



**UNILAB**

Universidade da Integração Internacional  
da Lusofonia Afro-Brasileira

**INSTITUTO DE ENGENHARIAS E DESENVOLVIMENTO SUSTENTÁVEL  
CURSO DE ENGENHARIA DE ENERGIAS**

**MATHEUS LUCAS MAIA DE FREITAS**

**PREVISÃO DE RADIAÇÃO UTILIZANDO IDENTIFICAÇÃO DE SISTEMAS  
LINEARES E NÃO LINEARES**

**REDENÇÃO**

**2021**

**MATHEUS LUCAS MAIA DE FREITAS**

**PREVISÃO DE RADIAÇÃO UTILIZANDO IDENTIFICAÇÃO DE SISTEMAS  
LINEARES E NÃO LINEARES**

Monografia apresentada ao curso de Engenharia de Energias do Instituto de Engenharias e Desenvolvimento Sustentável da Universidade da Integração Internacional da Lusofonia Afro-Brasileira, como requisito para obtenção do Título de Bacharel em Engenharia de Energias.

Orientador: Prof. Dr. Vandilberto Pinto

**REDENÇÃO**

**2021**

Universidade da Integração Internacional da Lusofonia Afro-Brasileira  
Sistema de Bibliotecas da UNILAB  
Catalogação de Publicação na Fonte.

---

Freitas, Matheus Lucas Maia de.

F936p

Previsão de radiação utilizando identificação de sistemas lineares e não lineares / Matheus Lucas Maia de Freitas. - Redenção, 2021.  
55f: il.

Monografia - Curso de Engenharia de Energias, Instituto de Engenharias e Desenvolvimento Sustentável, Universidade da Integração Internacional da Lusofonia Afro-Brasileira, Redenção, 2021.

Orientador: Prof. Dr. Vandilberto Pereira Pinto.

1. Sistemas lineares. 2. Sistemas não-lineares. 3. Radiação solar. I. Título

CE/UF/BSP

CDD 515.35

---

MATHEUS LUCAS MAIA DE FREITAS

PREVISÃO DE RADIAÇÃO UTILIZANDO IDENTIFICAÇÃO DE SISTEMAS  
LINEARES E NÃO LINEARES

Monografia apresentada ao curso de Engenharia de Energias do Instituto de Engenharias e Desenvolvimento Sustentável da Universidade da Integração Internacional da Lusofonia Afro-Brasileira, como requisito para obtenção do Título de Bacharel em Engenharia de Energias.

Aprovada em: 23/08/2021.

BANCA EXAMINADORA



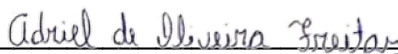
Prof. Dr. Vandilberto Pereira Pinto (Orientador)

Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB)



Prof. Dr. Antonio Alisson Pessoa Guimaraes

Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB)



Prof. Adriel de Oliveira Freitas

Serviço Nacional de Aprendizagem Industrial (SENAI)

## **AGRADECIMENTOS**

À Deus por sempre me dar forças para seguir em frente.

Ao Prof. Dr. Vandilberto Pinto, pela orientação e participação neste trabalho.

A minha família, em especial aos meus avós, à minha tia Maria que sempre me apoiou em toda a minha trajetória, minha prima Larissa, meu irmão Josean, meu pai José, minha madrasta Antônia, meus irmãos e irmãs e minha mãe Kertuilma.

Aos meus amigos, Dayane Silva, Henrique Silva, Lenira Silva, Jorge Bessa, Jorgeana Bessa, Vera Bessa, Alexandre Peixoto, André Lucas, Raiane Almeida e em especial ao meu melhor amigo Robson Almeida pela confiança e companheirismo desde sempre.

Aos meus amigos, Daniel Facó, Marcus Canutto, Simão Neto, Wladilson Martins, Patrick Silva e em especial à Inessa Guilherme e Thales Guimarães por sempre estarem ao meu lado me apoiando e contribuindo para que chegasse a esta etapa.

A todos os professores que contribuíram para que eu me desenvolvesse como pessoa e como profissional.

Aos professores participantes da banca examinadora Prof. Dr. Antonio Alisson e Prof. Adriel de Oliveira pelo tempo, pelas valiosas colaborações e sugestões.

