

VINICIUS LEONARDO GADIOLI DA SILVA

**Predição da radiação solar por meio de modelagem linear  
(ARX e ARMAX) e modelagem não-linear (Redes Neurais)**


Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, para obtenção do título de *Magister Scientiae*.

VIÇOSA  
MINAS GERAIS – BRASIL  
2016

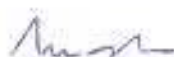
**Predição da radiação solar por meio de modelagem linear (ARX e ARMAX) e modelagem não-linear (Redes Neurais)**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, para obtenção do título de *Magister Scientiae*.

APROVADA: 02 de dezembro de 2016



Olga Moraes Toledo



Paulo Marcos de Barros Monteiro



Paulo José Hamakawa



Joyce Correna Carlo (Coorientadora)



Dely Oliveira Filho  
(Orientador)

**Ficha catalográfica preparada pela Biblioteca Central da Universidade  
Federal de Viçosa - Câmpus Viçosa**

T

S586p  
2016  
Silva, Vinicius Leonardo Gadioli da, 1991-  
Predição da radiação solar por meio de modelagem linear  
(ARX e ARMAX) e modelagem não-linear (Redes Neurais) /  
Vinicius Leonardo Gadioli da Silva. – Viçosa, MG, 2016.  
xvi, 93f. : il. (algumas color.) ; 29 cm.

Orientador: Delly Oliveira Filho.  
Dissertação (mestrado) - Universidade Federal de Viçosa.  
Inclui bibliografia.

1. Radiação solar. 2. Modelos matemáticos.  
3. Meteorologia. 4. Inteligência artificial. I. Universidade Federal  
de Viçosa. Departamento de Engenharia Agrícola. Programa de  
Pós-graduação em Engenharia Agrícola. II. Título.

CDD 22 ed. 551.5271

À minha família

*“Wyrð bið ful aræd – O destino é inexorável”* Autor desconhecido

## AGRADECIMENTOS

À Deus, por me abrir as portas e permitir assim que os próximos agradecimentos pudessem ser realizados.

Ao Professor Dely Oliveira Filho pela orientação e participação neste trabalho.

À Professora Joyce pela co-orientação, incentivo e prontidão em ajudar sempre que necessário.

À Professora Olga e aos Professores Paulo Monteiro e Paulo Hamakawa por aceitarem o convite de fazer parte da banca de defesa da dissertação.

À Professora Ketia, por ter sido minha grande incentivadora na área da Pesquisa desde a graduação.

Aos Professores que ao longo dos anos participaram da minha formação.

À minha família por sempre me apoiar, principalmente à minha mãe Ângela por todo seu esforço em minha criação e formação.

À Lais pelo amor, apoio e incentivo em todos os momentos.

Aos colegas da Energia.

Aos amigos de Viçosa.

## BIOGRAFIA

VINICIUS LEONARDO GADIOLI DA SILVA nasceu em São Bernardo do Campo, São Paulo, filho de Manoel Messias Leonardo da Silva e Ângela Siam Gadioli da Silva.

Cursou a educação básica no Centro Educacional de Aracruz e o ensino médio no Centro Educacional Casa do Estudante.

Em 2008, ingressou no curso de Engenharia Elétrica da Universidade Federal de Viçosa, UFV, em Viçosa, MG, concluindo em janeiro de 2015.

Entre 2013 e 2014 realizou graduação sanduíche pelo programa Ciência sem Fronteiras. Estudou Engenharia Elétrica na instituição Politécnico di Torino, na Itália, onde cursou disciplinas nas áreas de: Engenharia Elétrica, Mecatrônica e Computação.

Durante a graduação realizou estágios nas áreas de: Automação, Eletrotécnica e, durante o intercâmbio na Itália, na área de Projetos Automotivos.

Também foi bolsista de iniciação científica durante 3 anos e meio, período no qual atuou nas áreas de: Processamento Digital de Imagens, Inteligência Computacional e Visão Computacional.

Em março de 2015 ingressou no programa de Pós-Graduação, em nível de Mestrado, em Engenharia Agrícola, na Área de Energia da UFV.

Em março de 2016 ingressou no Corpo de Engenheiros da Marinha do Brasil, onde atua até o presente momento.

## SUMÁRIO

LISTA DE QUADROS .....	viii
LISTA DE FIGURAS.....	x
RESUMO.....	xiii
ABSTRACT .....	xv
<b>Capítulo 1 Introdução geral .....</b>	<b>1</b>
<b>1.1 Considerações Iniciais.....</b>	<b>1</b>
<b>1.2 Objetivo Geral .....</b>	<b>2</b>
<b>1.3 Objetivos Específicos .....</b>	<b>3</b>
<b>1.4 Limitações.....</b>	<b>3</b>
<b>1.5 Estrutura.....</b>	<b>3</b>
<b>1.6 Referências .....</b>	<b>4</b>
<b>Capítulo 2 Estado da Arte: Dados Meteorológicos e Radiação Solar.....</b>	<b>6</b>
<b>2.1 Introdução .....</b>	<b>6</b>
<b>2.2 Dados Meteorológicos e Estações Meteorológicas Automáticas</b>	<b>7</b>
<b>2.3 Arquivos Climáticos.....</b>	<b>10</b>
<b>2.4 Radiações Solar Global (G), Ultravioleta (UV), Visível (PAR) e</b>	
<b>    Infravermelha (IV). .....</b>	<b>11</b>
<b>2.5 Conclusão .....</b>	<b>17</b>
<b>2.6 Referências Bibliográficas.....</b>	<b>17</b>
<b>Capítulo 3 - Modelagem e Identificação de Sistemas ARX e ARMAX ...</b>	<b>24</b>
<b>3.1 Introdução .....</b>	<b>24</b>
<b>3.2 Modelos ARX e ARMAX .....</b>	<b>26</b>
<b>3.3 Metodologia .....</b>	<b>29</b>
<b>3.3.1 Introdução .....</b>	<b>29</b>
<b>3.3.2 Modelagem do Banco de Dados Meteorológicos Baseada</b>	
<b>        em Identificação de Sistemas .....</b>	<b>31</b>
<b>3.4 Resultados e Discussão .....</b>	<b>33</b>
<b>3.5 Considerações Finais .....</b>	<b>66</b>
<b>3.6 Referências Bibliográficas.....</b>	<b>67</b>
<b>Capítulo 4 - Modelagem não-linear (Redes Neurais Artificiais).....</b>	<b>69</b>
<b>4.1 Introdução .....</b>	<b>69</b>
<b>4.2 Breve Histórico .....</b>	<b>69</b>
<b>4.3 Redes Neurais Artificiais .....</b>	<b>71</b>
<b>4.3.1 Características das RNA's .....</b>	<b>72</b>

4.3.2 Processos de Aprendizado.....	74
4.4 Metodologia .....	75
4.5 Resultados e Discussão .....	76
4.6 Considerações Finais .....	89
4.7 Referências Bibliográficas.....	90
Conclusões Gerais .....	92
Sugestões para Trabalhos Futuros .....	93

## LISTA DE QUADROS

Quadro 1 - Amostra de dados climáticos horários de um dia típico do mês de Janeiro de 2015. Fonte: GUIMARÃES E CARLO, 2014. ....	34
Quadro 2 - Entradas e saídas utilizadas na modelagem linear.....	36
Quadro 3 - Valores RMSE e FIT para Radiação Extraterrestre Normal modelo ARX.....	38
Quadro 4- Valores RMSE e FIT para Radiação Extraterrestre Normal modelo ARMAX .....	41
Quadro 5 - Valores RMSE e FIT para Radiação Infravermelha Horizontal modelo ARX.....	44
Quadro 6 - Valores RMSE e FIT para Radiação Infravermelha Horizontal modelo ARMAX .....	45
Quadro 7 - Valores RMSE e FIT para Radiação Extraterrestre Horizontal modelo ARX.....	48
Quadro 8 - Valores RMSE e FIT para Radiação Extraterrestre Horizontal modelo ARMAX .....	51
Quadro 9 - Valores RMSE e FIT para Radiação Direta Normal modelo ARX...54	
Quadro 10 - Valores RMSE e FIT para Radiação Direta Normal modelo ARMAX .....	57
Quadro 11 - Valores RMSE e FIT para Radiação Difusa Horizontal modelo ARX .....	60
Quadro 12 - Valores RMSE e FIT para Radiação Difusa Horizontal modelo ARMAX .....	63
Quadro 13 - Índices atribuídos às faixas de temperatura .....	80
Quadro 14 - Correlação entre cada composição de radiação e temperaturas do banco de dados.....	81
Quadro 15 - Entradas e saídas da rede neural.....	81
Quadro 16 - Análise estatística $N_e = 1$ .....	83
Quadro 17 - Análise estatística $N_e = 2$ .....	83
Quadro 18 - Análise estatística $N_e = 3$ .....	84
Quadro 19 - Análise estatística $N_e = 4$ .....	84
Quadro 20 - Análise estatística $N_e = 5$ .....	85
Quadro 21 - Análise estatística $N_e = 6$ .....	85

Quadro 22 - Análise estatística $N_e = 7$ .....	86
Quadro 23 - Análise estatística $N_e = 8$ .....	86
Quadro 24 - Análise estatística $N_e = 9$ .....	87
Quadro 25 - Análise estatística $N_e = 10$ .....	87

## LISTA DE FIGURAS

Figura 1 - Uma típica estação meteorológica automática – EMA com sensores, mastro com caixa datalogger, painel solar, para-raios, cercada. Fonte: INMET, 2011.....	9
Figura 2 -Detalhe de uma estação meteorológica automática, mostrando a esquerda o pluviômetro, ao centro a antena de comunicação via satélite e à direita o "datalogger" com sensor de temperatura fixados ao mastro. Fonte: INMET, 2011.....	9
Figura 3 - Irradiação média anual. Fonte: BRASIL,1998. ....	13
Figura 4 - Variabilidade mensal da irradiação anual. Fonte: BRASIL,1998. ....	13
Figura 5 - A relação da frequência com o comprimento de onda eletromagnética. Fonte: MADEIRA, 2010. ....	15
Figura 6 – Sistema linear invariante no tempo. Fonte: AGUIRRE, 2007. ....	24
Figura 7 - Diagrama de blocos - ARX .....	26
Figura 8 - Diagrama de blocos - ARMAX.....	27
Figura 9 - Processo de identificação do sistema. Fonte: LJUNG, 1999.....	28
Figura 10 – Estágios do procedimento de identificação de sistemas. Fonte: LJUNG, 1999. ....	30
Figura 11 – Modelo ARX ( $n_a = 4, n_b = 4, n_c = 3$ ) para predição de dados de Radiação Extraterrestre Normal sem supressão do zero .....	38
Figura 12 - Modelo ARX ( $n_a = 4, n_b = 4, n_c = 3$ ) para predição de dados de Radiação Extraterrestre Normal com supressão do zero.....	39
Figura 13 – Modelo ARMAX ( $n_a = 4, n_b = 4, n_c = 4, n_k = 3$ ) para predição de dados de Radiação Extraterrestre Normal sem supressão do zero.....	41
Figura 14 - Modelo ARMAX ( $n_a = 4, n_b = 4, n_c = 4, n_k = 3$ ) para predição de dados de Radiação Extraterrestre Normal com supressão do zero.....	41
Figura 15 - Modelo ARX ( $n_a = 3, n_b = 3, n_k = 1$ ) para predição de dados de Radiação Infravermelha Horizontal sem supressão do zero.....	45
Figura 16 - Modelo ARMAX ( $n_a = 3, n_b = 3, n_c = 3, n_k = 1$ ) para predição de dados de Radiação Infravermelha Horizontal sem supressão do zero. ....	45
Figura 17 - Modelo ARX ( $n_a = 3, n_b = 3, n_k = 3$ ) para predição de dados de Radiação Extraterrestre Horizontal sem supressão do zero. ....	48
Figura 18 - Modelo ARX ( $n_a = 3, n_b = 3, n_k = 3$ ) para predição de dados de Radiação Extraterrestre Horizontal com supressão do zero. ....	49

Figura 19- Modelo ARMAX ( $n_a = 3, n_b = 3, n_c = 3, n_k = 3$ ) para predição de dados de Radiação Extraterrestre Horizontal sem supressão do zero. ....	51
Figura 20 - Modelo ARMAX ( $n_a = 4, n_b = 4, n_c = 4, n_k = 3$ ) para predição de dados de Radiação Extraterrestre Horizontal com supressão do zero. ....	52
Figura 21 - Modelo ARX ( $n_a = 4, n_b = 4, n_k = 1$ ) para predição de dados de Radiação Direta Normal sem supressão do zero.....	55
Figura 22 - Modelo ARX ( $n_a = 4, n_b = 4, n_k = 1$ ) para predição de dados de Radiação Direta Normal com supressão do zero.....	55
Figura 23 - Modelo ARMAX ( $n_a = 5, n_b = 5, n_c = 5, n_k = 1$ ) para predição de dados de Radiação Direta Normal sem supressão do zero.....	58
Figura 24 - Modelo ARMAX ( $n_a = 5, n_b = 5, n_c = 5, n_k = 1$ ) Radiação Direta Normal com supressão do zero.....	58
Figura 25 - Modelo ARX ( $n_a = 3, n_b = 3, n_k = 1$ ) para predição de dados de Radiação Difusa Horizontal sem supressão do zero.....	61
Figura 26 - Modelo ARX ( $n_a = 4, n_b = 4, n_k = 1$ ) para predição de dados de Radiação Difusa Horizontal com supressão do zero.....	61
Figura 27 - Modelo ARMAX ( $n_a = 6, n_b = 6, n_c = 6, n_k = 1$ ) para predição de dados de Radiação Difusa Horizontal sem supressão do zero.....	64
Figura 28 - Modelo ARMAX ( $n_a = 6, n_b = 6, n_c = 6, n_k=1$ ) para predição de dados de Radiação Difusa Horizontal com supressão do zero.....	64
Figura 29 - Representação de um neurônio biológico. Fonte: BARRETO, 2002. ....	72
Figura 30 – Modelo de McCulloch & Pitts. Fonte: BARRETO, 2002.....	73
Figura 31 - Rede Neural Artificial .....	73
Figura 32 - Treinamento da rede neural com propagação de erro (backpropagation). ....	76
Figura 33 - Histograma da distribuição de temperatura do banco de dados.....	76
Figura 34 - Histograma da distribuição de radiação global horizontal do banco de dados. ....	77
Figura 35 – Histograma da distribuição de radiação extraterrestre horizontal do banco de dados. ....	77
Figura 36 - Histograma da distribuição de radiação extraterrestre normal do banco de dados. ....	78
Figura 37 - Histograma da distribuição de radiação direta normal do banco de dados. ....	78

Figura 38 - Histograma da distribuição de radiação difusa horizontal do banco de dados. ....78

## RESUMO

SILVA, Vinicius Leonardo Gadioli da, M.Sc., Universidade Federal de Viçosa, dezembro de 2016. **Predição da Radiação Solar por meio de modelagem linear (ARX e ARMAX) e modelagem não-linear (Redes Neurais)**. Orientador: Delly Oliveira Filho. Coorientadores: Joyce Correna Carlo e Aristides Ribeiro.

O conhecimento da radiação solar é de vital importância para caracterizar o clima de uma região. A radiação solar está diretamente ligada aos fenômenos meteorológicos e aos componentes atmosféricos no planeta. Nos últimos anos as redes meteorológicas brasileiras têm introduzido numerosas estações automáticas que permitem monitorar a irradiação solar global em escalas horárias. Historicamente a medição de dados climáticos em larga escala dava suporte às atividades ligadas à aviação e agricultura. Seu uso em aplicações na área de arquitetura ou engenharia passou a receber atenção apenas nos últimos 40 anos. Com o desenvolvimento exponencial da tecnologia, a utilização de ferramentas baseadas em simulação computacional tem tomado espaço nas mais diversas áreas. A necessidade de se ter um bom modelo matemático que possa descrever adequadamente, um processo constitui-se sempre em um desafio, uma vez que o desempenho dos sistemas de controle baseados em modelos irá depender significativamente da precisão alcançada pelo modelo matemático. No projeto de sistemas de controle baseados em modelos preditivos, deve ser possível capturar o comportamento dinâmico do processo ou sistema em condições realísticas e, ainda, buscar encontrar o modelo o mais simples possível visando otimizar os recursos computacionais. No presente trabalho as variáveis de interesse foram as composições de radiação, dada sua importância tanto para agricultura quanto para geração de energia fotovoltaica e solar térmica. Para a simulação, os dados horários de todos os anos foram agrupados em um único arquivo. Deste modo, utilizou-se metade dos dados para criação dos modelos e metade para validação. Durante as simulações, a Radiação Global Horizontal foi definida como entrada e as demais como saída. Vale ressaltar que para cada variável foi realizada uma nova simulação. A utilização da modelagem linear (ARX e ARMAX) para predição de dados de radiação solar mostrou-se eficiente para as composições: Extraterrestre Normal (Erro Quadrático Médio = 2,51%), Infravermelha (Erro Quadrático Médio = 1,40%) e Extraterrestre Horizontal (Erro Quadrático Médio = 7,15%). Na

modelagem não-linear (redes neurais), a radiação foi utilizada como entrada e a temperatura como saída da rede. Em termos de intervalos, é mais simples criar pequenos intervalos para uma variável com menor ordem de grandeza, como é o caso da temperatura, uma vez que demanda um volume menor de dados de entrada e saída para classificação. As redes *multilayer perceptron* (MLP) foram aplicadas desempenhando a tarefa de classificação de padrões. Criaram-se duas camadas de rede *feed-forward*. A primeira camada utilizou a função de transferência tangente hiperbólica e, a segunda camada utilizou a função de transferência linear. A simulação que gerou menor grau de acerto, 74,48%, foi a que utilizou a radiação global horizontal como entrada e 3 neurônios na camada escondida. A que apresentou maior taxa de acerto, 90,32 %, foi a que utilizou radiação infravermelha horizontal como entrada e 2 neurônios na camada escondida. Por fim, pôde-se concluir que a modelagem linear mostrou-se mais eficiente que a não-linear na predição de dados de radiação solar abordados neste trabalho. Sua implementação é mais simples sob ponto de vista computacional e foi suficientemente eficiente para a geração de um banco de dados compatível com o que se desejava, apresentando erros aceitáveis e descrevendo o sistema de forma compatível com o real.

## ABSTRACT

SILVA, Vinicius Leonardo Gadioli da, M.Sc., Universidade Federal de Viçosa, December, 2016. **Prediction of Solar Radiation through linear (ARX and ARMAX) and nonlinear modeling (Neural Networks)**. Advisor: Delly Oliveira Filho. Co-advisors: Joyce Correna Carlo and Aristides Ribeiro.

The knowledge of solar radiation is of vital importance to characterize the climate of a region. Solar radiation is directly linked to weather phenomena and atmospheric components on the planet. In recent years Brazilian meteorological networks have introduced numerous automatic stations that allow monitoring of global solar irradiation at hourly scales. Historically large-scale climate data measurement supported aviation and agricultural activities. Its use in applications in the field of architecture or engineering received attention only in the last 40 years. With the exponential development of technology, the use of tools based on computer simulation has taken space in several areas. The need to have a good mathematical model that can adequately describe a process is always a challenge, since the performance of model-based control systems will depend significantly on the accuracy achieved by the mathematical model. In the design of control systems based on predictive model, it should be possible to capture the dynamic behavior of the process or system under realistic conditions and also to find the simplest possible model to optimize computational resources. In the present work the variables of interest were the compositions of radiation, given their importance for both agriculture and for photovoltaic and solar thermal generation. For the simulation, the hourly data of all the years were grouped into a single file. In this way, half of the data was used to create the models and half for validation. During the simulations, Horizontal Global Radiation was defined as input and the others as output. It should be noted that for each variable a new simulation was performed. The use of linear modeling (ARX and ARMAX) to predict solar radiation data was efficient for the compositions: Normal Extraterrestrial (Root-mean-square deviation = 2.51%), Infrared (Root-mean-square deviation = 1.40%) and Horizontal Extraterrestrial = 7.15%). In the nonlinear modeling (neural networks), the radiation was used as input and the temperature as output of the network. In terms of intervals, it is simpler to create small intervals for a variable with a smaller order of magnitude, as is the case of temperature, since it requires a smaller volume of input and output data for

classification. The multilayer perceptron (MLP) networks were applied performing the task of pattern classification. Two feed-forward network layers were created. The first layer used the hyperbolic tangent transfer function, and the second layer used the linear transfer function. The simulation that generated the lowest degree of accuracy, 74.48%, was the one that used horizontal global radiation as input and 3 neurons in the hidden layer. The one that presented the highest hit rate, 90.32%, and 2 neurons in the hidden layer was the one that used horizontal infrared radiation as input. Finally, it was concluded that the linear modeling was more efficient than the non-linear model in the prediction of solar radiation data. Its implementation is simpler from a computational point of view and was efficient enough to generate a database compatible with what was wanted, presenting acceptable errors and describing the system in a way compatible with the original.

## Capítulo 1 - Introdução geral

### 1.1 Considerações Iniciais

Segundo Barnaby e Crawley (2011), historicamente a medição de dados climáticos em larga escala dava suporte às atividades ligadas à aviação e agricultura. Seu uso em aplicações na área de arquitetura ou engenharia passou a receber atenção apenas nos últimos 40 anos, aproximadamente. Até a década de 1990, a maior parte dos dados climáticos era coletada manualmente, tornando-se automática somente após a mencionada década. No Brasil, a disponibilidade dos dados de estações automáticas é ainda mais recente, sendo que a maioria das estações automáticas começou as medições entre 2007 e 2008 (RORIZ, 2012).

A principal dificuldade em relação aos dados coletados é quanto à sua representatividade, pois os dados meteorológicos podem variar significativamente de ano para ano. Desta maneira, é preciso identificar quais dados são representativos para o clima local (CHAN et al., 2011; ROSSI et al., 2009). Segundo Rossi et al (2009), essa representatividade climática pode ser obtida por meio de métodos estatísticos, como as normais climatológicas, a identificação dos dias típicos de projeto, ou ainda por metodologias específicas, como o caso da confecção de arquivos meteorológicos (GUIMARAES et al., 2014).

Apesar dos métodos resultarem em dados meteorológicos representativos do local, a opção por um método ou outro tende a resultar em arquivos climáticos com dados distintos. Além disso, segundo Barnaby e Crawley (2011), parâmetros meteorológicos como temperatura e ventilação podem apresentar diferenças significativas a depender do local da medição (GUIMARAES et al., 2014).

A atmosfera, como sistema físico, pode ser descrita por um sistema de equações matemáticas que derivam da segunda lei de Newton e do desenvolvimento do cálculo diferencial (Século XVIII). Porém, o sistema de equações que determina o movimento da atmosfera é muito complexo, de modo que não pode ser resolvido de forma exata e analítica, exigindo assim algumas aproximações (INPE, 2016).

Com o desenvolvimento exponencial da tecnologia, a utilização de ferramentas baseadas em simulação computacional tem tomado espaço nas mais diversas áreas, desde processos industriais mais simples, até os mais complexos. O principal objetivo da simulação computacional é fornecer ao usuário resultados próximos das situações reais utilizando ferramentas baseadas em métodos numéricos que visam fornecer uma solução aproximada de um modelo realista, tendo como alvo a otimização de projetos e processos produtivos, a minimização de erros e a análise de resultados muito antes de iniciar-se a fase de prototipação do projeto (HENSEN; CARLO & LAMBERTS, 2011).

