceballos, J. C. **Glossário de Termos Técnicos em Radiação Atmosférica - versão 2.0**. 2005. Instituto de Astronomia, Geofísica e Ciências Atmosféricas (IAG/USP) – Centro de Previsão do Tempo e Estudos Climáticos (CPTEC/INPE), 2005. Disponível em <<http://www.cptec.inpe.br/satelite/metsat/pesquisa/gloss1/glossar.htm>>. Acesso em Março de 2005.

Rosenblatt, F. **Principles of Neurodynamics**. Washington: Spartan Books, 1962.

Rumelhart, D. E.; Hinton G. E.; Williams, R. J. Learning representations by backpropagation errors. **Nature**, v. 323, p. 533-536, 1986.

Sayao, A. C. **Estudo da Variabilidade Sazonal da Profundidade Óptica do Aerossol em São Paulo a partir de Radiômetros MFRSR**. 2008. 131 p. Dissertação (Mestrado) – Instituto de Astronomia, Geofísica e Ciências Atmosféricas (IAG/USP), São Paulo, 2008.

Sfetsos, A.; Coonick, A. H. Univariate and multivariate forecasting of hourly solar radiation with artificial intelligence techniques. **Solar Energy**, v. 68, n. 2, p. 169-178, 2000.

Soares, P. P. S.; Nadal, J. Aplicação de uma Rede Neural Feedforward com Algoritmo de Levenberg-Marquardt para Classificação de Alterações do Segmento ST do Eletrocardiograma. In: **Proceedings of the IV Brazilian Conference on Neural Networks**, São José dos Campos, p. 384-389, 1999.

SONDA, Sistema de Organização Nacional de Dados Ambientais. Instituto Nacional de Pesquisas Espaciais. Centro de Ciências do Sistema Terrestre (CCST/INPE). Disponível em <<http://www.sonda.cptec.inpe.br>>. Acesso em Outubro de 2010.

Tatibana, C. Y.; Kaetsu, D. Y. **Uma Introdução às Redes Neurais Artificiais**. Disponível em <<http://www.din.uem.br/ia/neurais/>>. Acesso em Outubro de 2010.

Tomalsquim, M. T.; Guerreiro, A.; Gorini, R. Matriz Energética Brasileira: uma Nova Perspectiva. **Novos Estudos – CEBRAP**, São Paulo, n. 79, 2007.

Tseles, D. I.; Dounis, A. I.; Zisos, J. **Meteorological Parameters Forecasting for Renewable Energy Systems Using Soft Computing Techniques**. Technological Educational Institute of Piraeus, Department of Automation, 250, P. Ralli & Thivon Str., Egaleo, 122 44, Greece.

Tymvios F. S.; Jacovides, C. P.; Michaelides, S. C.; Scouteli, C. Comparative study of Angström's and artificial neural networks' methodologies in estimating global solar radiation. **Solar Energy**, In Press, 2004.

Vieira, R. C.; Roisenberg, M. **Redes Neurais Artificiais**: um Breve Tutorial. Laboratório de Conexão e Ciências Cognitivas – UFSC,

Wallace, J. M.; Hobbs, P. V. **Atmospheric Science**: an introductory survey. San Diego: Academic Press, 1977, 467p.

Widrow, B.; Hoff, M. E. Adaptive switching circuits. In: Western Electronic Show and Convention (WESCON), 1960, Los Angeles, CA, EUA. In: **Proceedings of IRE WESCON Convention Record**. Los Angeles: Institute of Radio Engineers - IRE, v. 4, p. 96-104, 1960.