“Vamos viver uma vida sem arrependimentos, não importa o que aconteça!” - Portgas D. Ace

## RESUMO

Com a constante preocupação mundial acerca da sustentabilidade, há a necessidade de substituir fontes não renováveis de energia por fontes renováveis. O sistema elétrico tem tido um crescimento significativo das fontes renováveis de energia em sua composição, com destaque para a energia solar e eólica. Com isso, existe a necessidade de se realizar estudos sobre o potencial de geração de uma determinada região. Uma alternativa para isso é estabelecer um método de previsão a partir de dados meteorológicos de radiação solar, que seja preciso e eficiente. O registro desse tipo de série de dados é realizado através de estações meteorológicas automáticas (EMA) ou convencionais (EMC). A identificação de sistemas representa sistemas elaborados a partir de dados de entrada e saída, através de modelos matemáticos. Utiliza-se a ferramenta MATLAB em conjunto com o *System Identification Toolbox* para a identificação de sistemas lineares (ARX e ARMAX) e não lineares (*Hammerstein-Wiener*), aplicados a um banco de dados onde é identificada a estrutura que apresenta uma melhor estimativa dos parâmetros, na qual utiliza-se uma parte dos dados para criação dos modelos e outra parte para validação. Os modelos estimados foram estudados e comparados, onde o modelo não linear *Hammerstein-Wiener* foi mais eficiente para estimativa dos modelos, pelo fato de apresentar uma maior acurácia de 99,96%, além de um melhor FPE – *Final Prediction Error* de 0,002215, enquanto os modelos discretos ARX e ARMAX apresentaram uma acurácia de 93,49% e 73,85, respectivamente. Comprovando assim, a eficácia da aplicação do método de identificação de sistemas para geração de um banco de dados compatível com o real.

**Palavras-chave:** Identificação de sistemas. System identification toolbox. Radiação.

## ABSTRACT

With the constant global concern about sustainability, the need to replace non-renewable energy sources with renewable sources. The electrical system has seen significant growth in renewable energy sources in its composition, emphasizing solar and wind energy. Thus, there is a need to carry out studies on the generation potential of a specific region. An alternative is to establish a forecasting method based on meteorological data of solar radiation, which is accurate and efficient. The recording of this type of data series is carried out through automatic (EMA) or conventional (EMC) meteorological stations. The identification of systems represents systems elaborated from input and output data, through mathematical models. The MATLAB tool is used together with the System Identification Toolbox for the identification of linear (ARX and ARMAX) and non-linear (Hammerstein-Wiener) systems, applied to a database where the structure that presents a better estimation of the parameters, in which part of the data is used to create the models and another part for validation. The estimated models were studied and compared, where the nonlinear Hammerstein-Wiener model was more efficient for estimating the models, due to its greater accuracy of 99.96%, in addition to a better FPE - Final Prediction Error of 0.002215, while the discrete models ARX and ARMAX presented an accuracy of 93.49% and 73.85, respectively. Thus, proving the effectiveness of applying the system identification method to generate a database compatible with the real

**Keywords:** Identification of systems. System identification toolbox. Radiation



## LISTA DE FIGURAS

Figura 01 - Etapas do processo de identificação de sistemas.....	21
Figura 02 - Representação do modelo ARX.....	23
Figura 03 - Representação do modelo ARMAX.....	24
Figura 04 - Representação do modelo OE.....	25
Figura 05 - Representação modelo de hammerstein.....	26
Figura 06 - Modelo de wiener.....	27
Figura 07 - Modelo de Hammerstein-Wiener.....	27
Figura 08 - Função Pwlinear.....	28
Figura 09 - Média anual de radiação solar global diária (Wh/m <sup>2</sup> .dia).....	31
Figura 10 - Capacidade instalada da matriz elétrica brasileira.....	32
Figura 11 - Estação meteorológica automática (EMA)	33
Figura 12 - Interface da <i>systemIdentification toolbox</i> .....	35
Figura 13 - Janela de importação de dados.....	36
Figura 14 - Interface com dados importados.....	37
Figura 15 - Interface da <i>systemIdentification toolbox</i> .....	37
Figura 16 - Seleção da estrutura e ordem do modelo linear.....	38
Figura 17 - Seleção do tipo do modelo não linear.....	39
Figura 18 - Seleção da ordem do modelo não linear.....	40
Figura 19 - Janela de estimação dos parâmetros.....	40
Figura 20 - Curvas do Modelo ARX de agosto 15 dias.....	43
Figura 21 - Curvas do Modelo ARX de setembro 10 dias.....	43
Figura 22 - Curvas do Modelo ARX de outubro 10 dias.....	44
Figura 23 - Curvas do Modelo ARMAX de agosto 10 dias.....	46
Figura 24 - Curvas do Modelo ARMAX de setembro 10 dias.....	46
Figura 25 - Curvas do Modelo ARMAX de outubro 10 dias.....	47
Figura 26 - Modelo <i>Pwlinear-Pwlinear</i> .....	50
Figura 27 - Modelo <i>Pwlinear-Sigmoidnet</i> .....	51