A estimação de dados meteorológicos por meio de modelos matemáticos computacionais, tem por objetivo gerar um conjunto de valores numéricos com as mesmas características estatísticas da série histórica dos dados coletados (EVANGELISTA et al., 2006; FRUTEIRA et al., 2011).

Os geradores de dados meteorológicos promovem uma interação de natureza probabilística do clima com componentes de outros sistemas (modelos matemáticos geradores dos dados), que fornecem metodologias para medir o risco de incerteza climática que está relacionada com gerenciamentos alternativos, tais como em empreendimentos, sistemas de geração de energia, agricultura de precisão, dentre outros (FRUTEIRA et al., 2011).

Portanto, conforme preconizam Zanetti et al. (2006) e Fruteira et al. (2011), é necessário que esses dados simulados passem por um processo de validação, a fim de se analisar a sua confiabilidade e a representação das condições climáticas reais do local de interesse. Isto significa ter a garantia que as propriedades estatísticas contidas nas séries históricas de cada variável meteorológica, foram preservadas.

## **1.2 Objetivo Geral**

O objetivo principal deste trabalho é realizar um estudo de dados climáticos por meio de modelagem linear (ARX, ARMAX) e não-linear (Redes Neurais).

### **1.3 Objetivos Específicos**

- i) Avaliar o estado da arte sobre banco de dados climáticos;
- ii) Realizar a modelagem linear ARX e ARMAX do banco de dados;
- iii) Realizar a modelagem não-linear do banco de dados por meio de redes neurais; e
- iv) Comparar os resultados entre o modelo linear e não linear.

### **1.4 Limitações**

A maior limitação deste trabalho foi a indisponibilidade de um grande volume de dados meteorológicos tratados. Por este motivo, toda a análise foi realizada para dados tratados referentes ao município de Viçosa, Minas Gerais.

Neste trabalho foram utilizados dados horários dos anos de 2006, 2008, 2009, 2011, 2012, 2013, 2014 e 2015 do município de Viçosa-MG. O ano de 2010 não foi utilizado, por não possuir dados referentes aos meses de Março, Junho e Julho. O ano de 2007 não foi utilizado por não possuir os dados de janeiro e fevereiro. O ano de 2005 não foi utilizado por possuir apenas dados referentes a dezembro, uma vez que foi o ano de instalação da estação que passou por testes de setembro a novembro.

### **1.5 Estrutura**

Esta dissertação está estruturada da seguinte forma:

O Capítulo 2 trata dos conceitos que norteiam os trabalhos que utilizam de bancos de dados meteorológicos e, mais especificamente, radiação solar como referência para tais trabalhos.

O Capítulo 3 trata da modelagem matemática linear de dados meteorológicos realizada por meio de modelos auto regressivos com entrada simples e múltiplas entradas de erro (ARX e ARMAX). O objetivo deste capítulo foi realizar a predição dos dados de radiação solar e calcular o erro quadrático médio e o coeficiente de aproximação linear entre os dados reais e os gerados por meio de simulação. Para tal, utilizou-se metade dos dados para criação dos modelos e metade para validação.

O Capítulo 4 trata da modelagem matemática não-linear de dados meteorológicos realizada por meio de Redes Neurais Artificiais. O objetivo deste capítulo foi dividir os dados em faixas para classificação. Neste capítulo, utilizou-se a radiação como entrada e a temperatura como saída do sistema, a fim de analisar o comportamento do sistema.

A conclusão geral traz uma análise comparativa entre os modelos linear e não-linear. A maior contribuição deste trabalho foi a implementação de um algoritmo capaz de gerar dados de radiação passíveis de utilização em softwares de simulação.

## 1.6 Referências

BARNABY, C S; CRAWLEY, D B. “Weather data for building performance simulation” In: HENSEN, J.; LAMBERTS, R. (Org.). Building Performance Simulation for Design and Operation. Abingdon: SponPress, 2011, cap.3, p.37-55.

CHAN, A. L. S. Developing a Modified Typical Meteorological Year Weather File For Hong Kong Taking Into Account the Urban Heat Island Effect. Building and Environment, v.46, p.2434-2441, 2011.

FRUTEIRA, R. S.; LEITE, M. L.; VIRGENS FILHO, J. S.; Desempenho do Modelo PGECLIMA\_R na Simulação de Séries Diárias Sintéticas de Radiação Solar Global para Diferentes Localidades do Estado do Paraná. Revista Brasileira de Climatologia. N. 9 – JUL/DEZ/2011.

GUIMARÃES, Ítalo Bruno Baleeiro; AMORIM, Alexandre Cypreste; CARLO, Joyce Correna. Comparação estatística e simulatória de arquivos climáticos TRY e TMY desenvolvidos para a cidade de Viçosa-MG. Viçosa, 2014.

HENSEN, J. L. M.; AND LAMBERTS, R.; “Building Performance Simulation for Design and Operation”. Published 2011 by Spon Press 2 Park Square, Milton Park, Abingdon, Oxon OX14 4RN.

RORIZ, M. Arquivos Climáticos de Municípios Brasileiros. 2012 <http://www.labee.ufsc.br/downloads/arquivos-climaticos>; Acesso:

24/08/2016.

ROSSI, F. A.; DUMKE, E.; KRUGER, E. L. “Atualização do arquivo climático de referência para Curitiba.” In: Anais do X Encontro Nacional e VI Encontro Latino-americano de Conforto no Ambiente Construído. Natal: ENCAC-ELAC, 2009. CDROM.

ZANETTI, S. S.; OLIVEIRA, V. P. S.; PRUSKI, F. F. Validação do modelo ClimaBR em relação ao número de dias chuvosos e à precipitação total diária. Engenharia Agrícola, Jaboticabal, v.26, n.1, p.96-102, 2006.

## Capítulo 2 - Estado da Arte: Dados Meteorológicos e Radiação Solar

### 2.1 Introdução

Os arquivos meteorológicos são um conjunto de dados com um intervalo curto de tempo, normalmente compostos por um ano típico representativo, expressos por meio de parâmetros como temperatura, umidade relativa do ar, radiação solar, velocidade e direção do vento, dentre outros (GUIMARAES et al., 2014). Eles fornecem as condições para a análise termo-energética e, eventualmente, luminosa, de edificações. Os métodos para criação de arquivos climáticos mais comuns identificados no Brasil são os formatos *Test Reference Year* (TRY) e o *Test Meteorological Year* (TMY), cujos tratamentos estatísticos selecionam anos, no primeiro caso, ou meses, no segundo, sem extremos de temperaturas horárias (CARLO & LAMBERTS, 2008).

O conhecimento da radiação solar é de vital importância para caracterizar o clima de uma região. A radiação solar está diretamente ligada aos fenômenos meteorológicos e aos componentes atmosféricos, tais como vapor d'água e gases, possuindo também influência sobre os principais processos biológicos e fisiológicos no planeta (FRUTEIRA et al., 2011). A radiação solar pode ser utilizada na produção de energia para diferentes fontes, tais como: energia elétrica, energia para máquinas bioconversoras e aquecedores (VIRGENS FILHO et al., 2009).

Modelos computacionais para simulação de dados meteorológicos estimam elementos meteorológicos, que têm como objetivo gerar um conjunto de valores numéricos com as mesmas características estatísticas da série histórica (EVANGELISTA et al., 2006; FRUTEIRA et al., 2011). As séries de dados meteorológicos geradas computacionalmente são úteis em estudos de mudanças climáticas sobre riscos para agricultura (SEMENOV & BARROW, 1997; DAVID, 2010), perda de água no solo (CECÍLIO et al., 2004), e também na área da ecologia, como Kittel et al. (1995), que aplicou um gerador de dados meteorológicos na construção de um banco de dados meteorológicos que possibilitou a análise da sensibilidade de um ecossistema às mudanças climáticas (FRUTEIRA et al., 2011).

Segundo Fruteira (2011), vários modelos para geração de séries de dados climáticos, que simulam dentre outros elementos meteorológicos a radiação

solar, foram desenvolvidos. Na literatura sobre o assunto destacam-se o WGEN (RICHARDSON & WRIGHT, 1984), o WEATHERMAN (PICKERING et al., 1994), o CLIGEN (NICKS et al., 1995) e o LARS-WG (SEMENOV & BARROW, 1997).

Porém, muitos desses simuladores não possuem bom desempenho para áreas mais abrangentes, como as regiões brasileiras, visto que seus parâmetros muitas vezes estão calibrados para algumas regiões específicas e suas características (FRUTEIRA et al., 2011). Assim, tornou-se necessário o desenvolvimento de geradores de dados meteorológicos que representassem melhor as condições climáticas brasileiras. No Brasil, foram desenvolvidos os modelos GEPAC (VIRGENS FILHO, 1997), SEDAC\_R (VIRGENS FILHO, 2001), CLIMABR (BAENA et al., 2005) e PGECLIMA\_R (VIRGENS FILHO et al., 2011).

## **2.2 Dados Meteorológicos e Estações Meteorológicas Automáticas**

Uma estação meteorológica automática (EMA) coleta, a cada minuto, as informações de elementos meteorológicos (temperatura, umidade, pressão atmosférica, precipitação, direção e velocidade do vento, radiação solar) representativas da área em que está localizada (INMET, 2011; MELLIT, 2010).

A cada hora estes dados são processados e disponibilizados para serem transmitidos, via satélite ou telefonia celular, para a sede do INMET, em Brasília. O conjunto dos dados recebidos é validado por meio de um controle de qualidade e armazenado em um banco de dados (INMET, 2011).

Além disto, os dados são disponibilizados gratuitamente, em tempo real, na internet ([http://www.inmet.gov.br/sonabra/maps/pg\\_automaticas.php](http://www.inmet.gov.br/sonabra/maps/pg_automaticas.php)) para a elaboração de previsão do tempo e dos produtos meteorológicos diversos de interesse de usuários setoriais e do público em geral e para uma vasta gama de aplicações em pesquisa em meteorologia, hidrologia e oceanografia (INMET, 2011).

A estação meteorológica automática (EMA) é um instrumento de coleta automática de informações ambientais locais (meteorológicas, hidrológicas ou oceânicas), inclui os elementos:

- i. Sub-sistema de coleta de dados;

- ii. Sub-sistema de controle e armazenamento;
- iii. Sub-sistema de energia (por exemplo: painel solar e bateria); e
- iv. Sub-sistema de comunicação.

Segundo INMET (2011), a coleta de dados é feita por meio de sensores para medição dos parâmetros meteorológicos a serem observados (Figuras 2.1 e 2.2). As medidas tomadas, em intervalos de minuto em minuto, e processadas para no período de uma hora, para serem transmitidas, são:

- Temperatura instantânea do ar [°C];
- Temperatura máxima do ar [°C];
- Temperatura mínima do ar [°C];
- Umidade relativa instantânea do ar [%];
- Umidade relativa máxima do ar [%];
- Umidade relativa mínima do ar [%];
- Temperatura instantânea do ponto de orvalho [°C];
- Temperatura máxima do ponto de orvalho [°C];
- Temperatura mínima do ponto de orvalho [°C];
- Pressão atmosférica instantânea do ar [Pa];
- Pressão atmosférica máxima do ar [Pa];
- Pressão atmosférica mínima do ar [Pa];
- Velocidade instantânea do vento [m/s];
- Direção do vento [°];
- Intensidade máxima da rajada do vento [m/s];
- Radiação solar [W/m<sup>2</sup>]; e
- Precipitação acumulada no período [mm].



Figura 2.1 - Uma típica estação meteorológica automática – EMA com sensores, mastro com caixa datalogger, painel solar, para-raios, cercada. Fonte: INMET, 2011.



Figura 2.2 - Detalhe de uma estação meteorológica automática, mostrando a esquerda o pluviômetro, ao centro a antena de comunicação via satélite e à direita o "datalogger" com sensor de temperatura fixados ao mastro. Fonte: INMET, 2011.

## 2.3 Arquivos Climáticos

Os arquivos climáticos são um conjunto de dados meteorológicos com um intervalo curto de tempo, normalmente compostos por um ano típico representativo, expressos por meio de parâmetros como temperatura, umidade relativa do ar, radiação solar, velocidade e direção do vento, dentre outros (GUIMARAES et al., 2014). Eles fornecem as condições para a análise termo-energética e, eventualmente, luminosa, de edificações. Os métodos para criação de arquivos climáticos mais comuns identificados no Brasil são os formatos *Test Reference Year* (TRY) e o *Test Meteorological Year* (TMY), cujos tratamentos estatísticos selecionam anos, no primeiro caso, ou meses, no segundo, sem extremos de temperaturas horárias (CARLO & LAMBERTS, 2008). Enquanto isso, nos EUA, o *Test Meteorological Year 3* (TMY3) já está presente entre os arquivos disponíveis. Além de dados médios de temperatura do ar, sua criação requer tanto dados extremos quanto outros parâmetros climáticos, tais como: temperatura de ponto de orvalho, radiação global horizontal, radiação direta normal, velocidade e direção dos ventos (WILCOX & MARION, 2008). A seleção estatística é realizada pela determinação de pesos a tais parâmetros, de acordo com sua influência no desempenho da edificação (GUIMARÃES & CARLO, 2015).

Um arquivo climático TRY é formado por meio de uma metodologia baseada na eliminação de anos cujos dados contenham temperaturas médias mensais extremas (altas e baixas) até que se obtenha apenas um ano de dados médios. Um arquivo climático TMY é uma composição de meses sem extremos de temperatura proveniente de diferentes anos, gerando um ano típico que nunca existiu (CARLO & LAMBERTS, 2008).

Apesar dos métodos resultarem em dados climáticos representativos do local, a opção por um método ou outro tende a resultar em arquivos climáticos com dados distintos. Além disso, segundo Barnaby e Crawley (2011), parâmetros climáticos como temperatura e ventilação podem apresentar diferenças significativas a depender do local da medição (GUIMARAES et al., 2014).

As ferramentas de simulação computacional permitem a realização de

análises paramétricas que podem apontar indicadores que podem ser ajustados na busca do aprimoramento dos resultados das análises. Deste modo, são confeccionados arquivos climáticos que serão inseridos no programa computacional (GUIMARÃES & CARLO, 2015).

As primeiras incertezas acontecem durante a coleta dos dados, pois segundo Barnaby e Crawley (2011), dados climáticos usados para análises de edificações deveriam ser coletados preferencialmente no local da edificação, uma vez que as diferentes conformações urbanas e de relevo criam variações no microclima. Assim, várias pesquisas têm sido desenvolvidas a fim de se estudar o impacto de conformações urbanas em variações nos dados climáticos, resultando em diferentes microclimas dentro de uma mesma cidade, e o efeito dessa incerteza em simulações, tais como: Crawley (2007), Chan (2011) e Williamson et al (2009). Barnaby e Crawley (2011) complementa que historicamente a medição de dados climáticos em larga escala apoiam variadas atividades ligadas à aviação e agricultura (GUIMARÃES & CARLO, 2015).

Até os anos de 1990 a maioria das coletas de dados climáticos era feita manualmente, tornando-se automática apenas posteriormente (BARNABY & CRAWLEY, 2011). No Brasil, a disponibilidade dos dados de estações automáticas é ainda mais recente, uma vez que a maioria das estações automáticas começaram a realizar medições entre de 2007 e 2008 (RORIZ, 2012). Além disso, segundo Guimarães e Carlo (2015), o intervalo de tempo da coleta dos dados deveria também ser sempre consistente com as análises a serem realizadas, pois o estudo de diferentes fenômenos físicos demanda escalas de tempo distintas.

## **2.4 Radiações Solar Global (G), Ultravioleta (UV), Visível (PAR) e Infravermelha (IV).**

A radiação solar é fator de importância fundamental para as atividades agrícolas, tanto do ponto de vista da evaporação quanto da geração de massa (CEBALLOS et al., 2010).

Em se tratando de evaporação, o balanço de radiação costuma ser a variável predominante e a radiação solar global é uma componente (usualmente, a que tem maior peso relativo) do balanço de radiação. No caso da geração de massa, a radiação no espectro visível é a variável de interesse. (CEBALLOS et

al., 2010; MENNE et al., 2012).

Na América do Sul, a radiação global tem sido objeto de inúmeros trabalhos de recopilação histórica de medidas de solarímetros e de aproximações mediante dados de heliógrafos (TIBA, 2002; GALLEGOS & RIGHINI 2007).

Há pouco tempo, era evidente a escassez de dados de radiação solar no Brasil. Nos últimos anos as redes meteorológicas brasileiras têm introduzido numerosas estações automáticas que incluem piranômetros e permitem monitorar a irradiação solar global em escalas horárias e difundem seus dados por meio da Internet dois exemplos são: rede do INMET (escala horária) e rede associada ao SCD (Satélite de Comunicação de Dados) do Brasil com escala de 3 em 3 horas (CEBALLOS et al., 2010; INPE, 2016).

A distribuição de radiação solar no território brasileiro pode ser descrita como uniformemente distribuída com uma pequena variabilidade ao longo do ano (CARLO & LAMBERTS, 2008).

As Figuras 2.3 e 2.4 mostram uma das análises extraídas do Atlas de Irradiação Solar do Brasil (1998). A Figura 2.3 trata-se do mapa de irradiação média anual do país. A Figura 2.4 trata-se da variabilidade mensal da irradiação anual. Analisando-se as duas figuras, pode-se notar que a região sul do Brasil é a que possui o menor valor de irradiação média anual e a maior variabilidade de irradiação ao longo do ano. Isto ocorre porque trata-se da região do país de maior latitude, o que traz como consequência estações do ano bem definidas, ou seja, invernos mais frios e nebulosos do que nas outras regiões do país.

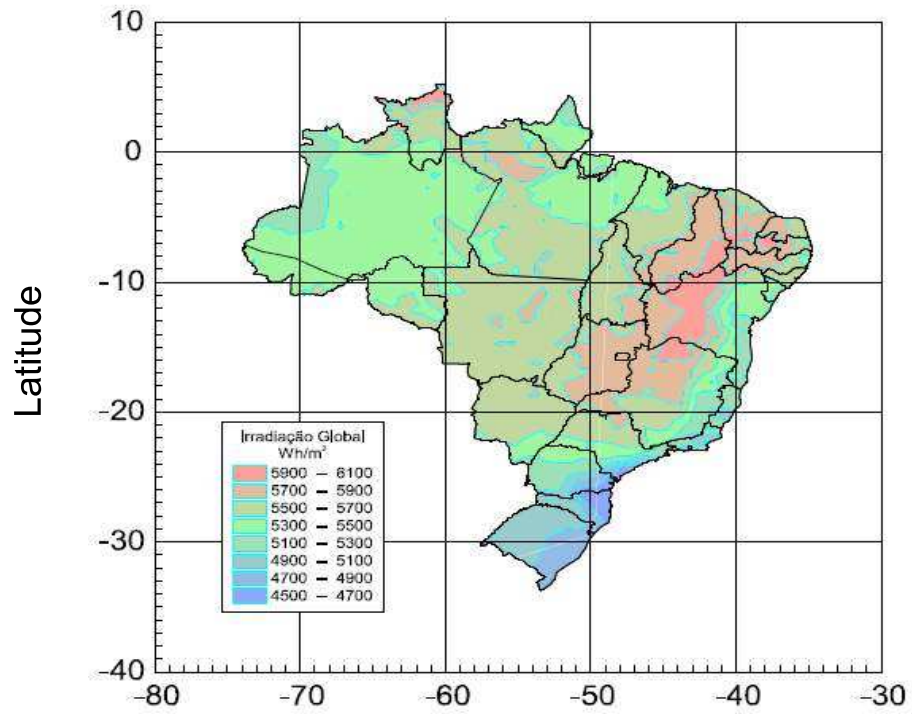


Figura 2.3 - Irradiação média anual. Fonte: BRASIL,1998.

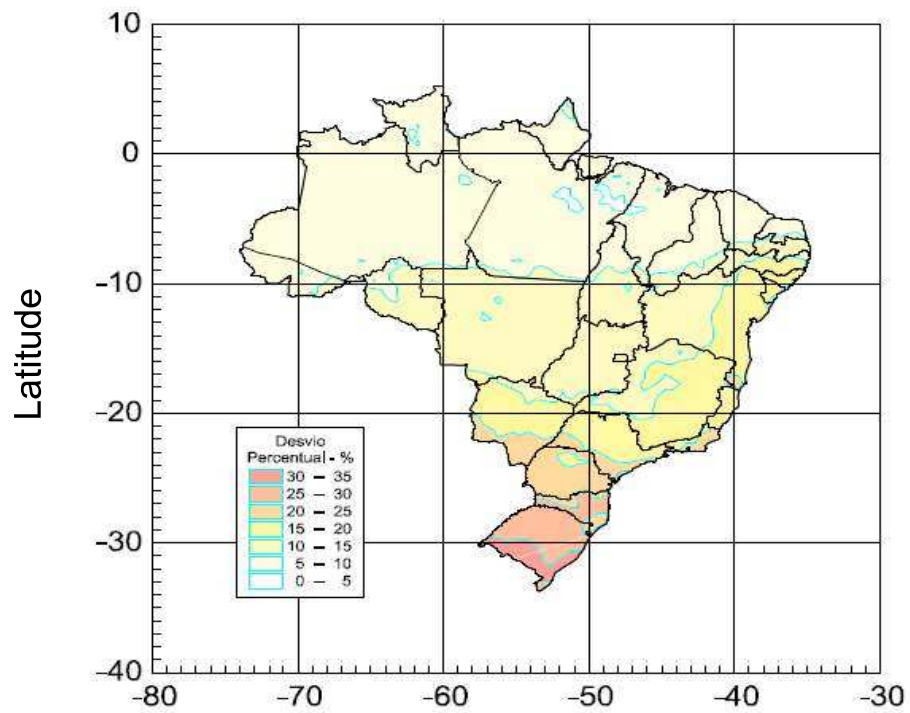


Figura 2.4 - Variabilidade mensal da irradiação anual. Fonte: BRASIL,1998.

Deste modo, torna-se evidente a necessidade de se conhecer o comportamento da distribuição da radiação solar. A distribuição da radiação solar global (G) é definida com base em intervalos de comprimento de onda do espectro da radiação e é composta pelas radiações: ultravioleta (UV), Visível (PAR) e a infravermelha (IV) (BALOGH et. al., 2011; MELLIT et al., 2010).

O espectro de emissão da radiação solar apresenta grandes variações decorrentes da absorção de componentes atômicos, tais como: hidrogênio, magnésio, alumínio, presentes na atmosfera do Sol (NASA, 2004). Esses espectros de absorção são denominados Linhas de *Fraunhofer*, em homenagem ao seu descobridor *Joseph Fraunhofer* (1887-1826). Estes espectros permitem analisar a composição química do Sol à distância (CORRÊA, 2016).

A emissão ou absorção de um fóton por um átomo ocorre quando um elétron muda de órbita. A emissão ocorre se o nível de energia da órbita de chegada é menor que o do nível de partida (OLIVEIRA & GOMES, 2006). Quando o equilíbrio termodinâmico é atingido, ou seja quando o fluxo de energia emitido é igual ao absorvido, o elemento passa a atuar como um corpo negro. No caso da fotosfera, a temperatura decresce com a altitude e, portanto, um fóton que escapa atravessa um meio mais frio. Desse modo, ele será absorvido por átomos em temperatura inferior e, por consequência, com taxas de emissão inferiores. Há, portanto, um déficit que pode ser traduzido em absorção de energia (DIAS et al., 2007).

Pode-se dizer que o Sol emite energia em múltiplos comprimentos de onda do espectro eletromagnético permeados pelas diversas linhas de absorção (SILVA, 2006). Cerca de 44% de toda essa energia emitida concentra-se na faixa entre 400 e 700 nm, denominada espectro visível de energia. O restante é dividido entre radiação ultravioleta (< 400nm) com 7%, infravermelho próximo (entre 700 e 1500nm) com 37% e infravermelho (> 1500nm) com 11%. Menos de 1% da radiação emitida concentra-se acima da região do infravermelho (micro-ondas e ondas de rádio), e abaixo da região ultravioleta (raios X e raios  $\gamma$ ) (CORRÊA, 2016). Na Figura 2.5 pode-se observar A relação da frequência com o comprimento de onda eletromagnética.




Figura 2.5 - A relação da frequência com o comprimento de onda eletromagnética. Fonte: MADEIRA, 2010.

Segundo *Foyo-Moreno et al.*(1999), o percentual de radiação UV na faixa total do espectro solar no topo é de 5,7%. Segundo *Alados-Arboledas et al.* (2000), o percentual de radiação PAR é de 38,8%. A radiação IV pode ser avaliada por meio do método da diferença:  $IV = G - (UV + PAR)$ , em que G no espectro total das ondas curtas representa 100%.

O valor da radiação UV na superfície da Terra depende do ângulo zenital solar, ozônio atmosférico e transparência da atmosfera (KYLING et al., 2000; KIRCHHOFF et al., 2002; LUCCINI et al., 2003). Os comprimentos de ondas da UV são divididos em três categorias: UVA (400 - 320 nm), UVB (320 – 290 nm) e UVC (290- 100 nm). A camada de ozônio absorve 100% da radiação UVC, 90% da radiação UVB e praticamente não absorve a radiação UVA (BALOGH et al., 2011).

A segunda faixa existente dentro do espectro solar é a radiação fotossinteticamente ativa (PAR - *Photosynthetically Available Radiation*). Seu espectro compreende a faixa do visível entre 0,358 e 0,700 μm. Este tipo de radiação exerce grande influência no desenvolvimento e crescimento das plantas pelo processo da fotossíntese (MCCREE, 1972; FOYO-MORENO et al., 1999). Esta faixa de radiação do espectro solar é absorvida pelas plantas, permitindo assim a realização do processo natural da fotossíntese, tendo grande importância para pesquisas em áreas como fisiologia vegetal (SILVA, 2006),

produtividade de culturas (GALVANI et al., 2000), dentre outras.

Segundo Oliveira & Gomes (2006), a obtenção da radiação PAR pode ocorrer de modo indireto ou direto. O método indireto é realizado por meio da diferença entre duas medidas de irradiância correspondentes. O método direto é obtido por meio de sensor quântico que mede somente a faixa correspondente da radiação PAR no espectro solar ((OLIVEIRA & GOMES, 2006).

A terceira faixa consiste na radiação infravermelho (IV) de ondas curtas. Tratam-se de ondas com comprimento de 0,7 a 4,0  $\mu\text{m}$ . Essa radiação não é em grande parte absorvida pelas plantas, pois sua importância está associada ao aquecimento do vapor d'água (HEMMING et al., 2006).

Segundo Escobedo (2009), a correlação entre as radiações UV e G é altamente dependente das condições do clima por meio das variações da cobertura de nuvens, vapor d'água e aerossóis na atmosfera do local. A radiação UV total consiste em uma fração aproximada entre 2,0 e 9,5% da radiação solar global G. A maior parte da radiação UV da radiação solar global G é devido a presença de ar seco com aerossóis na atmosfera sem nuvens, enquanto os menores valores ocorrem na atmosfera nebulosa e úmida (ESCOBEDO et al., 2009).

A correlação entre as radiações PAR e G também depende das condições do clima local. Além disso, a fração PAR representa um percentual entre 40,8 e 63,1% da radiação solar global G. Os maiores valores da fração PAR/G são obtidos em atmosfera clara, seca com presença de aerossóis, enquanto os menores valores, em atmosfera nebulosa e úmida (ESCOBEDO et al., 2009).

A radiação IV depende das condições de cobertura de céu, principalmente da presença de vapor d'água na atmosfera, e constitui uma fração média da radiação global G que vai de 44% (céu nublado) a 51,5% em condições de céu aberto. Para valores médios sobre todas as coberturas de céu, a fração IV constitui o percentual entre 46,9% a 51,0% da radiação global (ESCOBEDO et al., 2009).

## 2.5 Conclusão

O estudo de dados meteorológicos, mais especificamente da radiação solar, é de extrema importância nas mais diversas áreas, como aviação, meteorologia, geração de energia, agricultura, hidrologia, dentre outras. Tal área merece ser investigada e pesquisada das mais diversas formas possíveis, pois o volume de dados meteorológicos disponíveis desde o advento da instalação de estações meteorológicas automáticas ainda está aquém do que se espera para elevar o nível das pesquisas nesta área.

Mesmo que já haja uma definição matemática e física que explique de maneira satisfatória o comportamento da radiação solar, é necessário ainda o desenvolvimento e aplicação de métodos preditivos que venham a contribuir no aprimoramento de pesquisas que utilizem como insumo (ou alvo) os dados de radiação solar.

## 2.6 Referências Bibliográficas

ALADOS-ARBOLEDAS, L.; OLMOA, F.J.; ALADOSB, I.; PÉREZ, M.; Parametric models to estimate photosynthetically active radiation in Spain. *Agricultural and Forest Meteorology*, Amsterdam, v. 101, p. 187-201, 2000.

BALOGH T.S.; VELASCO M. V. R.; PEDRIALI C. A.; KANEKO T. M.; BABY A.R. Proteção à radiação ultravioleta: recursos disponíveis na atualidade em fotoproteção. *An Bras Dermatol*. 2011;86(4):732-42

BARNABY, C S; CRAWLEY, D B. "Weather data for building performance simulation" In: HENSEN, J.; LAMBERTS, R. (Org.). *Building Performance Simulation for Design and Operation*. Abingdon: SponPress, 2011, cap.3, p.37-55.

BRASIL. Agência Nacional de Energia Elétrica – ANEEL. *ATLAS de Irradiação Solar no Brasil*. 1998

- CARLO, J., LAMBERTS, R. Development of envelope efficiency labels for commercial buildings: Effect of different variables on electricity consumption. *Energy and Buildings*, n.40, p. 2002–2008, 2008.
- CEBALLOS, J. C., RODRIGUES, M. L., MACEDO, L. O.; Desempenho do modelo GL versão 1.2, época: outubro 2010 – dezembro 2010. Relatório Técnico 01/11-RST-DSA. Acessível na página internet da DSA: <http://satelite.cptec.inpe.br/radiacao/#/documentos.jsp>
- CECÍLIO, R. A.; RODRIGUES, R. D. G.; BAENA. L. G. N.; OLIVEIRA, F. G. Analysis of the RUSLE and WEPP models for a small watershed located in Viçosa, Minas Gerais State, Brazil. ISCO - INTERNATIONAL SOIL CONSERVATION ORGANIZATION CONFERENCE, 13., 2004, Brisbane, Austrália. *Proceedings... Brisbane, 2004.* n. 658.
- CHAN, A. L. S. Developing a Modified Typical Meteorological Year Weather File For Hong Kong Taking Into Account the Urban Heat Island Effect. *Building and Environment*, v.46, p.2434-2441, 2011a.
- CORRÊA, M. P. Notas de Aula: Fundamentos de Meteorologia. Universidade Federal de Itajubá. Itajubá-MG. 2016.
- CRAWLEY, D B. Creating weather files for climate change and urbanization impacts analysis. *Building Simulation*, p. 1075-1082, 2007.
- DAVID, M.; ADELARD, L.; LAURET, P.; GARDE, F.; A method to generate Typical Meteorological Years from raw hourly climatic databases. *Building and Environment* 45 (2010) 1722–1732.
- DIAS, A. A. C.; ANDRADE-NETO, A. V. E MILTÃO, M. S. R.; A Atmosfera terrestre: composição e estrutura. *Caderno de Física da UEFS* 05 (01 e 02): 21-40, 2007.
- ESCOBEDO, J. F. et al. Modeling hourly and daily fractions of UV, PAR and NIR to global solar radiation under various sky conditions at Botucatu, Brazil. *Applied Energy*, Oxford, v. 86, n. 3, p. 299-309, 2009.
- EVANGELISTA, A. W. P.; FERREIRA, P. A., PRUSKI; F. F. SEDIYAMA, G. C. Avaliação do desempenho do modelo CLIGEN em gerar dados climáticos

para modelos hidrológicos e agrônômicos. Revista Brasileira de Engenharia Agrícola e Ambiental, Campina Grande, v. 10, n. 1, p.119–127, 2006.

FOYO-MORENO, I.; VIDA, J.; ALADOS-ARBOLEDAS, L.; A simple all weather model to estimate ultraviolet solar radiation (290-385 nm). Journal of Applied Meteorology, Lawrence, v. 38, p. 1021-1026, 1999.

FRUTEIRA, R. S.; LEITE, M. L.; VIRGENS FILHO, J. S.; Desempenho do modelo PGECLIMA\_R na simulação de séries diárias sintéticas de radiação solar global para diferentes localidades do estado do paraná. Revista Brasileira de Climatologia. N. 9 – JUL/DEZ/2011.

GALLEGOS, H. G., RIGHINI, R.; Atlas de Energía Solar de la RepúblicaArgentina. SECYT & Universidad Nacional de Luján, Argentina. 2007.

Galvani, E.; Escobedo, J. F.; Cunha, A. R.; Klosowski, E. S.; Estimativa do índice de área foliar e da produtividade de pepino em meio protegido-cultivos de inverno e de verão. Revista brasileira de engenharia agrícola e ambiental. V. 4. Pp. 8-14. 2000.

GUIMARÃES, I. B. B.; CARLO, J. C.; Comparação estatística entre arquivos climáticos desenvolvidos com método diferentes. Proceedings of EURO ELECS 2015 - Connecting People and Ideas. Portugal, 2015.

GUIMARÃES, Ítalo Bruno Baleeiro; AMORIM, Alexandre Cypreste; CARLO, Joyce Correna. Comparação estatística e simulatória de arquivos climáticos TRY e TMY desenvolvidos para a cidade de Viçosa-MG. Viçosa, 2014.

HEMMING, S. ET AL. Greenhouse cooling by NIR-reflection. Acta Horticulturae, Leuven, v. 719, p. 97-106, 2006.

INMET – Instituto Nacional de Meteorologia, Monitoramento de Estações Automáticas. Nota Técnica Nº 001/2011/SEGER/LAIME/CSC/INMET. Disponível em:  
<[http://www.inmet.gov.br/portal/css/content/topo\\_iframe/pdf/Nota\\_Tecnica-Rede\\_estacoes\\_INMET.pdf](http://www.inmet.gov.br/portal/css/content/topo_iframe/pdf/Nota_Tecnica-Rede_estacoes_INMET.pdf) > Acesso: 25/09/2016.

INPE – Instituto Nacional de Pesquisas Espaciais, CPTEC - Centro de Previsão de Tempo e Estudos Climáticos. <<http://www.cptec.inpe.br/glossario.shtml#3>> Acesso: 30/08/2016.

JIANG, YINGNI. Generation of typical meteorological year for different climates of China. *Energy* 35 (2010) 1946–1953.

KIRCHHOFF, V. W.; SILVA, A.; PINHEIRO, K. Wavelength dependence of aerosol optical thickness in the UV-B band. *Geophysical Research Letters*, Washington, DC, v. 29 n. 12, p. 1620, 2002.

KITTEL, T. G. F.; ROSENBLOOM, N. A.; PAINTER, T. H.; SCHIMEL, D. S. The VEMAP integrated database for modeling United States ecosystem/vegetation sensitivity to climate change. *Journal of Biogeography*, Oxford, v.2, p.857- 862, 1995.

KYLLING, A.; DAHLBACK, A.; MAYER, B. The effect of clouds and surface albedo on UV irradiances at a high latitude site. *Geophysical Research Letters*, Washington, DC, v. 27, p. 1411-1414, 2000.

LUCCINI, E.; CEDE, A.; PIACENTINI, R. D. Effect of clouds on UV and total irradiance at Paradise Bay, Antarctic Peninsula, from a summer 2000 campaign. *Theoretical Applied Climatology*, Vienna, 75, p. 105-116, 2003.

LUDLAM, F. H. *Clouds and storms*. Pennsylvania: Pennsylvania State University Press, 1980. 405 p.

MCCREE, K. J.; The action spectrum, absorptance and quantum yield of photosynthesis in crop plants. *Agricultural and Forest Meteorology*. 9: 191–216. 1972.

MELLIT, A., PAVAN, A. M.; A 24-h forecast of solar irradiance using artificial neural network: Application for performance prediction of a grid-connected PV plant at Trieste, Italy. *Solar Energy* 84 (2010) 807–821.

MELLIT, A.; ELEUCH, H.; BENGHANEM, M.; ELAOUN, C.; PAVAN, A. M.; An adaptive model for predicting of global, direct and diffuse hourly solar irradiance. *Energy Conversion and Management* 51 (2010) 771–782.

- MENNE, M. J.; DURRE, I.; VOSE, R. S.; GLEASON, B. E.; HOUSTON, T. G.; An overview of the global historical climatology network-daily database. Journal of Atmospheric and Oceanic Technology. National Climatic Data Center, Asheville, North Carolina. 2012.
- NASA GODDARD SPACE FLIGHT CENTER. Sun Fact Sheet. Greenbelt, Maryland (2004). Consultado em 06-05-2016.
- NICKS, A. D.; LANE, L. J.; GANDER, G. A. Weather Generator. In: Flanagan, D. C.; Nearing, M. A. USDA-Water erosion prediction project (WEPP). West Lafayette: USDA/ARS, 1995. cap. 2, p.1-22.
- OLIVEIRA, O. A.; GOMES, J. D. Arquitetura atômica e molecular. EDUFRN – Editora da UFRN. Fernandes – Natal (RN). 2006.
- PICKERING, N.B., HANSEN, J.W., JONES, J.W., WELLS, C.M., CHAN, V.K., GODWIN, D.C. WeatherMan: A utility for managing and generating daily weather data. Agronomy Journal, v.86, p.332-7, 1994.
- RICHARDSON, C.W., WRIGHT, D.A. WGEN: A model for generating daily weather variables. USDA-ARS ARS-8, 1984, 80p. SEMENOV, M. A.; BARROW, E. M. Use of a stochastic weather generator in the development of climate change scenarios. Climatic Change, v.35, p.397–414, 1997.
- RORIZ, M. Arquivos Climáticos de Municípios Brasileiros. 2012 <http://www.labee.ufsc.br/downloads/arquivos-climaticos>; Acesso: 24/08/2016.
- SEMENOV, M. A.; BARROW, E. M. Use of a stochastic weather generator in the development of climate change scenarios. Climatic Change, v.35, p.397–414, 1997.
- SILVA, A. V. R. Nossa Estrela O Sol. Editora Livraria da Física. 166p. São Paulo – SP. 2006.
- TIBA, C.; Freidenreich, N., 2002. Atlas solarimétrico do Brasil, Editora Universitária da UFPE, Recife, 111 pp.
- VIRGENS FILHO, J. S. Modelo computacional para simulação de dados

climáticos. 1997. 86 p. Dissertação (Mestrado em Agronomia/Energia na Agricultura) – Faculdade de Ciências Agrônomicas, Universidade Estadual Paulista, Botucatu, 1997.

VIRGENS FILHO, J. S.; LEITE, M. L.; FRANCO, J. R.; KORELO, M. Modelo computacional estocástico para simulação de séries climáticas diárias de umidade relativa do ar, baseado na parametrização dinâmica das distribuições de probabilidade decorrente da retroalimentação de dados. *Revista Brasileira de Climatologia*, v.5, p.133-151, 2009.

VIRGENS FILHO, J. S.; OLIVEIRA, P. M.; LEITE, M. L.; TSUKAHARA, R. Y. PGECLIMA\_R: Gerador estocástico para simulação de cenários climáticos brasileiros. II – Automação da análise estatística e validação dos dados simulados. In: XVII Congresso Brasileiro de Agrometeorologia. Guarapari, Anais. Guarapari, Sociedade Brasileira de Agrometeorologia, p.1-5, 2011.

VIRGENS FILHO, J.S. Ferramenta computacional para simulação de séries climáticas diárias, baseada na parametrização dinâmica das distribuições de probabilidade. 2001. 92f. Tese (Doutorado em Energia na Agricultura) - Faculdade de Ciências Agrônomicas, Universidade Estadual Paulista, Botucatu, 2001.

VOGELMANN, A. M. et al. Observational constraints on non-Lorentzian continuum effects in the near-infrared solar spectrum using ARM ARESE data. *Journal of Quantitative Spectroscopy and Radiative Transfer*, New York, v. 60, n. 2, p. 231-246, 1998.

WILCOX, S; MARION, W. User's Manual for TMY3 Data Sets. National Renewable Energy Laboratory, 2008.

WILLIAMSON, T; ERELL, J E; SOEBARTO, V. Assessing the error from failure to account for urban microclimate in computer simulation of building energy performance. In: *Building Simulation 2011, Proceedings...* Glasgow, Scotland: IBPSA, 2011, p. 497-504.

YANG, L.; LAM, J. C.; LIU, J.; TSANG, C. L.; Building energy simulation using multi-years and typical meteorological years in different climates. *Energy Conversion and Management* 49 (2008) 113–124.

ZANETTI, S. S.; OLIVEIRA, V. P. S.; PRUSKI, F. F. Validação do modelo Clima BR em relação ao número de dias chuvosos e à precipitação total diária. Engenharia Agrícola, Jaboticabal, v.26, n.1, p.96-102, 2006.

## Capítulo 3 - Modelagem e Identificação de Sistemas ARX e ARMAX

### 3.1 Introdução

Estratégias de controle baseadas em modelos preditivos, são uma classe de algoritmo computacional que se baseia no comportamento dinâmico de um processo que pode ser explicitado por meio de um modelo matemático (RICHALET, 1993; MARTIN SANCHEZ, 1996; CAMACHO & BORDON, 1999; FROISY, 2006). A necessidade de se ter um bom modelo matemático que pode descrever adequadamente um processo, constitui-se sempre em um desafio, uma vez que o desempenho dos sistemas de controle baseados em modelos matemáticos irão depender significativamente da precisão alcançada pelo modelo matemático (MARTIN SANCHEZ & RODELLAR, 2005; VASQUEZ et. al., 2008).

O desenvolvimento de um modelo matemático eficiente não é trivial, principalmente porque os critérios que o tornam aplicável não dependem somente da sua finalidade e aplicação (RAMAMURTHI et al., 1993). No projeto de sistemas de controle baseados em modelos preditivos, deve ser possível capturar o comportamento dinâmico do processo ou sistema em condições realísticas e, ainda, buscar encontrar o modelo mais simples possível visando otimizar os recursos computacionais (SUGANTHI & SAMUEL, 2012; SHAKOURI & RADMANESH, 2009).

Utilizando-se o teorema da representação, pode-se obter diversas maneiras de expressar os modelos matemáticos de um sistema. A seguir são apresentadas as representações matemáticas lineares utilizadas com mais frequência na identificação de sistemas (AGUIRRE, 2007).




Figura 3.1 - Sistema linear invariante no tempo. Fonte: AGUIRRE, 2007.

Seja o sistema linear invariante no tempo representado na Figura 3.1, em que a perturbação  $X$  pode ser descrita por um processo estocástico estacionário com densidade espectral racional. Portanto a transformada  $Z$  da saída do sistema é dada por:

$$Y(z) = G(z)U(z) + H(z)W(z) \quad (2.1)$$

em que  $G(z)$  é a função de transferência da parte determinística do sistema,  $H(z)$  é a função de transferência da parte estocástica do sistema e elas são funções racionais e estáveis.

Supondo que, no caso geral, as funções de transferência da parte determinística e estocástica podem ter alguns polos em comum, pode-se escrever a seguinte representação para a saída do sistema:

$$Y(z) = \frac{z^{-d}B(z)}{F(z)A(z)}U(z) + \frac{C(z)}{D(z)A(z)}W(z) \quad (2.2)$$

em que  $A(z), B(z), C(z), D(z), F(z)$  são polinômios em  $z$ , cujas raízes são os polos e zeros da parte determinística e estocástica do sistema e  $d$  é o atraso de transporte do sistema.

Aplicando-se a anti-transformada  $z$  e utilizando o operador deslocamento para trás ( $q^{-1}$ ), resulta em:

$$A(q^{-1})y(k) = q^{-d} \frac{B(q^{-1})}{F(q^{-1})} u(k) + \frac{C(q^{-1})}{D(q^{-1})} w(k) \quad (2.3)$$

em que  $q^{-1}$  é o operador atraso definido de forma que  $y(k)q^{-1} = y(k - 1)$ ,  $w(k)$  é o ruído branco e  $A(q^{-1})$ ,  $B(q^{-1})$ ,  $C(q^{-1})$ ,  $D(q^{-1})$ ,  $F(q^{-1})$  são polinômios definidos da seguinte forma:

$$A(q^{-1}) = 1 + a_1 q^{-1} + \dots + a_{n_a} q^{-n_a} \quad (2.4)$$

$$B(q^{-1}) = b_0 + b_1 q^{-1} + \dots + b_{n_b} q^{-n_b} \quad (2.5)$$

$$D(q^{-1}) = 1 + d_1 q^{-1} + \dots + d_{n_d} q^{-n_d} \quad (2.6)$$

$$C(q^{-1}) = 1 + c_1 q^{-1} + \dots + c_{n_c} q^{-n_c} \quad (2.7)$$

$$F(q^{-1}) = 1 + f_1 q^{-1} + \dots + d_{n_f} q^{-n_f} \quad (2.8)$$

De acordo com os valores particulares dos polinômios  $A(q^{-1})$ ,  $B(q^{-1})$ ,  $C(q^{-1})$ ,  $D(q^{-1})$ ,  $F(q^{-1})$ , obtém-se os diferentes modelos para identificação utilizados na literatura. Neste trabalho foram explorados os modelos Autorregressivo com Entradas Exógenas (ARX) e Autoregressivo com Média Móvel e Entradas Exógenas (ARMAX).

A identificação de sistemas e processos pode ser dividida nas seguintes etapas: aquisição de dados, processamento de dados, escolha da estrutura dos modelos, estimação dos parâmetros e validação do modelo. Estas etapas serão vistas com mais detalhes na seção metodologia deste capítulo.

### 3.2 Modelos ARX e ARMAX

Existem diversos modelos que podem representar um sistema de maneiras diferentes, dependendo da perspectiva a ser considerada. Alguns dos modelos utilizados, para modelar sistemas lineares são os modelos autoregressivos, como o modelo autoregressivo com entradas exógenas (ARX) e o modelo autoregressivo com média móvel e entradas exógenas (ARMAX), modelos de variáveis de estado e funções transferência (AGUIRRE, 2007; JORGENSEN, 2011).