Figura 28 - Modelo <i>Sigmoidnet-Pwlinear</i> .....	51
Figura 29 - Modelo <i>Sigmoidnet-Sigmoidnet</i> .....	52

## LISTA DE TABELAS

Tabela 1 - Resultados obtidos para o modelo ARX.....	42
Tabela 2 - Resultados obtidos para o modelo ARMAX.....	45
Tabela 3 - Estrutura dos blocos de entrada e saída.....	48
Tabela 4 - Desempenhos dos modelos de agosto.....	48
Tabela 5 - Desempenhos dos modelos de setembro.....	49
Tabela 6 - Desempenhos dos modelos de outubro.....	49

## LISTA DE ABREVIATURAS E SIGLAS

ARX	<i>Autoregressive With Exogenous Inputs</i>
ARMAX	<i>Autoregressive Moving Verage With Exogenous Input</i>
OE	<i>Output Error</i>
FPE	<i>Final Prediction Error</i>
EPE	Empresa de Pesquisa Energética
BEN	Balanço energético nacional
EMC	Estação Meteorológica Convencional
EMA	Estação Meteorológica Automática

## SUMÁRIO

<b>1. INTRODUÇÃO</b> .....	15
<b>1.1 OBJETIVOS</b> .....	16
<b>1.1.1 OBJETIVO GERAL</b> .....	16
<b>1.1.2 OBJETIVOS ESPECÍFICOS</b> .....	16
<b>1.3 ORGANIZAÇÃO DO TRABALHO</b> .....	16
<b>2. REVISÃO BIBLIOGRÁFICA</b> .....	17
<b>2.1 IDENTIFICAÇÃO DE SISTEMAS</b> .....	19
<b>2.1.2. Sistemas Lineares</b> .....	21
<b>2.1.2.1 Modelo ARX</b> .....	22
<b>2.1.2.2 Modelo ARMAX</b> .....	22
<b>2.1.2.3 Modelo <i>Output Error</i></b> .....	23
<b>2.2. SISTEMAS NÃO LINEARES</b> .....	24
<b>2.2.1. O Modelo de <i>Hammerstein</i></b> .....	24
<b>2.2.2. O Modelo de <i>Wiener</i></b> .....	25
<b>2.2.3. O Modelo de <i>Hammerstein-Wiener</i></b> .....	26
<b>2.2.3.1. Função <i>pwlinear</i></b> .....	27
<b>2.2.3.2. Função <i>Sigmoidnet</i></b> .....	28
<b>2.2.4. Predição de Erro Final</b> .....	28
<b>3 RADIAÇÃO SOLAR</b> .....	29
<b>3.1 Energia Solar</b> .....	29
<b>3.2 Dados meteorológicos</b> .....	31
<b>4. <i>System Identification Toolbox</i> do MATLAB</b> .....	34
<b>4.1. ESTIMAÇÃO DE PARÂMETROS LINEARES</b> .....	34
<b>4.2 ESTIMAÇÃO DE PARÂMETROS NÃO-LINEARES</b> .....	38
<b>5. RESULTADOS E DISCUSSÕES</b> .....	40

<b>5.1 MODELO ARX</b> .....	40
<b>5.2 MODELO ARMAX</b> .....	43
<b>5.3. MODELO DE <i>HAMMERSTEIN-WIENER</i></b> .....	46
<b>6. CONCLUSÃO</b> .....	51
<b>REFERÊNCIAS</b> .....	52

## 1. INTRODUÇÃO

Nas últimas décadas, o crescimento e o desenvolvimento humano não ficaram apenas restritos a fatores econômicos e sociais, mas também foi atrelado a essas ideias uma constante preocupação ambiental. Os conceitos de sustentabilidade e educação ambiental tornaram-se exemplos disso, uma vez que são unanimidade em todo o mundo. Com isto, surge a necessidade da utilização de fontes renováveis de energia e, especialmente, limpas. Assim, atendendo a esse propósito, pôde-se observar um crescimento expressivo de duas dessas fontes: a solar e a eólica.