O modelo mais simples que pode ser ajustado aos dados de uma amostra é um modelo autorregressivo com a inclusão de variáveis exógenas (ARX - AutoRegressive with eXogeneous inputs). Uma série temporal  $y(t)$  segue um modelo ARX quando puder ser explicada pela expressão da Equação 9 e pelo diagrama de blocos da Figura 3.2 (SHUMWAY & STOFFER, 2006; AGUIRRE, 2007; MOURA & MONTINI, 2012):

$$\begin{aligned}
 y(t) + a_1y(t-1) + a_2y(t-2) + \dots + a_{n_a}y(t-n_a) & \quad (2.9) \\
 = b_1u(t-1) + b_2u(t-2) + \dots + b_{n_b}u(t-n_b) & \\
 + e(t) &
 \end{aligned}$$

em que  $e(t)$  representa um ruído branco.

Aplicando o operador de *delay* unitário  $z^{-1}y(t) = y(t-1)$ , tem-se:

$$A(z) = 1 + a_1z^{-1} + a_2z^{-2} + \dots + a_{n_a}z^{-n_a} \quad (2.10)$$

$$B(z) = b_1z^{-1} + b_2z^{-2} + \dots + a_{n_b}z^{-n_b} \quad (11)$$

Deste modo, a relação *input-output* do modelo é dada por:

$$A(z)y(t) = B(z)u(t) + e(t) \quad (2.12)$$

$$y(t) = \frac{B(z)}{A(z)}u(t) + \frac{1}{A(z)}e(t) \quad (2.13)$$




Figura 3.2 - Diagrama de blocos – ARX.

O modelo ARX pode ser melhorado com a utilização de uma média móvel aplicada a perturbação. Desta maneira tem-se:

$$\begin{aligned}
 y(t) + a_1y(t-1) + a_2y(t-2) + \dots + a_{n_a}y(t-n_a) \\
 = b_1u(t-1) + b_2u(t-2) + \dots + b_{n_b}u(t-n_b) \quad (2.14) \\
 + e(t) + c_1e(t-1) + c_2e(t-2) + \dots \\
 + c_{n_c}e(t-n_c)
 \end{aligned}$$

Aplicando-se o *delay* unitário, como no caso anterior, tem-se:

$$A(z) = 1 + a_1z^{-1} + a_2z^{-2} + \dots + a_{n_a}z^{-n_a} \quad (2.15)$$

$$B(z) = b_1z^{-1} + b_2z^{-2} + \dots + a_{n_b}z^{-n_b} \quad (2.16)$$

$$C(z) = 1 + c_1z^{-1} + c_2z^{-2} + \dots + c_{n_c}z^{-n_c} \quad (2.17)$$

Deste modo, a relação *input-output* do modelo ARMAX (*autoregressive-moving-average model with exogenous inputs model*) é dada por:

$$A(z)y(t) = B(z)u(t) + e(t) \quad (2.18)$$

$$y(t) = \frac{B(z)}{A(z)}u(t) + \frac{C(z)}{A(z)}e(t) \quad (2.19)$$

Além disso,  $n_a$ ,  $n_b$  e  $n_c$  representam as ordens dos modelos. O diagrama de blocos que representa este modelo pode ser observado na Figura 3.3.

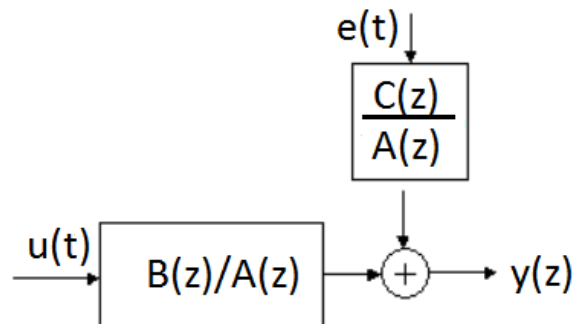


Figura 3.3 - Diagrama de blocos – ARMAX.

### 3.3 Metodologia

#### 3.3.1 Introdução

Identificação de sistemas pode ser compreendida como uma abordagem experimental para a obtenção de um modelo matemático que reproduz, para os fins desejados e, com exatidão suficiente, as características dinâmicas do processo em estudo com base nas variáveis observadas do processo, tais como: sinal de saída ou variável controlada  $y(t)$ , o sinal de entrada  $x(t)$ , e, em alguns casos, os distúrbios  $e(t)$  (LJUNG, 1999). A Figura 3.4 mostra um esboço geral do processo de identificação do sistema (VASQUEZ et. al., 2008).

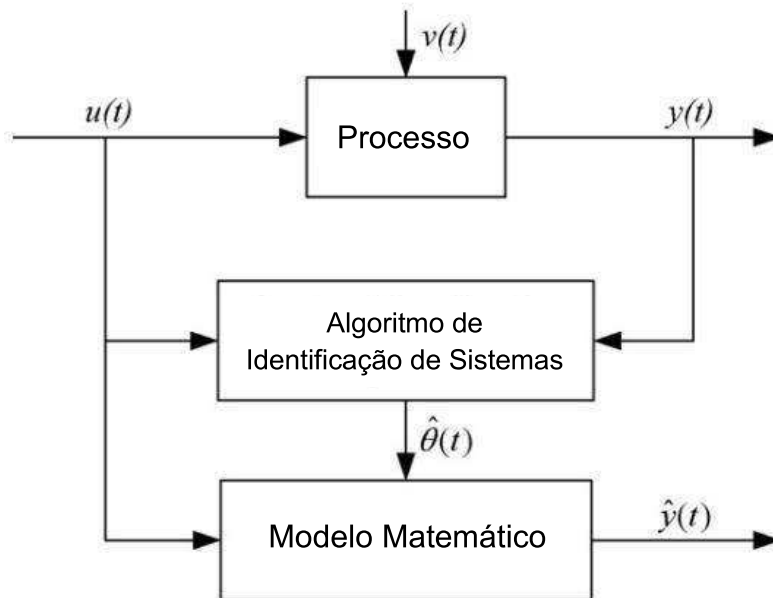


Figura 3.4 - Processo de identificação do sistema. Fonte: LJUNG, 1999.

Em geral, o processo de identificação de um sistema compreende as seguintes etapas:

1. Aquisição e modelagem dos dados: o sistema deve receber uma excitação externa por meio da aplicação de diferentes sinais de entrada, e registrar a evolução de seus sinais de entrada e de saída durante um intervalo de tempo fixo pré-determinado.

2. Pré-processamento dos dados adquiridos: os dados adquiridos geralmente acompanhados de ruídos indesejados e outros tipos de imperfeições, e por isto devem ser tratados antes de se iniciar a identificação do processo.
3. Definição do modelo a se utilizar: é desejável obter-se um modelo paramétrico condicionado à natureza dos dados que estão sendo utilizados durante o processo de modelagem. Desta maneira, o primeiro passo é o de determinar uma estrutura adequada para o modelo. Para isto, é necessário o conhecimento prévio do comportamento dinâmico do processo em questão.
4. Estimativa dos parâmetros do modelo: deve-se determinar os parâmetros da estrutura que melhor se adapte à resposta do modelo aos dados experimentais de entrada e saída.
5. Validação do modelo: trata-se da etapa final. Esta etapa visa determinar se o modelo obtido satisfaz a aplicação com a exatidão exigida para o processo. Se for concluído que o modelo obtido é inválido, os seguintes aspectos devem ser analisados como possíveis causas:
  - a. Os dados de entrada e saída adquiridos não fornecem informações suficientes sobre a dinâmica do sistema; e/ou
  - b. A estrutura escolhida não é capaz de descrever adequadamente o modelo; e/ou
  - c. Os critérios para determinação dos parâmetros não foram devidamente ajustados.

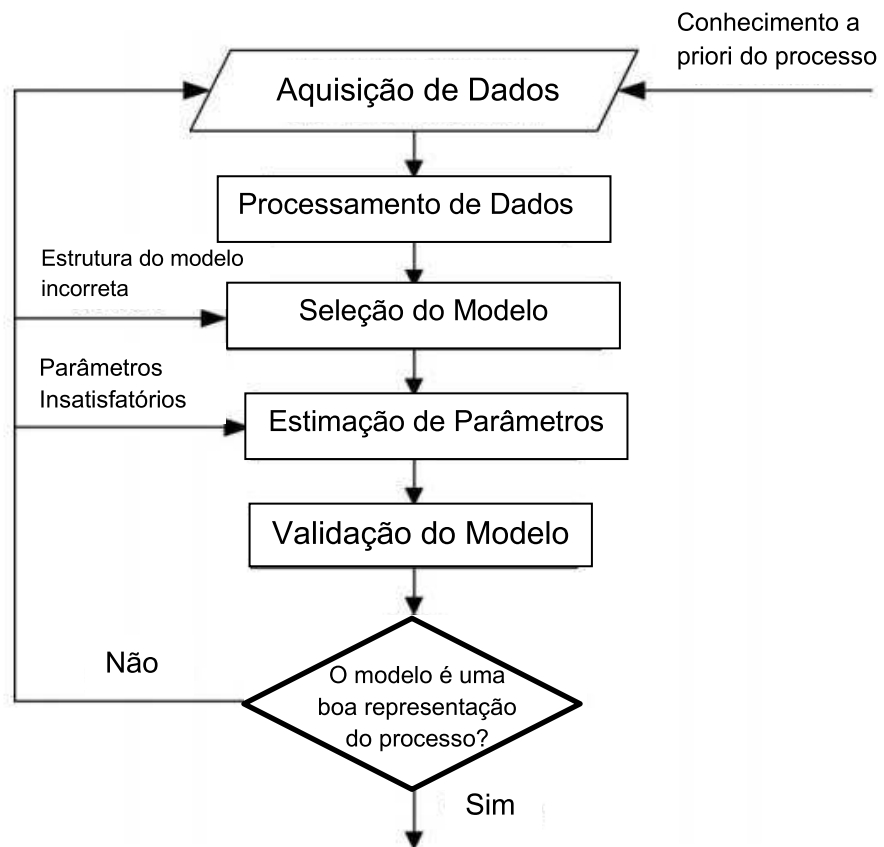


Figura 3.5 - Estágios do procedimento de identificação de sistemas. Fonte: LJUNG, 1999.

Assim, dependendo da razão pela qual foi obtido um modelo inválido, o processo de identificação deve ser repetido. O processo de identificação do sistema é um processo iterativo cujas etapas estão ilustradas no fluxograma da Figura 3.5.

### 3.3.2 Modelagem do Banco de Dados Meteorológicos Baseada em Identificação de Sistemas

Inicialmente, a média dos dados de entrada e saída foram removidos, a fim de se normalizar o banco de dados utilizado. Em seguida, os dados foram subdivididos, uma parte para simulação e outra para validação do modelo. O percentual utilizado tanto na simulação quanto na validação foi definido com base no tamanho do banco de dados disponível para o trabalho.

Os parâmetros dos modelos ARX e ARMAX foram simulados em diferentes valores de ordens e *delays*. Estes valores determinam o grau da equação diferencial ordinária que foi resolvida computacionalmente para a determinação dos coeficientes de cada modelo. Isto significa que, para cada

valor de  $n_a$ ,  $n_b$  e  $n_c$ , foi criado um novo modelo para simulação e validação. Neste trabalho a ordem dos modelos ( $n_a$ ,  $n_b$  e  $n_c$ ) variou de 1 a 7, enquanto a ordem do *delay* ( $n_K$ ) variou de 1 a 3. Tais valores justificam-se pela necessidade de se otimizar a utilização dos recursos computacionais, uma vez que há necessidade ampliá-los a medida em que se eleva a ordem dos modelos.

A escolha do modelo pode ser definida por meio da minimização do Erro Quadrático Médio (*Root Mean Square Error* - RMSE). Trata-se de um critério para selecionar um estimador adequado, o que significa escolher a ordem do modelo que será utilizado. O Erro Quadrático Médio é a soma das diferenças entre o valor estimado e o valor real dos dados, ponderados pelo número de termos.

$$RMSE(\%) = \sqrt{\frac{1}{N} \sum_{t=1}^N \left( \frac{y(t) - y_s(t)}{y(t)} \right)^2} \quad (20)$$

em que:

$N$  = tamanho do conjunto de dados;

$y(t)$  = valor original de cada dado; e

$y_s(t)$  = valor simulado.

Outro estimador abordado neste trabalho é o FIT (do inglês “*fitting*” que significa “encaixe”), que segundo MUSTAFARAJ *et al.* (2010) nada mais é do que a variação da saída gerada pelo modelo, ou seja, mede o quanto a saída se “encaixa” com os dados utilizados na validação do modelo. É calculado pela equação:

$$FIT = 1 - \frac{\sqrt{\sum_{t=1}^N [y(t) - y_s(t)]^2}}{\sqrt{\sum_{t=1}^N [y_s(t) - \frac{1}{N} \sum_{t=1}^N y(t)]^2}} \quad (2.21)$$

Em modelagem estatística, estes parâmetros são usados para determinar em que medida o modelo se ajustou ou não aos dados, ou se a remoção de

alguns termos poderia simplificar o modelo de forma benéfica. Ou seja, dentre outras coisas, ele pode ser utilizado para o auxílio na determinação das variáveis de interesse que possam ser utilizadas no trabalho. Ele fornece um mecanismo de escolha do melhor estimador. Neste caso a escolha dependerá do RMSE e do FIT nos modelos ARX e ARMAX e do grau de cada modelo.

### **3.4 Resultados e Discussão**

Inicialmente, para modelagem e processamento de dados, foi utilizado um banco de dados meteorológicos tratados, fornecido pelo Laboratório de Tecnologias em Conforto Ambiental e Eficiência Energética da Universidade Federal de Viçosa. A importância em se utilizar um banco de dados meteorológicos tratado reside no fato de que os dados brutos apresentaram uma série de incertezas a depender do contexto de medição e da abordagem de seleção e montagem dos mesmos. Dados brutos tendem a possuir discrepâncias, tais como erros de medição por ações externas à estação meteorológica, falhas de sensores na aquisição de dados e defeitos em equipamentos.

Foram utilizados dados horários de 2005 a 2015 contendo: Temperatura do ar ( $T_{BS}$ ), Temperatura de Ponto de Orvalho ( $T_{PO}$ ), Umidade Relativa do Ar ( $U_R$ ), Pressão Atmosférica ( $P_A$ ), Entalpia, Densidade do Ar, Radiação Global Horizontal, Radiação Infravermelha Horizontal, Radiação Extraterrestre Normal, Radiação Extraterrestre Horizontal, Radiação Direta Normal, Radiação Difusa Horizontal, Iluminância Global Horizontal, Iluminância Direta Normal, Iluminância Difusa Horizontal, Direção do Vento, Velocidade do Vento e Precipitação.

No presente trabalho as variáveis de interesse foram as composições de radiação, dada sua importância tanto para agricultura quanto para geração de energia fotovoltaica e solar térmica. No Quadro 1 tem-se uma amostra do banco de dados de um dia típico do mês de janeiro de 2015. Pode-se observar que existe uma gama de variáveis passíveis de análise.

Quadro 1 - Amostra de dados climáticos horários de um dia típico do mês de Janeiro de 2015. Fonte: GUIMARÃES E CARLO, 2014.

Hora	TBS(°C)	TPO(°C)	UR(%)	PA(Pa)	Razão de Umidade	Entalpia(KJ/Kg)	Densidade do Ar (Kg/m³)	Rad. Extrat. Hor. (Wh/m²)	Rad. Extrat. Normal (Wh/m²)
00:00	19,0	18,1	95	93540	0,01420	55,12846	1,09054	0	0
01:00	18,7	17,9	95	93500	0,01394	54,15039	1,09165	0	0
02:00	18,5	17,7	96	93470	0,01391	53,88151	1,09209	0	0
03:00	18,4	17,7	96	93510	0,01382	53,53769	1,09309	0	0
04:00	18,2	17,5	96	93550	0,01363	52,86977	1,09463	0	0
05:00	18,5	17,9	96	93600	0,01389	53,83143	1,09364	212	32
06:00	20,4	19,7	96	93620	0,01567	60,31987	1,08376	526	196
07:00	24,4	19,1	73	93660	0,01518	63,20998	1,07047	818	474
08:00	26,0	19,1	66	93650	0,01510	64,64891	1,06477	1067	807
09:00	27,4	19,4	62	93610	0,01542	66,90631	1,05883	1257	1119
10:00	28,6	18,9	56	93560	0,01493	66,90469	1,05486	1374	1337
11:00	30,3	19,9	54	93500	0,01591	71,17780	1,04666	1411	1409
12:00	31,1	19,2	49	93420	0,01511	69,94738	1,04433	1364	1318
13:00	32,2	19,4	47	93300	0,01545	71,96627	1,03867	1238	1085
14:00	32,2	17,6	42	93260	0,01378	67,67861	1,04096	1041	767
15:00	31,7	19,2	47	93240	0,01502	70,34427	1,04041	786	437
16:00	28,8	19,4	57	93300	0,01543	68,38545	1,05041	490	170
17:00	26,0	19,7	68	93300	0,01563	65,99719	1,05991	174	22
18:00	23,9	19,8	78	93380	0,01581	64,27902	1,06802	0	0
19:00	23,0	19,8	82	93450	0,01573	63,14031	1,07220	0	0
20:00	22,4	19,8	85	93480	0,01571	62,48673	1,07475	0	0
21:00	21,8	19,8	88	93510	0,01568	61,77539	1,07734	0	0
22:00	21,4	19,6	90	93490	0,01565	61,28840	1,07862	0	0
23:00	20,9	19,5	92	93450	0,01552	60,43446	1,08022	0	0
00:00	20,7	19,6	93	93390	0,01550	60,19280	1,08028	0	0

Quadro 2 - Continuação

Hora	Rad.Infrav. Hor. (Wh/m <sup>2</sup> )	Rad.Global Hor. (Wh/m <sup>2</sup> )	Rad. Direta Normal (Wh/m <sup>2</sup> )	Rad. Difusa Horária (Wh/m <sup>2</sup> )
00:00	368	0	0	0
01:00	366	0	0	0
02:00	365	0	0	0
03:00	364	0	0	0
04:00	363	0	0	0
05:00	365	16	0	16
06:00	377	57	0	57
07:00	397	460	129	238
08:00	406	687	332	248
09:00	414	860	541	252
10:00	420	984	719	246
11:00	430	1045	811	234
12:00	434	1031	785	219
13:00	441	960	672	194
14:00	438	828	490	164
15:00	437	492	166	193
16:00	421	256	36	153
17:00	406	22	0	22
18:00	395	0	0	0
19:00	390	0	0	0
20:00	387	0	0	0
21:00	384	0	0	0
22:00	382	0	0	0
23:00	379	0	0	0
00:00	378	0	0	0

Para a simulação, os dados horários de todos os anos foram agrupados em um único arquivo. Deste modo, utilizou-se metade dos dados para criação dos modelos e metade para validação. Durante as simulações, a Radiação Global Horizontal foi definida como entrada e as demais como saída. Vale ressaltar que para cada variável foi realizada uma nova simulação.

Quadro 3 - Entradas e saídas utilizadas na modelagem linear.

Entrada x(t)	Saída y(t)
Radiação Global Horizontal	Radiação Extraterrestre Normal
Radiação Global Horizontal	Radiação Infravermelha
Radiação Global Horizontal	Radiação Extraterrestre Horizontal
Radiação Global Horizontal	Radiação Direta Normal
Radiação Global Horizontal	Radiação Difusa Horizontal

Em cada simulação foi utilizada uma amostra de 64992 valores, dos quais 32496 foram utilizados para criação do modelo e 32496 para validação. Na validação, os dados gerados a partir dos modelos foram comparados com os dados existentes pela análise do RMSE e de um coeficiente de performance (FIT).

Na criação dos modelos ARX e ARMAX, a ordem dos modelos ( $n_a$ ,  $n_b$  e  $n_c$ ) variou de 1 a 7, enquanto a ordem do delay ( $n_k$ ) variou de 1 a 3. A partir disto, os modelos foram simulados e obtiveram-se os valores RMSE e FIT conforme os Quadros Quadro 4 a Quadro 14.

Cada modelo gera 32496 valores horários de radiação, porem foram apresentados gráficos com amostras de 100 horas, a fim de facilitar a comparação os dados originais com os dados gerados pelos modelos. Para se ter uma noção da dimensão dos dados, na Figura 3.6 pode-se observar um gráfico com todos os dados de 1000 horas.




Figura 3.6 - Modelo ARX ( $n_a = 4$ ,  $n_b = 4$ ,  $n_c = 3$ ) para predição de dados de Radiação Extraterrestre Normal sem supressão do zero.

Quadro 4 - Valores RMSE e FIT para Radiação Extraterrestre Normal modelo ARX

RMSE - ARX - Rad. Ext. Nor. (Wh/m <sup>2</sup> ) - Sem Supressão do Zero								FIT - ARX - Rad. Ext. Nor. (Wh/m <sup>2</sup> ) - Sem Supressão do Zero							
Ordem do Modelo	k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo	k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7
na = k nb = k nc = 1	140,23	48,47	29,61	25,57	25,55	25,08	24,96	na = k nb = k nc = 1	0,663	0,883	0,929	0,939	0,939	0,940	0,940
na = k nb = k nc = 2	121,1	47,49	29,08	25,59	25,56	25,11	24,98	na = k nb = k nc = 2	0,709	0,886	0,930	0,938	0,939	0,940	0,940
na = k nb = k nc = 3	112,03	46,86	28,53	25,61	25,5	25,06	24,82	na = k nb = k nc = 3	0,731	0,887	0,931	0,938	0,939	0,940	0,940

RMSE - ARX - Rad. Ext. Nor. (%)								FIT - ARX - Rad. Ext. Nor. (%)							
Ordem do Modelo	k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo	k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7
na = k nb = k nc = nk	70,12	24,24	14,81	12,79	12,78	12,54	12,48	na = k nb = k nc = 1	66,27	88,34	92,88	93,85	93,85	93,97	94,00
na = k nb = k nc = nk	60,55	23,75	14,54	12,80	12,78	12,56	12,49	na = k nb = k nc = 2	70,87	88,58	93,01	93,84	93,85	93,96	93,99
na = k nb = k nc = nk	56,02	23,43	14,27	12,81	12,75	12,53	12,41	na = k nb = k nc = 3	73,05	88,73	93,14	93,84	93,87	93,97	94,03

RMSE - ARX - Rad. Ext. Nor. (Wh/m <sup>2</sup> ) - Com Supressão do Zero								FIT - ARX - Rad. Ext. Nor. (Wh/m <sup>2</sup> ) - Com Supressão do Zero							
Ordem do Modelo	k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo	k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7
na = k nb = k nc = 1	222,14	55,21	19,48	13,63	13,51	12,81	12,83	na = k nb = k nc = 1	0,547	0,887	0,960	0,972	0,973	0,974	0,974
na = k nb = k nc = 2	190,66	54,23	18,75	13,08	13,00	12,29	12,28	na = k nb = k nc = 2	0,611	0,889	0,962	0,973	0,974	0,975	0,975
na = k nb = k nc = 3	165,15	52,37	17,14	12,84	12,74	12,09	12,12	na = k nb = k nc = 3	0,663	0,893	0,965	0,974	0,974	0,975	0,975

RMSE - ARX - Rad. Ext. Nor. (%)								FIT - ARX - Rad. Ext. Nor. (%)							
Ordem do Modelo	k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo	k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7
na = k nb = k nc = 1	42,64	10,60	3,74	2,62	2,59	2,46	2,46	na = k nb = k nc = 1	54,72	88,74	96,03	97,22	97,25	97,39	97,39
na = k nb = k nc = 2	36,59	10,41	3,60	2,51	2,50	2,36	2,36	na = k nb = k nc = 2	61,14	88,94	96,18	97,33	97,35	97,50	97,50
na = k nb = k nc = 3	31,70	10,05	3,29	2,46	2,44	2,32	2,33	na = k nb = k nc = 3	66,34	89,32	96,51	97,38	97,40	97,54	97,53

Analisando-se o Quadro 4, pode observar que no modelo ARX sem supressão de zero, o erro tende a se estabilizar nos modelos a partir de 4ª ordem em torno de 12%. Isto significa que, em termos de consumo de recursos computacionais para resolução de equações, o modelo que representa melhor custo-benefício neste caso é o de 4ª ordem. O gráfico dos dados utilizados na validação e dos dados gerados pelo modelo podem ser observados na Figura 3.7.




Figura 3.7 - Modelo ARX ( $n_a = 4$ ,  $n_b = 4$ ,  $n_c = 3$ ) para predição de dados de Radiação Extraterrestre Normal sem supressão do zero.

Por meio da Figura 3.7, pode-se observar que há maior discrepância entre os dados utilizados para validação e os dados gerados pelo modelo quando o gráfico se aproxima de zero. Deste modo, foram feitas duas análises: a primeira denominada “Sem Supressão do Zero”, na qual os dados foram utilizados na íntegra. A segunda foi denominada “Com Supressão do Zero”. Nesta análise foram removidos os valores de radiação iguais a zero do banco de dados original e o valor médio do banco de dados é subtraído de toda a amostra, a fim de se normalizar os resultados. Isto impossibilita que o modelo gere pontos nestes intervalos.

Além disso, para o cálculo percentual do RMSE foi utilizado o valor médio de cada componente de radiação em todo o banco de dados. O FIT, que trata-se do coeficiente de aproximação entre os dados gerados pelo modelo e os dados utilizados na validação estabilizou-se em 93% na análise sem a supressão do zero e 97% com a supressão do zero.

Na Figura 3.8 pode-se observar o gráfico correspondente ao gráfico da Figura 3.7, porém com a supressão do zero.




Figura 3.8 - Modelo ARX ( $n_a = 4$ ,  $n_b = 4$ ,  $n_c = 3$ ) para predição de dados de Radiação Extraterrestre Normal com supressão do zero.

Pode-se observar, por meio do Quadro 4, que a supressão do zero diminuiu sensivelmente o erro, e do ponto de vista prático não interfere na performance real do modelo, uma vez que a radiação solar igual a zero ocorre sempre nos períodos da noite e madrugada.

Seguindo o método descrito, realizou-se a mesma análise utilizando-se o modelo ARMAX.

Quadro 5- Valores RMSE e FIT para Radiação Extraterrestre Normal modelo ARMAX

RMSE - ARMAX - Rad. Ext. Nor. (Wh/m <sup>2</sup> ) - Sem Supressão do Zero								FIT - ARMAX - Rad. Ext. Nor. - Sem Supressão do Zero							
Ordem do Modelo	k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo	k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7
na = k nb = k nc = k nk = 1	79,25	29,93	26,71	24,48	24,08	23,02	21,11	na = k nb = k nc = k nk = 1	0,809	0,928	0,936	0,941	0,942	0,945	0,949
na = k nb = k nc = k nk = 2	75,21	29,90	26,78	24,50	19,67	22,34	19,36	na = k nb = k nc = k nk = 2	0,819	0,928	0,936	0,941	0,953	0,946	0,953
na = k nb = k nc = k nk = 3	72,26	29,53	26,81	24,47	24,51	23,27	23,06	na = k nb = k nc = k nk = 3	0,826	0,929	0,936	0,941	0,941	0,944	0,945
RMSE - ARMAX - Rad. Ext. Nor. - Sem Supressão do Zero (%)								FIT - ARMAX - Rad. Ext. Nor. - Sem Supressão do Zero (%)							
Ordem do Modelo	k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo	k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7
na = k nb = k nc = k nk = 1	27,81	10,50	9,37	8,59	8,45	8,08	7,41	na = k nb = k nc = k nk = 1	80,94	92,80	93,57	94,11	94,21	94,46	94,92
na = k nb = k nc = k nk = 2	26,39	10,49	9,40	8,60	6,90	7,84	6,79	na = k nb = k nc = k nk = 1	81,91	92,81	93,56	94,11	95,27	94,63	95,34
na = k nb = k nc = k nk = 3	25,35	10,36	9,41	8,59	8,60	8,16	8,09	na = k nb = k nc = k nk = 1	82,62	92,90	93,55	94,11	94,10	94,40	94,45
RMSE - ARMAX - Rad. Ext. Nor. (Wh/m <sup>2</sup> ) - Com Supressão do Zero								FIT - ARMAX - Rad. Ext. Nor. - Com Supressão do Zero							
Ordem do Modelo	k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo	k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7
na = k nb = k nc = k nk = 1	121,6	20,4	13,7	12,9	8,1	14,6	11,2	na = k nb = k nc = k nk = 1	0,752	0,958	0,972	0,974	0,984	0,970	0,977
na = k nb = k nc = k nk = 2	112,9	20,0	13,0	12,7	13,5	11,5	8,84	na = k nb = k nc = k nk = 2	0,770	0,959	0,973	0,974	0,972	0,977	0,982
na = k nb = k nc = k nk = 3	102,4	19,6	12,9	12,6	11,7	11,4	13,7	na = k nb = k nc = k nk = 3	0,791	0,960	0,974	0,974	0,976	0,977	0,972
RMSE - ARMAX - Rad. Ext. Nor. - Com Supressão do Zero (%)								FIT - ARMAX - Rad. Ext. Nor. - Com Supressão do Zero (%)							
Ordem do Modelo	k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo	k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7
na = k nb = k nc = k nk = 1	42,68	7,15	4,80	4,54	2,83	5,11	3,92	na = k nb = k nc = k nk = 1	75,21	95,85	97,21	97,36	98,36	97,03	97,72
na = k nb = k nc = k nk = 2	39,62	7,02	4,57	4,46	4,75	4,05	3,10	na = k nb = k nc = k nk = 2	76,99	95,92	97,35	97,41	97,24	97,65	98,20
na = k nb = k nc = k nk = 3	35,95	6,87	4,51	4,43	4,09	3,99	4,80	na = k nb = k nc = k nk = 3	79,12	96,01	97,38	97,43	97,63	97,68	97,21




Figura 3.9 - Modelo ARMAX ( $n_a = 4$ ,  $n_b = 4$ ,  $n_c = 4$ ,  $n_k = 4$ ) para predição de dados de Radiação Extraterrestre Normal sem supressão do zero.




Figura 3.10 - Modelo ARMAX ( $n_a = 4$ ,  $n_b = 4$ ,  $n_c = 4$ ,  $n_k = 4$ ) para predição de dados de Radiação Extraterrestre Normal com supressão do zero.

Analisando-se o Quadro 5, pode-se observar que no modelo ARMAX quando da supressão de zero, o erro não tende a se estabilizar nos modelos a partir de 4ª ordem. Isto significa que a escolha da ordem do modelo dependerá da margem de erro admitida pelo processo que venha a utilizar o banco de dados simulado. O FIT estabilizou-se em 94% na análise sem a supressão do zero e 97% com a supressão do zero.

Comparando as figuras e quadros dos modelos ARX e ARMAX aplicados à Radiação Extraterrestre Normal, conclui-se que neste caso torna-se mais viável a utilização do modelo ARX, pois ele apresenta menores erros entre os dados criados e os dados utilizados na validação para a ordem do modelo maior ou igual a 4, além de ser menos complexo, ou seja, demanda menos recursos computacionais que o modelo ARMAX.

Quadro 6 - Valores RMSE e FIT para Radiação Infravermelha Horizontal modelo ARX

RMSE - ARX - Rad. Infra. (Wh/m <sup>2</sup> ) - Sem Supressão do Zero									FIT - ARX - Rad. Infra. - Sem Supressão do Zero										
Ordem do Modelo			k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo			k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7
na = k	nb = k	nc = 1	6,25	5,37	5,24	5,18	5,14	5,11	5,09	na = k	nb = k	nc = 1	0,756	0,790	0,795	0,798	0,799	0,800	0,801
na = k	nb = k	nc = 2	6,63	5,31	5,23	5,20	5,16	5,14	5,12	na = k	nb = k	nc = 2	0,741	0,792	0,796	0,797	0,798	0,799	0,800
na = k	nb = k	nc = 3	6,53	5,31	5,22	5,20	5,18	5,15	5,13	na = k	nb = k	nc = 3	0,745	0,793	0,796	0,797	0,798	0,799	0,799
RMSE - ARX - Rad. Infra. (%)									FIT - ARX - Rad. Infra. (%)										
Ordem do Modelo			k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo			k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7
na = k	nb = k	nc = 1	1,69	1,45	1,42	1,40	1,39	1,38	1,38	na = k	nb = k	nc = 1	75,57	78,99	79,53	79,75	79,91	80,03	80,11
na = k	nb = k	nc = 2	1,79	1,44	1,41	1,40	1,39	1,39	1,38	na = k	nb = k	nc = 2	74,10	79,25	79,56	79,70	79,84	79,92	80,00
na = k	nb = k	nc = 3	1,77	1,43	1,41	1,40	1,40	1,39	1,39	na = k	nb = k	nc = 3	74,47	79,26	79,59	79,69	79,77	79,86	79,93

Quadro 7 - Valores RMSE e FIT para Radiação Infravermelha Horizontal modelo ARMAX

<b>RMSE - ARMAX - Rad. Infra. (Wh/m<sup>2</sup>) - Sem Supressão do Zero</b>										<b>FIT - ARMAX - Rad. Infra. - Sem Supressão do Zero</b>											
Ordem do Modelo				k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo				k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7
na = k	nb = k	nc = k	nk = 1	5,91	5,10	4,87	4,86	4,69	4,72	4,60	na = k	nb = k	nc = k	nk = 1	0,769	0,801	0,810	0,810	0,817	0,815	0,820
na = k	nb = k	nc = k	nk = 2	5,95	5,12	4,90	4,79	4,61	4,64	4,49	na = k	nb = k	nc = k	nk = 2	0,768	0,800	0,808	0,813	0,820	0,819	0,825
na = k	nb = k	nc = k	nk = 3	5,84	5,15	5,13	4,83	4,61	4,69	4,50	na = k	nb = k	nc = k	nk = 3	0,772	0,799	0,799	0,811	0,820	0,817	0,824
<b>RMSE - ARMAX - Rad. Infra. - Sem Supressão do Zero (%)</b>										<b>FIT - ARMAX - Rad. Infra. - Sem Supressão do Zero (%)</b>											
Ordem do Modelo				k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo				k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7
na = k	nb = k	nc = k	nk = 1	1,60	1,38	1,32	1,31	1,27	1,28	1,24	na = k	nb = k	nc = k	nk = 1	76,90	80,07	80,98	80,99	81,67	81,54	82,01
na = k	nb = k	nc = k	nk = 2	1,61	1,38	1,32	1,29	1,25	1,25	1,21	na = k	nb = k	nc = k	nk = 2	76,76	79,98	80,85	81,28	81,98	81,88	82,47
na = k	nb = k	nc = k	nk = 3	1,58	1,39	1,39	1,31	1,25	1,27	1,22	na = k	nb = k	nc = k	nk = 3	77,16	79,88	79,95	81,11	81,97	81,65	82,40




Figura 3.11 - Modelo ARX ( $n_a = 3$ ,  $n_b = 3$ ,  $n_k = 1$ ) para predição de dados de Radiação Infravermelha Horizontal sem supressão do zero.




Figura 3.12 - Modelo ARMAX ( $n_a = 3$ ,  $n_b = 3$ ,  $n_c = 3$ ,  $n_k = 1$ ) para predição de dados de Radiação Infravermelha Horizontal sem supressão do zero.

Como os dados de radiação infravermelha com supressão do zero são todos maiores do que zero, nesta análise não foi utilizada a supressão do zero. Conforme pode ser observado nos Quadros Quadro 6 e Quadro 7, a diferença percentual entre os valores RMSE e FIT nos modelos ARX e ARMAX não é muito significativa. Ambos mantêm o erro abaixo de 2% e o FIT em torno de 80%. Em ambos os casos, os erros tendem a estabilizar-se a partir de  $k = 3$ .

Comparando-se os gráficos e Quadros dos modelos ARX e ARMAX aplicados à Radiação Infravermelha, conclui-se que neste caso torna-se mais viável a utilização do modelo ARX, uma vez que demanda menos recursos computacionais que o modelo ARMAX.

Quadro 8 - Valores RMSE e FIT para Radiação Extraterrestre Horizontal modelo ARX

RMSE - ARX - Rad. Ext. Hor. (Wh/m <sup>2</sup> ) (Wh/m <sup>2</sup> ) - Sem Supressão do Zero								FIT - ARX - Rad. Ext. Hor. - Sem Supressão do Zero							
Ordem do Modelo	k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo	k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7
na = k nb = k nc = 1	147,91	70,40	65,57	65,46	65,11	65,04	65,00	na = k nb = k nc = 1	0,694	0,854	0,864	0,865	0,865	0,865	0,866
na = k nb = k nc = 2	124,01	69,69	65,52	65,28	65,08	65,06	65,01	na = k nb = k nc = 2	0,743	0,856	0,864	0,865	0,865	0,865	0,865
na = k nb = k nc = 3	115,52	68,90	65,46	65,21	65,13	65,12	65,07	na = k nb = k nc = 3	0,761	0,857	0,865	0,865	0,865	0,865	0,865

RMSE - ARX - Rad. Ext. Hor.(%)								FIT - ARX - Rad. Ext. Nor. (%)							
Ordem do Modelo	k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo	k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7
na = k nb = k nc = 1	37,44	17,82	16,60	16,57	16,48	16,47	16,45	na = k nb = k nc = 1	69,40	85,43	86,43	86,45	86,53	86,54	86,55
na = k nb = k nc = 2	31,39	17,64	16,59	16,53	16,48	16,47	16,46	na = k nb = k nc = 2	74,34	85,58	86,44	86,49	86,53	86,54	86,55
na = k nb = k nc = 3	29,24	17,44	16,57	16,51	16,49	16,49	16,47	na = k nb = k nc = 3	76,10	85,74	86,46	86,51	86,52	86,52	86,54

RMSE - ARX - Rad. Ext. Hor. (Wh/m <sup>2</sup> ) - Com Supressão do Zero								FIT - ARX - Rad. Ext. Hor. - Com Supressão do Zero							
Ordem do Modelo	k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo	k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7
na = k nb = k nc = 1	188,24	41,64	38,80	38,39	38,36	38,47	38,64	na = k nb = k nc = 1	0,5743	0,9058	0,9122	0,9132	0,9132	0,9130	0,9126
na = k nb = k nc = 2	15,69	41,81	38,76	38,30	38,36	38,49	38,53	na = k nb = k nc = 2	0,6451	0,9054	0,9123	0,9134	0,9132	0,9130	0,9128
na = k nb = k nc = 3	13,56	41,71	38,81	38,41	38,53	38,49	38,01	na = k nb = k nc = 3	0,6933	0,9056	0,9122	0,9131	0,9129	0,9129	0,9140

RMSE - ARX - Rad. Ext. Hor.(%)								FIT - ARX - Rad. Ext. Hor. (%)							
Ordem do Modelo	k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo	k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7
na = k nb = k nc = 1	34,73	7,68	7,16	7,08	7,08	7,10	7,13	na = k nb = k nc = 1	57,43	90,58	91,22	91,32	91,32	91,30	91,26
na = k nb = k nc = 2	2,89	7,71	7,15	7,07	7,08	7,10	7,11	na = k nb = k nc = 2	64,51	90,54	91,23	91,34	91,32	91,30	91,28
na = k nb = k nc = 3	2,50	7,70	7,16	7,09	7,11	7,10	7,01	na = k nb = k nc = 3	69,33	90,56	91,22	91,31	91,29	91,29	91,40

Analisando-se o Quadro 8, pode-se observar que no modelo ARX sem supressão de zero, o erro tende a se estabilizar nos modelos a partir de 3ª ordem em torno de 16%. Neste caso, a supressão do zero diminui o erro para em torno de 7%, o que representa uma melhoria de mais de 200% na representatividade do modelo, sem prejuízo na aplicações práticas como descrito anteriormente. Além disso, o FIT estabiliza-se em 86% sem a supressão do zero e 91% com a supressão do zero. O gráfico dos dados utilizados na validação e dos dados gerados pelo modelo podem ser observados nas Figuras 3.13 e 3.14.




Figura 3.13 - Modelo ARX ( $n_a = 3$ ,  $n_b = 3$ ,  $n_k = 3$ ) para predição de dados de Radiação Extraterrestre Horizontal sem supressão do zero.




Figura 3.14 - Modelo ARX ( $n_a = 3$ ,  $n_b = 3$ ,  $n_k = 3$ ) para predição de dados de Radiação Extraterrestre Horizontal com supressão do zero.

Quadro 9 - Valores RMSE e FIT para Radiação Extraterrestre Horizontal modelo ARMAX

RMSE - ARMAX - Rad. Ext. Hor. (Wh/m <sup>2</sup> ) - Sem Supressão do Zero											FIT - ARMAX - Rad. Ext. Hor. - Sem Supressão do Zero										
Ordem do Modelo				k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo				k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7
na = k	nb = k	nc = k	nk = 1	96,14	65,72	61,66	56,64	61,00	57,21	53,53	na = k	nb = k	nc = k	nk = 1	0,801	0,864	0,872	0,883	0,874	0,882	0,889
na = k	nb = k	nc = k	nk = 2	88,69	65,76	61,69	58,29	57,54	58,56	56,02	na = k	nb = k	nc = k	nk = 2	0,816	0,864	0,872	0,879	0,881	0,879	0,884
na = k	nb = k	nc = k	nk = 3	83,48	65,78	61,72	58,98	43,87	49,87	53,73	na = k	nb = k	nc = k	nk = 3	0,827	0,864	0,872	0,878	0,909	0,897	0,889
RMSE - ARMAX - Rad. Ext. Hor. - Sem Supressão do Zero (%)											FIT - ARMAX - Rad. Ext. Hor. - Sem Supressão do Zero (%)										
Ordem do Modelo				k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo				k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7
na = k	nb = k	nc = k	nk = 1	24,34	16,64	15,61	14,34	15,44	14,48	13,55	na = k	nb = k	nc = k	nk = 1	80,11	86,40	87,24	88,28	87,38	88,16	88,92
na = k	nb = k	nc = k	nk = 2	22,45	16,65	15,62	14,76	14,57	14,83	14,18	na = k	nb = k	nc = k	nk = 2	81,65	86,39	87,23	87,94	88,09	87,88	88,41
na = k	nb = k	nc = k	nk = 3	21,13	16,65	15,62	14,93	11,11	12,63	13,60	na = k	nb = k	nc = k	nk = 3	82,73	86,39	87,23	87,80	90,92	89,68	88,88
RMSE - ARMAX - Rad. Ext. Hor. (Wh/m <sup>2</sup> ) - Com Supressão do Zero											FIT - ARMAX - Rad. Ext. Hor. - Com Supressão do Zero										
Ordem do Modelo				k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo				k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7
na = k	nb = k	nc = k	nk = 1	111,29	38,30	38,77	32,33	33,13	34,96	28,30	na = k	nb = k	nc = k	nk = 1	0,748	0,913	0,912	0,927	0,925	0,921	0,936
na = k	nb = k	nc = k	nk = 2	97,93	38,26	38,71	32,31	32,66	28,10	28,95	na = k	nb = k	nc = k	nk = 2	0,779	0,913	0,912	0,927	0,926	0,936	0,935
na = k	nb = k	nc = k	nk = 3	87,11	38,33	38,85	33,19	32,65	34,16	30,08	na = k	nb = k	nc = k	nk = 3	0,803	0,913	0,912	0,925	0,926	0,923	0,932
RMSE - ARMAX - Rad. Ext. Hor. - Com Supressão do Zero (%)											FIT - ARMAX - Rad. Ext. Hor. - Com Supressão do Zero (%)										
Ordem do Modelo				k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo				k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7
na = k	nb = k	nc = k	nk = 1	20,49	7,05	7,14	5,95	6,10	6,44	5,21	na = k	nb = k	nc = k	nk = 1	74,83	91,34	91,23	92,69	92,51	92,09	93,60
na = k	nb = k	nc = k	nk = 2	18,03	7,05	7,13	5,95	6,01	5,17	5,33	na = k	nb = k	nc = k	nk = 2	77,85	91,35	91,25	92,69	92,61	93,64	93,45
na = k	nb = k	nc = k	nk = 3	16,04	7,06	7,15	6,11	6,01	6,29	5,54	na = k	nb = k	nc = k	nk = 3	80,30	91,33	91,21	92,49	92,62	92,28	93,20

Analisando-se o Quadro 9, pode observar que no modelo ARMAX o erro não tende a se estabilizar nos modelos a partir de 3ª ordem sem supressão de zero e 4ª ordem com a supressão do zero. Isto significa que a escolha da ordem do modelo dependerá da margem de erro admitida pelo processo que venha a utilizar o banco de dados simulado. O FIT estabilizou-se em 87% na análise sem a supressão do zero e 92% com a supressão do zero.




Figura 3.15- Modelo ARMAX ( $n_a = 3$ ,  $n_b = 3$ ,  $n_c = 3$ ,  $n_k = 3$ ) para predição de dados de Radiação Extraterrestre Horizontal sem supressão do zero.




Figura 3.16 - Modelo ARMAX ( $n_a = 4$ ,  $n_b = 4$ ,  $n_c = 4$ ,  $n_k = 3$ ) para predição de dados de Radiação Extraterrestre Horizontal com supressão do zero.

Comparando os gráficos e quadros dos modelos ARX e ARMAX aplicados à Radiação Extraterrestre Horizontal, conclui-se que neste caso torna-se mais viável a utilização do modelo ARX, pois ele apresenta menores erros entre os dados criados e os dados utilizados na validação para a ordem do modelo maior ou igual a 3, além de possuir menor variação de erro no intervalo de ordens de modelo entre 3 e 7.

Quadro 10 - Valores RMSE e FIT para Radiação Direta Normal modelo ARX

RMSE - ARX - Rad. Direta Nor. (Wh/m <sup>2</sup> ) - Sem Supressão do Zero									FIT - ARX - Rad. Direta Nor. - Sem Supressão do Zero										
Ordem do Modelo			k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo			k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7
na = k	nb = k	nc = 1	78,33	75,36	73,81	73,37	73,19	73,02	72,72	na = k	nb = k	nc = 1	0,440	0,461	0,472	0,475	0,476	0,478	0,480
na = k	nb = k	nc = 2	81,83	75,57	74,87	74,85	74,66	74,29	73,99	na = k	nb = k	nc = 2	0,415	0,459	0,464	0,465	0,466	0,469	0,471
na = k	nb = k	nc = 3	81,70	79,50	76,64	76,56	76,21	75,87	75,75	na = k	nb = k	nc = 3	0,415	0,431	0,452	0,452	0,455	0,457	0,458
RMSE - ARX - Rad. Direta Nor. (%)									FIT - ARX - Rad. Direta Nor. (%)										
Ordem do Modelo			k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo			k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7
na = k	nb = k	nc = 1	126,34	121,55	119,04	118,3341	118,05	117,77	117,29	na = k	nb = k	nc = 1	43,96	46,08	47,20	47,51	47,64	47,76	47,97
na = k	nb = k	nc = 2	131,98	121,89	120,76	120,72	120,41	119,82	119,33	na = k	nb = k	nc = 2	41,46	45,94	46,43	46,45	46,59	46,85	47,07
na = k	nb = k	nc = 3	131,77	128,23	123,61	123,48	122,91	122,37	122,18	na = k	nb = k	nc = 3	41,55	43,12	45,17	45,23	45,48	45,72	45,80
RMSE - ARX - Rad. Direta Nor. (Wh/m <sup>2</sup> ) - Com Supressão do Zero									FIT - ARX - Rad. Direta Nor. - Com Supressão do Zero										
Ordem do Modelo			k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo			k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7
na = k	nb = k	nc = 1	149,83	143,08	139,34	137,38	136,82	136,36	135,67	na = k	nb = k	nc = 1	0,441	0,466	0,480	0,487	0,489	0,491	0,494
na = k	nb = k	nc = 2	161,97	144,76	141,91	141,42	141,08	140,29	139,62	na = k	nb = k	nc = 2	0,396	0,460	0,470	0,472	0,474	0,477	0,479
na = k	nb = k	nc = 3	160,80	152,60	146,49	146,09	145,52	144,88	144,37	na = k	nb = k	nc = 3	0,400	0,431	0,453	0,455	0,457	0,459	0,461
RMSE - ARX - Rad. Direta Nor. (%)									FIT - ARX - Rad. Direta Nor. (%)										
Ordem do Modelo			k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo			k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7
na = k	nb = k	nc = 1	68,10	65,03	63,33	62,45	62,19	61,98	61,67	na = k	nb = k	nc = 1	44,07	46,60	48,00	48,73	48,94	49,11	49,37
na = k	nb = k	nc = 2	73,62	65,80	64,50	64,28	64,13	63,77	63,46	na = k	nb = k	nc = 2	39,55	45,98	47,05	47,23	47,35	47,65	47,90
na = k	nb = k	nc = 3	73,09	69,37	66,59	66,41	66,15	65,86	65,62	na = k	nb = k	nc = 3	40,00	43,06	45,33	45,48	45,70	45,94	46,13

Analisando-se o Quadro 10, pode observar que para a Radiação Direta Normal, no modelo ARX sem supressão de zero o erro não tende a diminuir aumentando-se a ordem do modelo, possuindo valores da ordem de mais de 100% em todos os graus do modelo analisado. Além disso, o FIT é menor que 50% em ambos os casos. A radiação direta normal é de grande importância para simulações na área de eficiência energética em edificações. Deste modo, pode-se concluir que a modelagem ARX não é eficaz em se tratando de sua utilização para predição de dados de radiação direta normal.

Nas Figuras 3.17 e 3.18 é possível observar graficamente o comportamento dos dados gerados matematicamente com relação ao dados utilizados para validação.




Figura 3.17 - Modelo ARX ( $n_a = 4$ ,  $n_b = 4$ ,  $n_k = 1$ ) para predição de dados de Radiação Direta Normal sem supressão do zero.




Figura 3.18 - Modelo ARX ( $n_a = 4$ ,  $n_b = 4$ ,  $n_k = 1$ ) para predição de dados de Radiação Direta Normal com supressão do zero.

Quadro 11 - Valores RMSE e FIT para Radiação Direta Normal modelo ARMAX

RMSE - ARMAX - Rad. Direta. Nor. (Wh/m <sup>2</sup> ) - Sem Supressão do Zero								FIT - ARMAX - Rad. Direta. Nor. - Sem Supressão do Zero													
Ordem do Modelo		k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo		k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7				
na = k	nb = k	nc = k	nk = 1	76,55	73,47	72,32	72,14	70,84	70,83	70,55	na = k	nb = k	nc = k	nk = 1	0,452	0,474	0,483	0,484	0,493	0,493	0,495
na = k	nb = k	nc = k	nk = 2	79,45	75,08	73,55	73,00	72,20	71,34	69,48	na = k	nb = k	nc = k	nk = 2	0,432	0,463	0,474	0,478	0,483	0,490	0,503
na = k	nb = k	nc = k	nk = 3	81,20	76,45	75,94	75,36	74,20	70,93	71,51	na = k	nb = k	nc = k	nk = 3	0,419	0,453	0,457	0,461	0,469	0,492	0,488
RMSE - ARMAX - Rad. Direta. Nor. - Sem Supressão do Zero (%)								FIT - ARMAX - Rad. Direta. Nor. - Sem Supressão do Zero (%)													
Ordem do Modelo		k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo		k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7				
na = k	nb = k	nc = k	nk = 1	123,47	118,50	116,65	116,36	114,26	114,25	113,79	na = k	nb = k	nc = k	nk = 1	45,23	47,44	48,26	48,38	49,31	49,32	49,53
na = k	nb = k	nc = k	nk = 2	128,14	121,09	118,64	117,74	116,46	115,06	112,06	na = k	nb = k	nc = k	nk = 2	43,16	46,29	47,38	47,77	48,34	48,96	50,29
na = k	nb = k	nc = k	nk = 3	130,96	123,31	122,48	121,54	119,68	114,41	115,34	na = k	nb = k	nc = k	nk = 3	41,91	45,30	45,67	46,09	46,91	49,25	48,84
RMSE - ARMAX - Rad. Direta. Nor. (Wh/m <sup>2</sup> ) - Com Supressão do Zero								FIT - ARMAX - Rad. Direta. Nor. - Com Supressão do Zero													
Ordem do Modelo		k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo		k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7				
na = k	nb = k	nc = k	nk = 1	145,90	137,51	134,92	134,16	130,75	129,84	130,16	na = k	nb = k	nc = k	nk = 1	0,455	0,487	0,497	0,499	0,512	0,516	0,514
na = k	nb = k	nc = k	nk = 2	155,54	142,77	138,99	138,72	134,82	134,85	135,73	na = k	nb = k	nc = k	nk = 2	0,419	0,467	0,481	0,482	0,497	0,497	0,494
na = k	nb = k	nc = k	nk = 3	160,33	146,76	143,46	143,36	142,80	132,56	128,91	na = k	nb = k	nc = k	nk = 3	0,402	0,452	0,465	0,465	0,467	0,506	0,519
RMSE - ARMAX - Rad. Direta. Nor. - Com Supressão do Zero (%)								FIT - ARMAX - Rad. Direta. Nor. - Com Supressão do Zero (%)													
Ordem do Modelo		k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo		k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7				
na = k	nb = k	nc = k	nk = 1	66,32	62,50	61,33	60,98	59,43	59,02	59,16	na = k	nb = k	nc = k	nk = 1	45,54	48,68	49,65	49,94	51,22	51,56	51,44
na = k	nb = k	nc = k	nk = 2	70,70	64,89	63,18	63,05	61,28	61,29	61,69	na = k	nb = k	nc = k	nk = 2	41,95	46,73	48,14	48,24	49,69	49,68	49,37
na = k	nb = k	nc = k	nk = 3	72,88	66,71	65,21	65,16	64,91	60,26	58,60	na = k	nb = k	nc = k	nk = 3	40,17	45,24	46,47	46,51	46,73	50,56	51,93

Na modelagem ARMAX (Quadro 11) ocorreu o mesmo efeito que na modelagem ARX para esta composição de radiação. Obtiveram-se valores da ordem de mais de 100% em todos os graus do modelo analisado. Com a supressão do zero, os erros tornam-se bem inferiores, porém ainda não encontram-se dentro de uma faixa aceitável. Além disso, o FIT é menor que 50% em ambos os casos. Deste modo, pode-se concluir que a modelagem ARMAX geram uma aproximação menor que as previamente discutidas em se tratando de sua utilização para predição de dados de radiação direta normal.

Nas Figuras 3.19 e 3.20 é possível observar graficamente o comportamento dos dados gerados matematicamente com relação ao dados utilizados para validação.

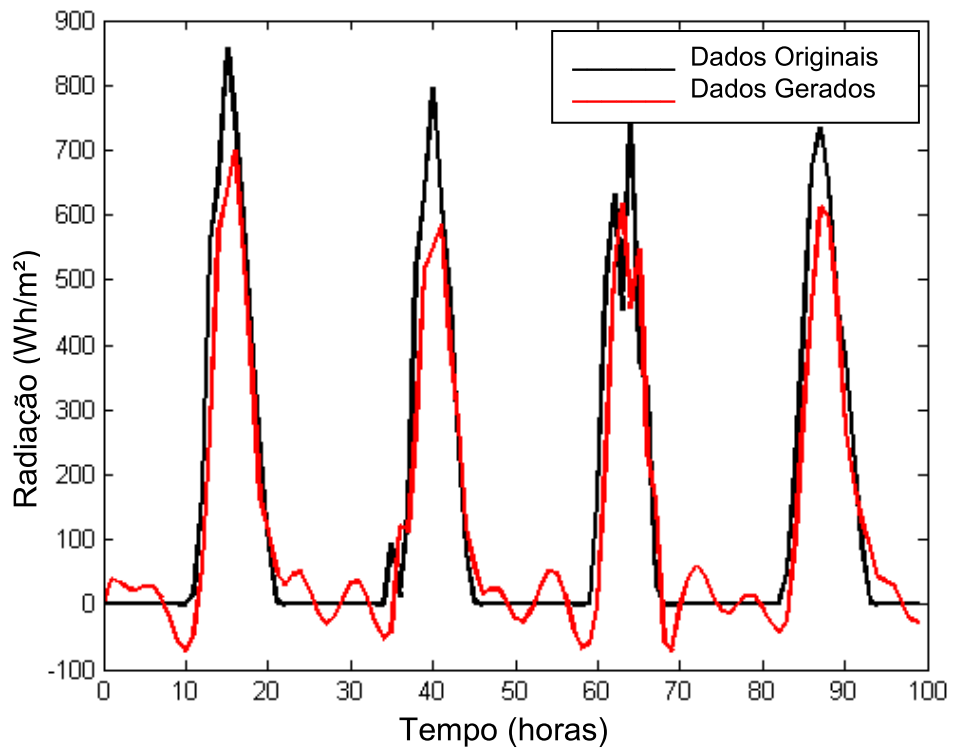


Figura 3.19 - Modelo ARMAX ( $n_a = 5$ ,  $n_b = 5$ ,  $n_c = 5$ ,  $n_k = 1$ ) para predição de dados de Radiação Direta Normal sem supressão do zero.




Figura 3.20 - Modelo ARMAX ( $n_a = 5$ ,  $n_b = 5$ ,  $n_c = 5$ ,  $n_k = 1$ ) Radiação Direta Normal com supressão do zero.

Quadro 12 - Valores RMSE e FIT para Radiação Difusa Horizontal modelo ARX

RMSE - ARX - Rad. Difusa Hor. (Wh/m <sup>2</sup> ) - Sem Supressão do Zero								FIT - ARX - Rad. Difusa Hor. - Sem Supressão do Zero							
Ordem do Modelo	k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo	k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7
na = k nb = k nc = 1	57,02	52,53	51,86	51,74	51,67	51,61	51,57	na = k nb = k nc = 1	0,547	0,583	0,588	0,589	0,590	0,590	0,591
na = k nb = k nc = 2	55,27	53,45	52,90	52,70	52,62	52,60	52,58	na = k nb = k nc = 2	0,561	0,576	0,580	0,582	0,582	0,583	0,583
na = k nb = k nc = 3	54,07	53,43	52,99	52,73	52,68	52,68	52,67	na = k nb = k nc = 3	0,571	0,576	0,579	0,581	0,582	0,582	0,582
RMSE - ARX - Rad. Difusa Hor. (%)								FIT - ARX - Rad. Difusa Hor. (%)							
Ordem do Modelo	k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo	k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7
na = k nb = k nc = 1	59,40	54,71	54,02	53,89	53,82	53,76	53,72	na = k nb = k nc = 1	54,74	58,31	58,84	58,94	58,99	59,03	59,07
na = k nb = k nc = 2	57,57	55,68	55,10	54,89	54,81	54,79	54,77	na = k nb = k nc = 2	56,13	57,58	58,02	58,18	58,24	58,25	58,26
na = k nb = k nc = 3	56,32	55,66	55,20	54,93	54,88	54,87	54,86	na = k nb = k nc = 3	57,08	57,59	57,94	58,15	58,19	58,19	58,20
RMSE - ARX - Rad. Difusa Hor. (Wh/m <sup>2</sup> ) - Com Supressão do Zero								FIT - ARX - Rad. Difusa Hor. - Com Supressão do Zero							
Ordem do Modelo	k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo	k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7
na = k nb = k nc = 1	82,54	76,72	74,63	73,83	73,57	73,45	73,23	na = k nb = k nc = 1	0,3851	0,4284	0,4439	0,4499	0,4518	0,4527	0,4544
na = k nb = k nc = 2	80,37	76,63	74,72	73,84	73,57	73,30	72,88	na = k nb = k nc = 2	0,4011	0,4290	0,4432	0,4498	0,4518	0,4539	0,4570
na = k nb = k nc = 3	78,04	76,01	74,56	73,81	73,44	73,00	72,43	na = k nb = k nc = 3	0,4185	0,4336	0,4445	0,4501	0,4528	0,4561	0,4604
RMSE - ARX - Rad. Difusa Hor. (%)								FIT - ARX - Rad. Difusa Hor. (%)							
Ordem do Modelo	k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo	k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7
na = k nb = k nc = 1	56,92	52,91	51,47	50,91	50,74	50,65	50,50	na = k nb = k nc = 1	38,51	42,84	44,39	44,99	45,18	45,27	45,44
na = k nb = k nc = 2	55,43	52,85	51,53	50,93	50,74	50,55	50,26	na = k nb = k nc = 2	40,11	42,90	44,32	44,98	45,18	45,39	45,70
na = k nb = k nc = 3	53,82	52,42	51,42	50,90	50,65	50,34	49,95	na = k nb = k nc = 3	41,85	43,36	44,45	45,01	45,28	45,61	46,04

No caso da Radiação Difusa Horizontal (Quadro 12), pode-se observar que no modelo ARX sem supressão de zero o erro não tende a diminuir significativamente aumentando-se a ordem do modelo, possuindo valores entre 50 e 60% em todos os graus do modelo analisado. Com a supressão do zero, os erros praticamente não diminuem, mantendo-se na mesma faixa. Além disso, o FIT é menor que 60% sem a supressão do zero e menor que 50% com a supressão do zero, o que demonstra que, para este caso, eliminar os valores de radiação igual a zero do banco de dados para validação não foi eficiente para a modelagem matemática. Deste modo, pode-se concluir que a modelagem ARX não é eficaz em se tratando de sua utilização para predição de dados de Radiação Difusa Horizontal.

Nas Figuras 3.21 e 3.22 é possível observar graficamente o comportamento dos dados gerados matematicamente com relação ao dados utilizados para validação.

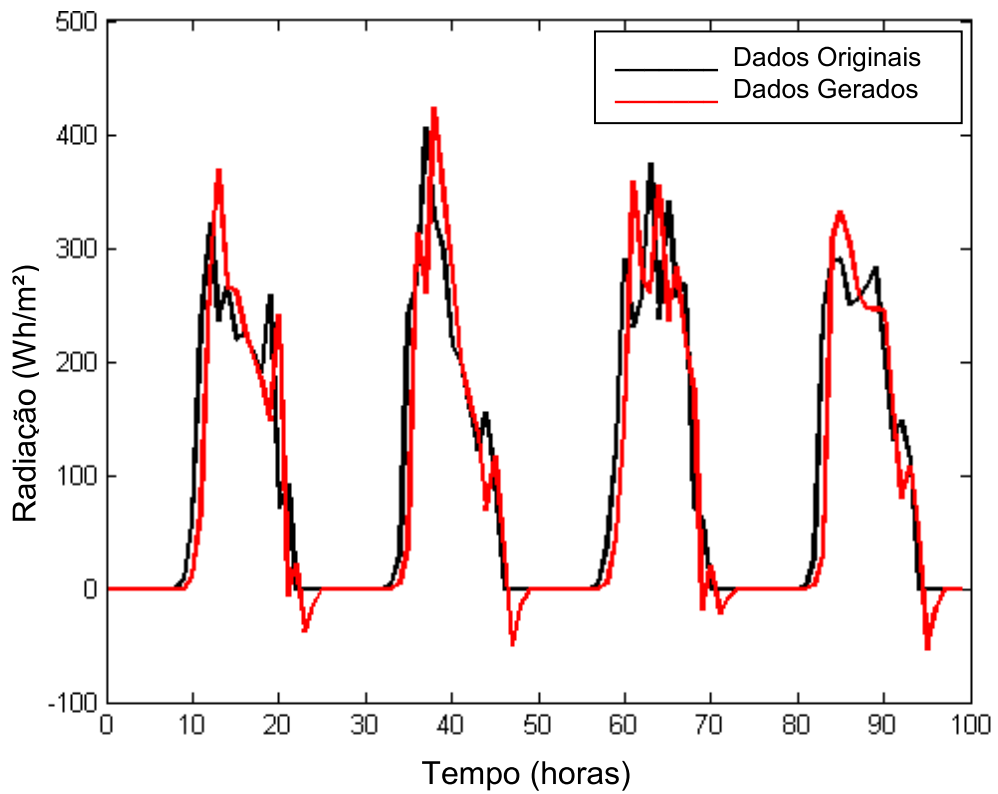


Figura 3.21 - Modelo ARX ( $n_a = 3$ ,  $n_b = 3$ ,  $n_k = 1$ ) para predição de dados de Radiação Difusa Horizontal sem supressão do zero.




Figura 3.22 - Modelo ARX ( $n_a = 4$ ,  $n_b = 4$ ,  $n_k = 1$ ) para predição de dados de Radiação Difusa Horizontal com supressão do zero.

Quadro 13 - Valores RMSE e FIT para Radiação Difusa Horizontal modelo ARMAX

RMSE - ARMAX – Rad. Difusa Hor. (Wh/m²) - Sem Supressão do Zero										FIT - ARMAX - Rad. Difusa Hor. - Sem Supressão do Zero											
Ordem do Modelo				k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo				k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7
na = k	nb = k	nc = k	nk = 1	55,24	51,77	51,51	47,42	42,52	39,52	48,24	na = k	nb = k	nc = k	nk = 1	0,562	0,589	0,591	0,624	0,663	0,686	0,617
na = k	nb = k	nc = k	nk = 2	54,76	52,75	51,31	47,96	45,37	42,54	47,88	na = k	nb = k	nc = k	nk = 2	0,565	0,581	0,593	0,619	0,640	0,662	0,620
na = k	nb = k	nc = k	nk = 3	53,80	52,79	51,26	49,06	47,49	40,18	47,52	na = k	nb = k	nc = k	nk = 3	0,573	0,581	0,593	0,611	0,623	0,681	0,623
RMSE - ARMAX - Rad. Difusa Hor. - Sem Supressão do Zero (%)										FIT - ARMAX - Rad. Difusa Hor. - Sem Supressão do Zero (%)											
Ordem do Modelo				k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo				k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7
na = k	nb = k	nc = k	nk = 1	58,15	54,49	54,22	49,91	44,76	41,60	50,78	na = k	nb = k	nc = k	nk = 1	56,16	58,91	59,12	62,36	66,25	68,63	61,71
na = k	nb = k	nc = k	nk = 2	57,65	55,53	54,01	50,49	47,76	44,77	50,40	na = k	nb = k	nc = k	nk = 2	56,53	58,13	59,28	61,93	63,99	66,24	62,00
na = k	nb = k	nc = k	nk = 3	56,63	55,57	53,96	51,64	49,99	42,30	50,03	na = k	nb = k	nc = k	nk = 3	57,30	58,10	59,31	61,06	62,31	68,11	62,28
RMSE - ARMAX - Rad. Difusa Hor. (Wh/m²) - Com Supressão do Zero										FIT - ARMAX - Rad. Difusa Hor. - Com Supressão do Zero											
Ordem do Modelo				k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo				k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7
na = k	nb = k	nc = k	nk = 1	80,50	70,96	71,52	63,01	63,00	62,61	59,68	na = k	nb = k	nc = k	nk = 1	0,400	0,471	0,467	0,530	0,531	0,534	0,555
na = k	nb = k	nc = k	nk = 2	79,55	71,09	71,23	71,18	70,71	61,98	58,30	na = k	nb = k	nc = k	nk = 2	0,407	0,470	0,469	0,470	0,473	0,538	0,566
na = k	nb = k	nc = k	nk = 3	77,70	71,20	63,76	63,00	59,16	62,05	58,87	na = k	nb = k	nc = k	nk = 3	0,421	0,470	0,525	0,531	0,559	0,538	0,561
RMSE - ARMAX - Rad. Difusa Hor. - Com Supressão do Zero (%)										FIT - ARMAX - Rad. Difusa Hor. - Com Supressão do Zero (%)											
Ordem do Modelo				k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7	Ordem do Modelo				k = 1	k = 2	k = 3	k = 4	k = 5	k = 6	k = 7
na = k	nb = k	nc = k	nk = 1	55,51	48,94	49,32	43,46	43,45	43,18	41,16	na = k	nb = k	nc = k	nk = 1	40,03	47,13	46,71	53,05	53,06	53,36	55,54
na = k	nb = k	nc = k	nk = 2	54,86	49,03	49,12	49,09	48,77	42,75	40,21	na = k	nb = k	nc = k	nk = 2	40,73	47,03	46,93	46,96	47,32	53,83	56,56
na = k	nb = k	nc = k	nk = 3	53,59	49,10	43,97	43,45	40,80	42,79	40,60	na = k	nb = k	nc = k	nk = 3	42,10	46,95	52,49	53,05	55,92	53,78	56,14

Na modelagem ARMAX (Quadro 13) ocorre o mesmo efeito que na modelagem ARX para esta composição de radiação. Para o modelo sem a supressão do zero obtiveram-se valores de RMSE entre 40 e 60% em todos os graus do modelo analisado. Com a supressão do zero, os erros praticamente não diminuem, mantendo-se na mesma faixa. Além disso, o FIT é menor que 60% em ambos os casos, demonstrando que, para este caso, eliminar os valores de radiação igual a zero do banco de dados para validação não foi eficiente para a modelagem matemática. Deste modo, pode-se concluir que a modelagem ARMAX não é eficaz em se tratando de sua utilização para predição de dados de Radiação Difusa Horizontal.

Nas Figuras 3.23 e 3.24 é possível observar graficamente o comportamento dos dados gerados matematicamente com relação ao dados utilizados para validação.




Figura 3.23 - Modelo ARMAX ( $n_a = 6$ ,  $n_b = 6$ ,  $n_c = 6$ ,  $n_k = 1$ ) para predição de dados de Radiação Difusa Horizontal sem supressão do zero.




Figura 3.24 - Modelo ARMAX ( $n_a = 6$ ,  $n_b = 6$ ,  $n_c = 6$ ,  $n_k = 1$ ) para predição de dados de Radiação Difusa Horizontal com supressão do zero.

### 3.5 Considerações Finais

A utilização da modelagem linear (ARX e ARMAX) para predição de dados de radiação solar mostrou-se eficiente para as composições: Extraterrestre Normal, Infravermelha e Extraterrestre Horizontal. Para estes casos, os menores erros encontrados entre os dados utilizados na validação e os dados gerados pelos modelos foram, bem como seu FIT correspondente, levando-se em consideração o custo-benefício computacional na escolha do  $k$  são:

Quadro 14 - RMSE e FIT dos modelos mais precisos para cada componente de radiação

	<b>Erro - RMSE</b>	<b>FIT</b>
<b>Radiação Extraterrestre Normal</b>	ARX(4,4,2) – 2,51%	97,33%
<b>Radiação Infravermelha</b>	ARX(4,4,1) – 1,40%	79,75%
<b>Radiação Extraterrestre Horizontal</b>	ARX(3,3,2) – 7,15%	91,34%
<b>Radiação Direta Normal</b>	ARMAX(5,5,5,1) - 59,43%	51,22%
<b>Radiação Difusa Horizontal</b>	ARMAX(6,6,6,3) - 42,75%	53,83%

A utilização do RMSE coloca mais peso em grandes erros do que em pequenos (resultado do termo de cada quadratura), enfatizando, assim, dados discrepantes de maneira inconsistente com a mediana de dados de amostra. Isto explica o porquê das análises da radiação direta horizontal e da radiação difusa horizontal possuírem um RMSE tão elevado quando comparadas às outras.

Além disso, nota-se graficamente um disposição não senoidal das composições de radiação nas quais foram encontrados elevados valores de RMSE e baixos valores de FIT. Tal resultado demonstra que as modelagens lineares do tipo ARX ou ARMAX funciona bem para bancos de dados de variáveis que variam de forma cíclica, como se fosse uma composição de senos e cossenos.

Para trabalhos futuros sugere-se a adição de outros estimadores, a fim de compará-los com os resultados obtidos utilizando-se os modelos ARX e ARMAX.

### 3.6 Referências Bibliográficas

- AGUIRRE, L. A.; Introdução à identificação de sistemas, 3ª ed.; Editora UFMG, Belo Horizonte, Brasil, 2007.
- CAMACHO, E. F., & BORDON, C. (1999). Particle swarm optimization based predictive control of proton exchange membrane fuel cell. *Journal of Zhejiang University-SCIENCE A*. March 2006, Volume 7, Issue 3, pp 458–462.
- FROISY, J. B.; Model predictive control—building a bridge between theory and practice. *Computer and Chemical Engineering*, 30(10–12), 1426–1435. 2006.
- JORGENSEN, J. B.; HUUSOM, J. K.; RAWLINGS, J. B.; Finite horizon MPC for systems in innovation form. 2011 50th IEEE Conference on Decision and Control and European Control Conference (CDC-ECC) Orlando, FL, USA, December 12-15, 2011.
- LJUNG, L. (1999). *System identification, theory for the user* (2nd ed.). NJ: Prentice Hall.
- LJUNG, L., & GLAD, T. (1994). *Modelling of dynamic systems*. NJ: Prentice-Hall.
- MARTIN SANCHEZ, J. M. (1996). *Adaptive predictive control: From the concepts to plan optimization*. NJ: Prentice Hall.
- MOURA, F. A.; MONTINI, A. A.; Aplicação do Modelo ARX para Previsão do Consumo Industrial de Energia Elétrica do Brasil. *FACEF Pesquisa: Desenvolvimento e Gestão*, v.15, n.2 - p.192-206 – mai/jun/jul/ago. São Paulo. 2012.
- MUSTAFARAJ, G.; CHEN, J.; LOWRY, G.; Development of room temperature and relative humidity linear parametric models for an open office using BMS data. *Energy and Buildings* 42 (2010) 348–356.
- RAMAMURTHI, Y., SISTU, P. B., & BEQUETTE, B. W. (1993). Control relevant dynamic data reconciliation and parameter estimation. *Computers and*

Chemical Engineering, 17, 41–59.

RICHALET, J. (1993). Industrial applications of model based predictive control. *Automatica*, 19(5), 1251–1274.

SANCHEZ, J. M., & RODELLAR, J. (2005). Adaptive predictive expert control. Methodology, design, and application. Madrid: UNED.

SHAKOURI, G. H.; RADMANESH, H. R.; Identification of a continuous time nonlinear state space model for the external power system dynamic equivalent by neural network,” *Electrical Power and Energy Systems*, vol. 31, pp. 334-344, 2009.

SHUMWAY, R. H.; STOFFER, D. S. Time series analysis and its applications with R examples. Springer: New York, 2006.

SUGANTHI, L.; SAMUEL, A. A.; Energy models for demand forecasting—A review. *Renewable and Sustainable Energy Reviews* 16 (2012) 1223–1240.

VASQUEZ, J. R. R.; PEREZ, R. R.; MORIANO, J. S.; GONZALEZ, J. R. P.; System identification of steam pressure in a fire-tube boiler. *Computers and Chemical Engineering* 32 (2008) 2839–2848.

## **Capítulo 4 - Modelagem não-linear (Redes Neurais Artificiais)**

### **4.1 Introdução**

As redes neurais artificiais consistem em um modo de abordar a solução de problemas de inteligência artificial. Deste modo, ao invés de tentar programar um computador a fim de imitar um comportamento inteligente (saber jogar xadrez, traduzir línguas estrangeiras, resolver problemas de matemática, dentre outros), procura-se construir um computador que tenha circuitos modelando os circuitos cerebrais. Assim, é esperado um comportamento inteligente que consiste no aprendizado de novas tarefas, errando, fazendo generalizações e descobertas, e frequentemente ultrapassando seu “professor” (BARRETO, 2002; KALOGIROU, 2000).

### **4.2 Breve Histórico**

Segundo Barreto (1997), é possível dividir as fases da história da inteligência artificial em períodos baseados em marcos científicos nesta área.

A primeira fase foi até 1875, nada se conhecia sobre mecanismos da mente sob os pontos de vista fisiológico e psicológico. Neste momento da história, o italiano Camillo Golgi visualizou o neurônio (Nobel, 1998). Assim, objetivou-se criar mecanismos de precisão como autômatos e outros mecanismos baseados em teares. As maiores limitações foram relativas à alta complexidade dos mecanismos que ocasionava dificuldades construtivas dos sistemas (BARRETO, 2002).

A segunda fase foi entre 1875 e 1943. Nesta época fortaleceu-se significativamente a lógica formal (Russell, Gödel, dentre outros) e passou-se a reconhecer o cérebro como órgão responsável pela inteligência. Nesta época, o matemático David Hilbert (1862-1943) idealizou um mundo no qual tudo poderia ser reduzido à lógica, questionando os limites fundamentais para o poder dos procedimentos de comprovação efetiva. Isto fica claro em sua proposição dos 23 “Problemas Insolucionáveis de Hilbert” (RUSSELL e NORVIG, 1995). Entretanto, assim como no final do século XIX viu-se o desmoronamento do mundo Euclidiano, Gödel abalou o mundo de Hilbert com seu teorema da incompletude da aritmética. Foi neste período em que estabeleceram-se as

bases da IAS (Inteligência Artificial Simbólica) e da IAC (Inteligência Artificial Conexionista), culminando com a publicação do trabalho de McCulloch & Pitts (1943). Este período foi marcado pelo surgimento da Psicanálise. Entretanto, o fator limitante para os estudos relacionados à Inteligência Artificial desta época foi a distância entre as conquistas da psicologia e da neurofisiologia (RUSSELL & NORVIG, 1995).

A terceira fase ocorreu entre 1943 e 1956. Nesse período houve o nascimento da Cibernética e desenvolvimento dos primeiros programas imitando funcionamento de redes de neurônios e comportamento inteligente. A maior barreira dessa época foi a limitação dos recursos computacionais (BARRETO, 2002).

A quarta fase ocorreu entre 1956 e 1969 e foi marcada pelo interesse dos grandes fabricantes de computadores interessados em vender suas máquinas para aplicações de escritório. O grande objetivo desta fase foi expandir ao máximo as aplicações da IA (Inteligência Artificial) tanto usando a abordagem simbólica quanto a conexionista. A maior limitação foram as dificuldades em técnicas de aprendizado de redes complexas (BARRETO, 2002).

Na quinta fase (1969-1981) houve a paralização de quase todas as pesquisas em IA por falta de verbas. Esta “Idade Média” acabou em outubro de 1981, quando os japoneses anunciaram seus planos para a Quinta Geração de Computadores e, em outro ambiente, quando *Hopfield* publica seu célebre artigo sobre redes neurais (HOPFIELD, 1982). Uma característica importante é que o renascimento da IA simbólica ocorreu em ambiente de computação e o de redes neurais em um ambiente interdisciplinar. Nesta época, nasceram também as primeiras aplicações dos conjuntos nebulosos de *Zadeh* (1965) e o controle inteligente com *Mamdani* (KING & MAMDANI, 1977; MAMDANI, 1974). Além disso os sistemas especialistas firmaram-se com *Shortliffe* (1974). A maior limitação desta época foi a falta de interesses econômicos voltados à IA (Barreto, 2002).

Entre 1981 e 1987 iniciou-se a corrida para a IA (sexta fase). Os resultados obtidos nas épocas anteriores atingiram o público em geral. Sistemas especialistas foram popularizados. Em 1987 ocorreu em São Francisco (Califórnia) a primeira conferência de redes neurais em tempos modernos, a *IEEE International Conference on Neural Networks*, e também foi formada a *International Neural Networks Society* (INNS). A partir destes acontecimentos

decorreram a fundação do *INNS journal* em 1989, seguido do *Neural Computation* e do *IEEE Transactions on Neural Networks* em 1990 (HAYKIN, 2001).

A última fase compreende o fim da sexta fase e os tempos atuais. Logo no início deste período, *Gallant* (1988) publica seu célebre artigo sobre sistemas especialistas conexionistas. Foi o ponto de partida para a união das duas abordagens de IA (simbólica e conexionista). Desde então, a inteligência artificial vem sendo usada nas mais diversas áreas: tomografia, pesquisas em campos de petróleo, bases de dados inteligentes, dentre muitas outras (BARRETO, 2002).

### **4.3 Redes Neurais Artificiais**

Redes Neurais Artificiais são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência. Uma grande rede neural artificial pode ter centenas ou milhares de unidades de processamento, enquanto o cérebro de um mamífero pode ter muitos bilhões de neurônios (HAYKIN, 2001; RUSSELL & NORVIG, 1995; BRAGA, 2000).

O sistema nervoso é formado por um conjunto extremamente complexo de células, os neurônios. Eles têm um papel essencial na determinação do funcionamento e comportamento do corpo humano e do raciocínio. Os neurônios são formados pelos dendritos, que são um conjunto de terminais de entrada, pelo corpo central, e pelos axônios que são longos terminais de saída, conforme pode ser observado na Figura 4.1 (HAYKIN, 2001; RUSSELL & NORVIG, 1995; BRAGA, 2000).

Os neurônios se comunicam através de sinapses. Sinapse é a região onde dois neurônios entram em contato e através da qual os impulsos nervosos são transmitidos entre eles. Os impulsos recebidos por um neurônio A, em um determinado momento, são processados, e atingindo um dado limiar de ação, o neurônio A dispara, produzindo uma substância neurotransmissora que flui do corpo celular para o axônio, que pode estar conectado a um dendrito de um outro neurônio B. O neurotransmissor pode diminuir ou aumentar a polaridade da membrana pós-sináptica, inibindo ou excitando a geração dos pulsos no neurônio B. Este processo depende de vários fatores, como a geometria da

sinapse e o tipo de neurotransmissor (HAYKIN, 2001; BRAGA, 2000; YANG et al., 2007).




Figura 4.1 - Representação de um neurônio biológico. Fonte: BARRETO, 2002.

#### 4.3.1 Características das RNA's

Uma rede neural artificial é composta por várias unidades de processamento, cujo funcionamento é bastante simples. Essas unidades, geralmente são conectadas por canais de comunicação que estão associados a determinado peso. As unidades fazem operações apenas sobre seus dados locais, que são entradas recebidas pelas suas conexões. O comportamento inteligente de uma Rede Neural Artificial vem das interações entre as unidades de processamento da rede (YANG et al., 2007; LI & SHI, 2010).

Segundo Braga (2000), a operação de uma unidade de processamento, proposta por *McCulloch & Pitts* em 1943 (Figura 4.2), pode ser resumida da seguinte maneira:

- Sinais são apresentados à entrada;
- Cada sinal é multiplicado por um número, ou peso, que indica a sua influência na saída da unidade;
- É feita a soma ponderada dos sinais que produz um nível de atividade;
- Se este nível de atividade exceder certo limite (threshold) a unidade produz uma determinada resposta de saída.

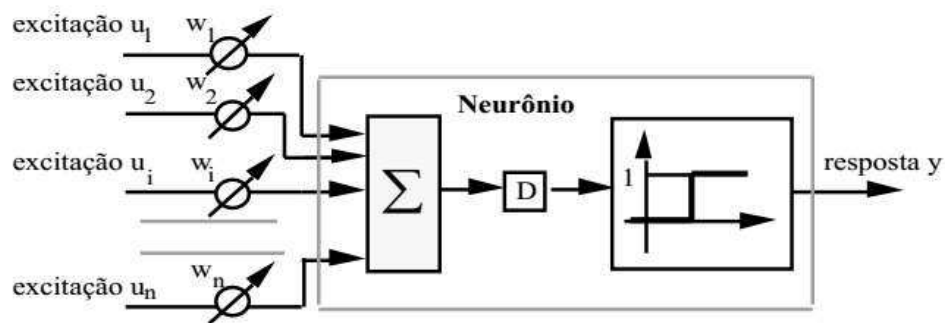


Figura 4.2 - Modelo de McCulloch & Pitts. Fonte: BARRETO, 2002.

A maioria dos modelos de redes neurais possui alguma regra de treinamento, onde os pesos de suas conexões são ajustados de acordo com os padrões apresentados. Em outras palavras, elas aprendem através de exemplos.

Arquiteturas neurais são tipicamente organizadas em camadas, com unidades que podem estar conectadas às unidades da camada posterior, conforme pode ser observado na Figura 4.3. Usualmente as camadas são classificadas em três grupos (HAYKIN, 2001; RUSSELL & NORVIG, 1995; BRAGA, 2000):

- Camada de entrada: onde os padrões são apresentados à rede;
- Camadas intermediárias ou escondidas: onde é feita a maior parte do processamento, através das conexões ponderadas; podem ser consideradas como extratoras de características; e
- Camada de saída: onde o resultado final é concluído e apresentado.




Figura 4.3 - Rede Neural Artificial

Uma rede neural é especificada, principalmente pela sua topologia, pelas características dos nós e pelas regras de treinamento. A seguir, serão analisados os processos de aprendizado.

#### **4.3.2 Processos de Aprendizado**

A propriedade mais importante das redes neurais é a habilidade de aprender de seu ambiente e com isso melhorar seu desempenho. Isso é feito através de um processo iterativo de ajustes aplicado a seus pesos: o treinamento. O aprendizado ocorre quando a rede neural atinge uma solução generalizada para uma classe de problemas (HAYKIN, 2001; RUSSELL & NORVIG, 1995; BRAGA, 2000).

Denomina-se algoritmo de aprendizado a um conjunto de regras bem definidas para a solução de um problema de aprendizado. Existem muitos tipos de algoritmos de aprendizado específicos para determinados modelos de redes neurais, estes algoritmos diferem entre si principalmente pelo modo como os pesos são modificados (HAYKIN, 2001; RUSSELL & NORVIG, 1995; BRAGA, 2000).

Outro fator importante é a maneira pela qual uma rede neural se relaciona com o ambiente. Nesse contexto existem os seguintes paradigmas de aprendizado:

- Aprendizado Supervisionado, quando é utilizado um agente externo que indica à rede a resposta desejada para o padrão de entrada;
- Aprendizado Não Supervisionado (auto-organização), quando não existe um agente externo indicando a resposta desejada para os padrões de entrada;
- Reforço, quando um crítico externo avalia a resposta fornecida pela rede.

Denomina-se ciclo uma apresentação de todos os N pares (entrada e saída) do conjunto de treinamento no processo de aprendizado. A correção dos pesos num ciclo pode ser executada de dois modos (HAYKIN, 2001; RUSSELL

& NORVIG, 1995; BRAGA, 2000):

- 1) Modo Padrão: A correção dos pesos acontece a cada apresentação à rede de um exemplo do conjunto de treinamento. Cada correção de pesos baseia-se somente no erro do exemplo apresentado naquela iteração. Assim, em cada ciclo ocorrem N correções.
- 2) Modo Batch: Apenas uma correção é feita por ciclo. Todos os exemplos do conjunto de treinamento são apresentados à rede, seu erro médio é calculado e a partir deste erro fazem-se as correções dos pesos.

#### 4.4 Metodologia

A ferramenta utilizada para o reconhecimento de padrão das imagens em questão foram as Redes Neurais Artificiais.

Com o auxílio do software Matlab foi utilizada uma rede neural do tipo MLP (*Multilayer Perceptron*) para a solução da classificação. Este tipo de rede opera numa sequência de dois passos durante o treinamento com o algoritmo *backpropagation*.

A rede do tipo MLP trata-se de uma rede neural que possui mais de uma camada de neurônios. Em casos em que não há a possibilidade de uma única reta separar os elementos, há o uso da MLP que, gera mais de uma reta classificadora. O aprendizado nesse tipo de rede geralmente é por meio do algoritmo de retropropagação do erro (*backpropagation*), mas existem outros algoritmos para este fim.

Cada camada da rede tem uma função específica. A camada de saída recebe os estímulos da camada intermediária e constrói a resposta.

Inicialmente a camada de entrada da rede recebe um padrão. Em seguida o resultado flui através da rede, camada por camada até que seja produzida uma resposta na camada de saída. Na segunda etapa, a saída obtida é comparada a saída desejada para o padrão em particular.

O erro sofre propagação a partir da camada de saída até a camada de entrada, e os pesos das conexões das unidades das camadas internas são modificados conforme o erro é retropropagado pela rede, conforme esquematizado na **Erro! Fonte de referência não encontrada.**

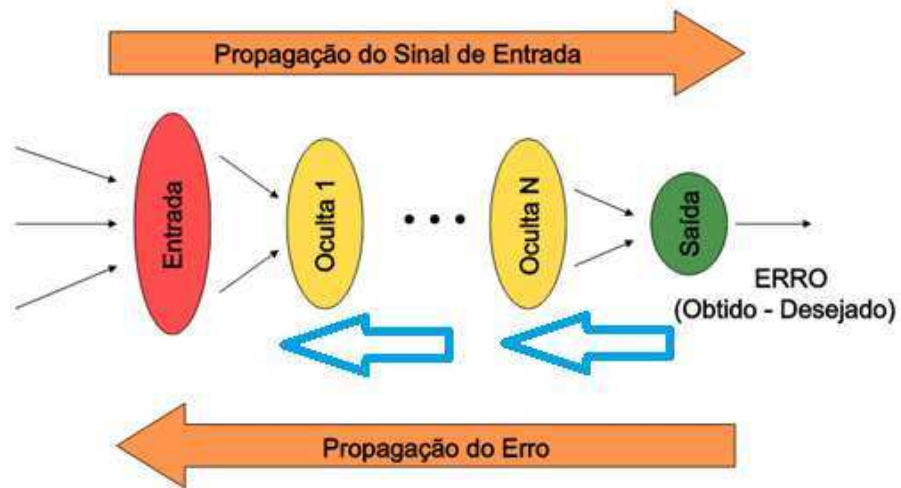


Figura 4.4 - Treinamento da rede neural com propagação de erro em direção à entrada (backpropagation).

#### 4.5 Resultados e Discussão

Para definição da base dados, foi calculada a distribuição de temperatura ao longo dos anos em análise, e assim definidas faixas de temperatura de acordo com a frequência de ocorrência. Uma vez que dispõe-se de valores de medidas de radiação para cada medida horária de temperatura, pode-se supor que ao dividir as temperaturas em faixas, tais faixas podem ser relacionadas aos valores de radiação.

Na Figura 4.5 tem-se o histograma com a distribuição de temperatura do banco de dados.




Figura 4.5 - Histograma da distribuição de temperatura do banco de dados de 2006 a 2011.

Deste modo, utilizou-se a distribuição de temperatura como referência para se encontrar uma correlação entre as faixas de temperatura definidas no trabalho e os valores de cada composição de radiação correspondentes. Pode-se observar ainda, por meio das Figuras 4.6 e 4.10 os histogramas com as distribuições de cada composição de radiação no banco de dados utilizado.

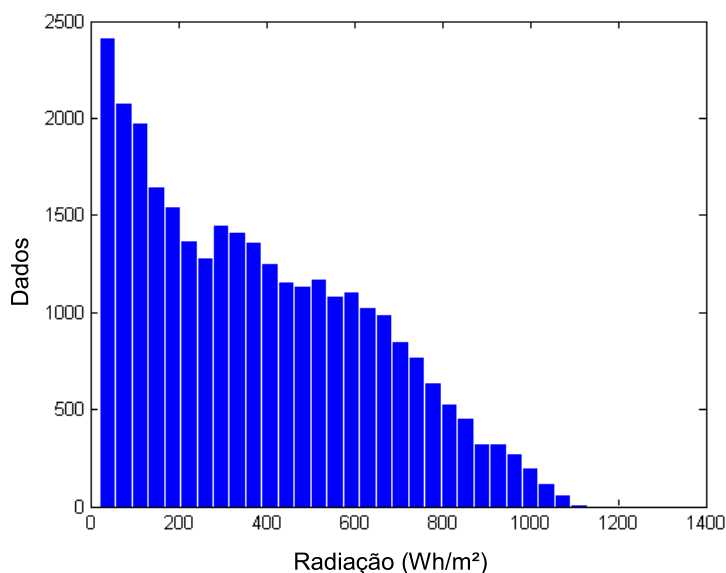


Figura 4.6 - Histograma da distribuição de radiação global horizontal do banco de dados.




Figura 4.7 - Histograma da distribuição de radiação extraterrestre horizontal do banco de dados.




Figura 4.8 - Histograma da distribuição de radiação extraterrestre normal do banco de dados.




Figura 4.9 - Histograma da distribuição de radiação direta normal do banco de dados.




Figura 4.10 - Histograma da distribuição de radiação difusa horizontal do banco de dados.

Quadro 15 - Índices atribuídos às faixas de temperatura

<b>Faixa de Temperatura (°C)</b>	<b>Índice Atribuído</b>
<b>4,0 - 8,0</b>	1
<b>8,1 - 12,0</b>	2
<b>12,1 - 16,0</b>	3
<b>16,1 - 18,0</b>	4
<b>18,1 - 20,0</b>	5
<b>20,1 - 22,0</b>	6
<b>22,1 - 24,0</b>	7
<b>24,1 - 28,0</b>	8
<b>28,1 - 32,0</b>	9
<b>32,1 - 38,0</b>	10

As redes multilayer perceptron (MLP) foram aplicadas desempenhando a tarefa de classificação de padrões. Foram criadas duas camadas de rede feed-forward. A primeira camada utilizou a função de transferência tangente hiperbólica e, a segunda camada utilizou a função de transferência linear.

Nesta etapa do trabalho, a utilização de redes neurais artificiais parte do princípio de que haja uma relação não-linear entre temperatura e radiação, uma vez que para estimação de radiação são necessárias outras variáveis além da temperatura.

Deste modo, todo o banco de dados de temperatura foi classificado conforme a Quadro 15 e utilizado como saída da rede. Cada composição de radiação foi utilizada como entrada separadamente, com a finalidade de realizar a análise estatística de cada uma separadamente.

A princípio esperava-se realizar uma análise na qual a temperatura fosse a variável de entrada e as composições de radiação as saídas. Isto não foi possível, pois durante as simulações constatou-se a necessidade de um banco de dados muito maior para a criação de índices para classificar faixas de radiação. Em termos de intervalos, é mais simples criar pequenos intervalos para uma variável com menor ordem de grandeza, como é o caso da temperatura, uma vez que demanda um volume menor de dados de entrada e saída para classificação, e deste modo caracterizar o comportamento do sistema. A relação de entradas e saídas pode ser vista no Quadro 17.

Esta análise pode ser matematicamente justificada com base na correlação entre a temperatura e cada composição de radiação. O cálculo é feito

por meio do coeficiente de correlação de Pearson ( $\rho$ ), que mede o grau da correlação linear entre duas variáveis quantitativas, conforme a Equação 3.1. No Quadro 16 pode-se observar a correlação entre a temperaturas e cada tipo de radiação.

$$\rho = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{(\sum(x_i - \bar{x})^2)(\sum(y_i - \bar{y})^2)}} \quad (3.1)$$

em que  $x$  e  $y$  são as variáveis a ser correlacionadas.

Quadro 16 – Correlação entre cada composição de radiação e temperaturas do banco de dados

		<b>Correlação (%)</b>
<b>Radiação Extraterrestre Horizontal</b>	Temperatura	63,02
<b>Radiação Extraterrestre Normal</b>	Temperatura	59,57
<b>Radiação Infravermelha Horizontal</b>	Temperatura	99,37
<b>Radiação Global Horizontal</b>	Temperatura	69,11
<b>Radiação Direta Normal</b>	Temperatura	56,76
<b>Radiação Difusa Horizontal</b>	Temperatura	61,15

Quadro 17 - Entradas e saídas da rede neural

<b>Entrada x(t)</b>	<b>Saída y(t)</b>
<b>Radiação Extraterrestre Horizontal</b>	Índice de Temperaturas
<b>Radiação Extraterrestre Normal</b>	Índice de Temperaturas
<b>Radiação Infravermelha Horizontal</b>	Índice de Temperaturas
<b>Radiação Global Horizontal</b>	Índice de Temperaturas
<b>Radiação Direta Normal</b>	Índice de Temperaturas
<b>Radiação Difusa Horizontal</b>	Índice de Temperaturas

Além disso, variou-se o número de neurônios da camada escondida de 1 a 10, a fim de se verificar para qual valor haveria maior taxa de acerto do modelo. A parametrização do modelo teve como referência medidas de temperatura e de radiação.

O conjunto de dados utilizados dispõe de 62992 valores medidos para cada variável, dos quais 90% foram utilizados para treinamento da rede e 10% para validação.

Os resultados da análise estatística podem ser observados nos Quadros Quadro 18 a Quadro 27. Cada quadro apresenta a análise estatística para um determinado número de neurônios na camada escondida ( $N_e$ ) de 1 a 10.

Em geral, o desvio padrão do conjunto de dados gerados não se aproximou do desvio padrão do banco de dados utilizado na validação de maneira proporcional à taxa de acerto. A simulação que gerou menor grau de acerto, 74,48%, foi a que utilizou a radiação global horizontal como entrada e 3 neurônios na camada escondida. A que apresentou maior taxa de acerto, 90,32%, foi a que utilizou radiação infravermelha horizontal como entrada e 2 neurônios na camada escondida.

Outro fator que dificultou a classificação por meio das redes neurais foi a sazonalidade do banco de dados. O que torna o tamanho do banco de dados um fator limitante é o comportamento das componentes de radiação ao longo do ano. Tendo em vista quatro estações no ano, é necessário um volume de dados maior, a fim gerar um quantidade maior de padrões para classificação. Tais padrões são proveniente dos ciclos anuais de dados.

O banco de dados da radiação global horizontal pode ser visto na Figura 4.11, e assim pode-se observar a sazonalidade dos dados e concluir que ocorrem poucos ciclos, pelo fato de se possuir poucos anos de banco de dados.

Quadro 18 - Análise estatística  $N_e = 1$

Radiação Extraterrestre Horizontal			Radiação Global Horizontal		
Acerto = 78,92%	Saída para Validação	Saída da Rede	Acerto = 77,40%	Saída para Validação	Saída da Rede
Desvio Padrão	1,9828	1,4763	Desvio Padrão	1,9828	1,2484
Variância	3,9313	2,1794	Variância	3,9313	1,5586
Radiação Extraterrestre Normal			Radiação Direta Normal		
Acerto = 79,02%	Saída para Validação	Saída da Rede	Acerto = 77,41%	Saída para Validação	Saída da Rede
Desvio Padrão	1,9828	1,4455	Desvio Padrão	1,9828	1,1758
Variância	3,9313	2,0895	Variância	3,9313	1,3825
Radiação Infravermelha Horizontal			Radiação Difusa Horizontal		
Acerto = 83,41%	Saída para Validação	Saída da Rede	Acerto = 82,51%	Saída para Validação	Saída da Rede
Desvio Padrão	1,9828	1,4123	Desvio Padrão	1,9828	1,7536
Variância	3,9313	1,9946	Variância	3,9313	3,0751

Quadro 19 - Análise estatística  $N_e = 2$

Radiação Extraterrestre Horizontal			Radiação Global Horizontal		
Acerto = 78,02%	Saída para Validação	Saída da Rede	Acerto = 77,36%	Saída para Validação	Saída da Rede
Desvio Padrão	1,9828	1,4318	Desvio Padrão	1,9828	1,2491
Variância	3,9313	2,0500	Variância	3,9313	1,5603
Radiação Extraterrestre Normal			Radiação Direta Normal		
Acerto = 76,31%	Saída para Validação	Saída da Rede	Acerto = 76,34%	Saída para Validação	Saída da Rede
Desvio Padrão	1,9828	1,4943	Desvio Padrão	1,9828	1,2006
Variância	3,9313	2,2328	Variância	3,9313	1,4416
Radiação Infravermelha Horizontal			Radiação Difusa Horizontal		
Acerto = 90,32%	Saída para Validação	Saída da Rede	Acerto = 82,81%	Saída para Validação	Saída da Rede
Desvio Padrão	1,9828	1,6972	Desvio Padrão	1,9828	2,8321
Variância	3,9313	2,8805	Variância	3,9313	8,0209

Quadro 20 - Análise estatística  $N_e = 3$

<b>Radiação Extraterrestre Horizontal</b>			<b>Radiação Global Horizontal</b>		
<b>Acerto = 76,50%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>	<b>Acerto = 74,48%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>
<b>Desvio Padrão</b>	1,9828	1,4674	<b>Desvio Padrão</b>	1,9828	1,4670
<b>Variância</b>	3,9313	2,1532	<b>Variância</b>	3,9313	2,1520
<b>Radiação Extraterrestre Normal</b>			<b>Radiação Direta Normal</b>		
<b>Acerto = 76,94%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>	<b>Acerto = 75,58%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>
<b>Desvio Padrão</b>	1,9828	1,4462	<b>Desvio Padrão</b>	1,9828	1,2499
<b>Variância</b>	3,9313	2,0914	<b>Variância</b>	3,9313	1,5623
<b>Radiação Infravermelha Horizontal</b>			<b>Radiação Difusa Horizontal</b>		
<b>Acerto = 81,59%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>	<b>Acerto = 79,87%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>
<b>Desvio Padrão</b>	1,9828	1,3037	<b>Desvio Padrão</b>	1,9828	1,8672
<b>Variância</b>	3,9313	1,6997	<b>Variância</b>	3,9313	3,4865

Quadro 21 - Análise estatística  $N_e = 4$

<b>Radiação Extraterrestre Horizontal</b>			<b>Radiação Global Horizontal</b>		
<b>Acerto = 77,04%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>	<b>Acerto = 79,67%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>
<b>Desvio Padrão</b>	1,9828	1,4340	<b>Desvio Padrão</b>	1,9828	1,7165
<b>Variância</b>	3,9313	2,0564	<b>Variância</b>	3,9313	2,9465
<b>Radiação Extraterrestre Normal</b>			<b>Radiação Direta Normal</b>		
<b>Acerto = 76,50%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>	<b>Acerto = 76,80%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>
<b>Desvio Padrão</b>	1,9828	1,4924	<b>Desvio Padrão</b>	1,9828	1,1325
<b>Variância</b>	3,9313	2,2271	<b>Variância</b>	3,9313	1,2826
<b>Radiação Infravermelha Horizontal</b>			<b>Radiação Difusa Horizontal</b>		
<b>Acerto = 85,85%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>	<b>Acerto = 84,63%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>
<b>Desvio Padrão</b>	1,9828	1,3527	<b>Desvio Padrão</b>	1,9828	13,8960
<b>Variância</b>	3,9313	1,8297	<b>Variância</b>	3,9313	193,0998

Quadro 22 - Análise estatística  $N_e = 5$

Radiação Extraterrestre Horizontal			Radiação Global Horizontal		
Acerto = 76,98%	Saída para Validação	Saída da Rede	Acerto = 75,28%	Saída para Validação	Saída da Rede
Desvio Padrão	1,9828	1,4508	Desvio Padrão	1,9828	1,3561
Variância	3,9313	2,1050	Variância	3,9313	1,8389
Radiação Extraterrestre Normal			Radiação Direta Normal		
Acerto = 77,52%	Saída para Validação	Saída da Rede	Acerto = 76,74%	Saída para Validação	Saída da Rede
Desvio Padrão	1,9828	1,4826	Desvio Padrão	1,9828	1,1180
Variância	3,9313	2,1981	Variância	3,9313	1,2500
Radiação Infravermelha Horizontal			Radiação Difusa Horizontal		
Acerto = 84,96%	Saída para Validação	Saída da Rede	Acerto = 79,75%	Saída para Validação	Saída da Rede
Desvio Padrão	1,9828	2,2332	Desvio Padrão	1,9828	6,3314
Variância	3,9313	4,9872	Variância	3,9313	40,0871

Quadro 23 - Análise estatística  $N_e = 6$

Radiação Extraterrestre Horizontal			Radiação Global Horizontal		
Acerto = 78,04%	Saída para Validação	Saída da Rede	Acerto = 78,31%	Saída para Validação	Saída da Rede
Desvio Padrão	1,9828	1,4583	Desvio Padrão	1,9828	3,8005
Variância	3,9313	2,1266	Variância	3,9313	14,4442
Radiação Extraterrestre Normal			Radiação Direta Normal		
Acerto = 80,17%	Saída para Validação	Saída da Rede	Acerto = 76,88%	Saída para Validação	Saída da Rede
Desvio Padrão	1,9828	1,6264	Desvio Padrão	1,9828	1,1344
Variância	3,9313	2,6450	Variância	3,9313	1,2869
Radiação Infravermelha Horizontal			Radiação Difusa Horizontal		
Acerto = 84,13%	Saída para Validação	Saída da Rede	Acerto = 83,94%	Saída para Validação	Saída da Rede
Desvio Padrão	1,9828	1,7054	Desvio Padrão	1,9828	12,9863
Variância	3,9313	2,9085	Variância	3,9313	168,6444

Quadro 24 - Análise estatística  $N_e = 7$

Radiação Extraterrestre Horizontal			Radiação Global Horizontal		
<b>Acerto = 77,24%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>	<b>Acerto = 80,49%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>
<b>Desvio Padrão</b>	1,9828	1,4576	<b>Desvio Padrão</b>	1,9828	2,5067
<b>Variância</b>	3,9313	2,1247	<b>Variância</b>	3,9313	6,2833
Radiação Extraterrestre Normal			Radiação Direta Normal		
<b>Acerto = 77,04%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>	<b>Acerto = 80,92%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>
<b>Desvio Padrão</b>	1,9828	1,5773	<b>Desvio Padrão</b>	1,9828	3,8708
<b>Variância</b>	3,9313	2,4879	<b>Variância</b>	3,9313	14,9834
Radiação Infravermelha Horizontal			Radiação Difusa Horizontal		
<b>Acerto = 86,13%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>	<b>Acerto = 84,41%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>
<b>Desvio Padrão</b>	1,9828	2,1363	<b>Desvio Padrão</b>	1,9828	7,9497
<b>Variância</b>	3,9313	4,5638	<b>Variância</b>	3,9313	63,1982

Quadro 25 - Análise estatística  $N_e = 8$

Radiação Extraterrestre Horizontal			Radiação Global Horizontal		
<b>Acerto = 79,91%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>	<b>Acerto = 81,85%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>
<b>Desvio Padrão</b>	1,9828	1,7253	<b>Desvio Padrão</b>		4,6108
<b>Variância</b>	3,9313	2,9767	<b>Variância</b>		21,2592
Radiação Extraterrestre Normal			Radiação Direta Normal		
<b>Acerto = 77,94%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>	<b>Acerto = 82,47%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>
<b>Desvio Padrão</b>	1,9828	1,6104	<b>Desvio Padrão</b>	1,9828	10,6096
<b>Variância</b>	3,9313	2,5935	<b>Variância</b>	3,9313	112,5639
Radiação Infravermelha Horizontal			Radiação Difusa Horizontal		
<b>Acerto = 85,68%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>	<b>Acerto = 84,46%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>
<b>Desvio Padrão</b>	1,9828	1,3195	<b>Desvio Padrão</b>	1,9828	9,6686
<b>Variância</b>	3,9313	1,7411	<b>Variância</b>	3,9313	93,4819

Quadro 26 - Análise estatística  $N_e = 9$

<b>Radiação Extraterrestre Horizontal</b>			<b>Radiação Global Horizontal</b>		
<b>Acerto = 76,74%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>	<b>Acerto = 81,59%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>
<b>Desvio Padrão</b>	1,9828	1,5653	<b>Desvio Padrão</b>	1,9828	4,2158
<b>Variância</b>	3,9313	2,4502	<b>Variância</b>	3,9313	17,7730
<b>Radiação Extraterrestre Normal</b>			<b>Radiação Direta Normal</b>		
<b>Acerto = 79,29%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>	<b>Acerto = 84,21%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>
<b>Desvio Padrão</b>	1,9828	1,8554	<b>Desvio Padrão</b>	1,9828	27,6532
<b>Variância</b>	3,9313	3,4426	<b>Variância</b>	3,9313	764,7017
<b>Radiação Infravermelha Horizontal</b>			<b>Radiação Difusa Horizontal</b>		
<b>Acerto = 88,54%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>	<b>Acerto = 84,82%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>
<b>Desvio Padrão</b>	1,9828	1,4049	<b>Desvio Padrão</b>	1,9828	8,8392
<b>Variância</b>	3,9313	1,9738	<b>Variância</b>	3,9313	78,1313

Quadro 27 - Análise estatística  $N_e = 10$

<b>Radiação Extraterrestre Horizontal</b>			<b>Radiação Global Horizontal</b>		
<b>Acerto = 76,78%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>	<b>Acerto = 83,40%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>
<b>Desvio Padrão</b>	1,9828	1,7688	<b>Desvio Padrão</b>	1,9828	3,3345
<b>Variância</b>	3,9313	3,1286	<b>Variância</b>	3,9313	11,1191
<b>Radiação Extraterrestre Normal</b>			<b>Radiação Direta Normal</b>		
<b>Acerto = 80,63%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>	<b>Acerto = 83,71%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>
<b>Desvio Padrão</b>	1,9828	1,4872	<b>Desvio Padrão</b>	1,9828	37,8701
<b>Variância</b>	3,9313	2,2116	<b>Variância</b>	3,9313	1,434,1415
<b>Radiação Infravermelha Horizontal</b>			<b>Radiação Difusa Horizontal</b>		
<b>Acerto = 90,28%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>	<b>Acerto = 84,70%</b>	<b>Saída para Validação</b>	<b>Saída da Rede</b>
<b>Desvio Padrão</b>	1,9828	3,2304	<b>Desvio Padrão</b>	1,9828	9,5427
<b>Variância</b>	3,9313	10,4356	<b>Variância</b>	3,9313	91,0636




Figura 4.11 - Radiação Global Horizontal

## 4.6 Considerações Finais

Utilizou-se a análise estatística dos dados para validação e dos dados de saída da rede como parâmetro, pois a temperatura e a radiação são variáveis no tempo. Uma análise pontual destas variáveis demandaria uma análise estocástica com abordagem mais profunda e complexa do que a realizada neste trabalho.

O banco de dados disponível foi pequeno, tanto pela necessidade de classificação de faixas de radiação para a determinação de entradas e saídas nas redes neurais, quanto pela necessidade de mais ciclos de dados a fim de se determinar padrões de sazonalidade.

A correlação independe de qual variável será utilizada como entrada ou saída. Isto significa que a análise feita neste trabalho se justifica pelo fato de mostrar ser viável a aplicação de um banco de dados maior para um tratamento de dados que permita que a radiação seja obtida como saída do sistema.

#### 4.7 Referências Bibliográficas

- ANTOSZCZYSZYN, P. M., Hannah, J. M., Grant, P. M. "Tracking of the motion of important facial features in model-based coding". *Signal Processing* 66, (1998).
- BARRETO, J. M. Introdução às redes neurais artificiais. In V Escola Regional de Informática. Sociedade Brasileira de Computação, Regional Sul, Santa Maria, Florianópolis, Maringá, 5-10/05 1997, p. 41–71.
- BARRETO, J. M. Introdução às Redes Neurais Artificiais. Laboratório de Conexionismo e Ciências Cognitivas UFSC -Departamento de Informática e de Estatística. Florianópolis, SC. 2002
- BRAGA, A. P., Carvalho, A. C. P. L. F., Ludermir, T. B. "Redes Neurais Artificiais: Teoria e Aplicações". Ed. LTC, (2000).
- FERREIRA, D. F. (1996). *Análise Multivariada*. 1 ed. UFLA, Lavras – MG.
- GALLANT, S. Connectionist expert systems. *Communications of the ACM Association for Computing Machinery*. V. 31.1, 2 (1988).
- HAYKIN, S.. *Redes neurais: princípios e prática*. trad. Paulo Martins Engel. - 2.ed. - Porto Alegre: Bookman, 2001.
- HOPFIELD, J. Neural Networks and Physical Systems with Emergent Collectives Computational Abilities. *Proceedings of the National Academy of Sciences* 79 (1982), 2554–2558. 1982.
- HUBEL, D. H. *The Brain*. vol. 1. Freeman, San Francisco, 1979, ch. 1, p. 2–14.
- KALOGIROU, S. A.; Applications of artificial neural-networks for energy systems; *Applied Energy* 67 (2000) 17-35.
- KING, P. & MAMDANI, E. The application of fuzzy control systems to industrial processes. *Automatica* 13 (1977), 235–242.
- LI, G.; SHI, J.; On comparing three artificial neural networks for wind speed forecasting. *Applied Energy* 87 (2010) 2313–2320

- MAMDANI, E. Application of fuzzy algorithms for control of simple dynamic plant. Proc. IEE 121, 12 (1974), 1585–88.
- MCCULLOCH, W. S. & PITTS, W. A Logical Calculus of the Ideas Immanent in Nervous Activity. Bulletin of Mathematical Biophysics 5 (1943), 115–133
- MORE, B. C., (1981). Principal Component Analysis in Linear Systems: Controllability, Observability, and Model Reduction. IEE Transactions On Automatic Control. Vol. Ac-26, No. 1, pp 17-31.
- NOBEL PRIZE. Life and Discoveries of Camillo Golgi. Nobel Media AB 1998. <[https://www.nobelprize.org/nobel\\_prizes/medicine/laureates/1906/golgi-article.html](https://www.nobelprize.org/nobel_prizes/medicine/laureates/1906/golgi-article.html)>. Acessado em: 01/06/2016 13:12 hs
- RUSSELL, S. J.; NORVIG, P. Artificial Intelligence: A Modern Approach. Prentice Hall, Englewood Cliffs, New Jersey, 1995.
- SHORTLIFFE, E. H. MYCIN: a rule-based computer program for advising physicians regarding antimicrobial therapy selection. Tese de Doutorado, Stanford University, California, 1974.
- YANG, H. J.; ROE, B. P.; ZHU, J.; Studies of stability and robustness for artificial neural networks and boosted decision trees. Nuclear Instruments and Methods in Physics Research A 574 (2007) 342–349.
- ZADEH, L. A. Fuzzy sets. Information and Control 8, 1 (January 1965), 338–353.

## Conclusões Gerais

Neste trabalho foram realizadas simulações para predição de dados de radiação solar utilizando modelos lineares (ARX e ARMAX) e modelos não-lineares (Redes Neurais). Nas análises foram realizadas abordagens diferentes: na modelagem linear foi possível gerar computacionalmente um banco de dados e analisar os dados com mais exatidão, uma vez que o banco de dados baseado em predição foi gerado ponto-a-ponto.

Com relação à modelagem linear, foram alcançados resultados satisfatórios, uma vez que foi possível realizar a estimação de dados de três das cinco componentes radiação com elevada precisão (Quadro 28).

Quadro 28 - RMSE e FIT dos modelos mais precisos para cada componente de radiação

	<b>Erro - RMSE</b>	<b>FIT</b>
<b>Radiação Extraterrestre Normal</b>	ARX(4,4,2) – 2,51%	97,33%
<b>Radiação Infravermelha</b>	ARX(4,4,1) – 1,40%	79,75%
<b>Radiação Extraterrestre Horizontal</b>	ARX(3,3,2) – 7,15%	91,34%
<b>Radiação Direta Normal</b>	ARMAX(5,5,5,1) - 59,43%	51,22%
<b>Radiação Difusa Horizontal</b>	ARMAX(6,6,6,3) - 42,75%	53,83%

Na modelagem não-linear não foi possível gerar um banco de dados de radiação, uma vez que o banco de dados utilizado neste trabalho não foi suficiente para o processo de classificação dos parâmetros de radiação. Deste modo, a saída encontrada para analisar o comportamento de uma rede neural que trabalhe com parâmetros de radiação e temperatura, foi inverter as variáveis de interesse, utilizando a radiação como entrada da rede e a temperatura como saída. Esta análise pode ser matematicamente justificada com base na correlação entre a temperatura e cada composição de radiação. A correlação independe de qual variável será utilizada como entrada ou saída. Isto significa que a análise feita neste trabalho se justifica pelo fato de mostrar ser viável a aplicação de um banco de dados maior para um tratamento de dados que permita que a radiação seja obtida como saída do sistema.

Na modelagem não-linear (Redes Neurais), a simulação que gerou menor grau de acerto, 74,48%, foi a que utilizou a radiação global horizontal como entrada e 3 neurônios na camada escondida. A que apresentou maior taxa de acerto, 90,32%, foi a que utilizou radiação infravermelha horizontal como entrada com 2 neurônios na camada escondida

Por fim, pôde-se concluir que a modelagem linear mostrou-se mais eficiente que a não-linear na predição da radiação solar abordados nesta pesquisa. Sua implementação é mais simples sob ponto de vista computacional e foi suficientemente eficiente para a geração de um banco de dados compatível com o que se desejava, apresentando erros aceitáveis e descrevendo o sistema de forma compatível com o original.

### **Sugestões para Trabalhos Futuros**

- i. Refazer as simulações utilizando um banco de dados maior;
- ii. Calcular os coeficientes dos modelos lineares, a fim de estabelecer uma única equação que descreva o sistema;
- iii. Adição de outros estimadores além do RMSE e do FIT;
- iv. Testar outros modelos de redes-neurais, variando os parâmetros de cada camada e número de neurônios das camadas escondidas, a fim de se encontrar o modelo que descreva o sistema com maior precisão; e
- v. Na posse de um banco de dados suficientemente grande, refazer a simulação da modelagem não-linear tendo a temperatura como entrada e radiação como saída.