O sistema elétrico tem tido um crescimento significativo das fontes renováveis de energia em sua composição. Com esse crescimento, surge a demanda de uma melhoria na estimação do montante de energia proveniente das fontes renováveis de energia solar e eólica (DOMINGOS, 2020).

Com a competitividade das tecnologias que usam a energia solar ocorre o crescimento da participação da fonte na matriz elétrica. Em 2018, sua participação correspondeu à 1,83%, desde então só tende a crescer. A capacidade instalada de energia solar no mundo alcançou 487,8 GW no final de 2018, aproximadamente 22 vezes maior do que o observado em 2009 por exemplo, com um aumento de 40,8 % de capacidade em todo o mundo (BEZERRA, 2020).

Entretanto mesmo com o uso cada vez maior da energia solar na produção de energia elétrica, existe a necessidade de se realizar estudos de potencial que comprovem a efetividade de um investimento. Uma alternativa para determinar o potencial de geração em determinados períodos, corresponde no conhecimento de dados meteorológicos de radiação solar.

A utilização e conversão da energia solar, depende da precisão, exatidão e dados contínuos que são essencialmente importantes. Com isso, estabelecer um método de previsão, preciso e eficiente, desempenha um papel importante para o desenvolvimento da energia solar, principalmente, na geração em grandes usinas solares (DOMINGOS, 2020).

Com base nessas informações, este trabalho aplicou modelos de predição para dados médios diários de radiação solar na região de Jaguaruana no estado do Ceará, baseados em identificação de sistemas lineares e não lineares, para que sejam utilizados na estimação do potencial de geração de energia solar.

## 1.1 OBJETIVOS

### 1.1.1 OBJETIVO GERAL

O objetivo principal é obter modelos de estimação de parâmetros de radiação solar utilizando-se os métodos de identificação de sistemas por meio de modelagem linear (ARX e ARMAX) e não-linear (*Hammerstein-Wiener*).

### 1.1.2 OBJETIVOS ESPECÍFICOS

- Utilizar a *toolbox systemIdentification* do software MATLAB para aplicar um banco de dados e desenvolver um modelo de estimação;
- Aplicar a modelagem linear dos modelos ARX e ARMAX à banco de dados;
- Aplicar a modelagem não linear *Hammerstein-Wiener* do banco de dados;
- Comparar os resultados entre os modelos linear e não linear obtidos, com o propósito de identificar o modelo que melhor se adequa aos dados,

## 1.3 ORGANIZAÇÃO DO TRABALHO

O presente Trabalho de Conclusão de Curso está organizado em 06 capítulos, que serão descritos a seguir:

- Capítulo 1: introduz o tema deste trabalho de conclusão de curso e apresenta os objetivos.
- Capítulo 2: faz uma breve revisão bibliográfica sobre identificação de sistemas, destacando seus tipos e suas características. Em seguida, são desenvolvidos os modelos lineares ARX, ARMAX e não-linear *Hammerstein-Wien*.
- Capítulo 3: será apresentado os conceitos gerais relacionados a radiação e energia solar, apresentando dados atuais no Brasil, além de explorar a obtenção e organização dos dados meteorológicos.
- Capítulo 4: apresenta a metodologia utilizada para obter os resultados deste trabalho, as modelagens lineares e não lineares através da ferramenta *system Identification toolbox* do programa MATLAB.
- Capítulo 5: apresenta a modelagem matemática da curva de radiação solar, utilizando a teoria de identificação de sistemas. Também são apresentados os modelos validados e realizada identificação do melhor modelo linear e não linear.
- Capítulo 6: este capítulo apresenta a conclusão deste trabalho



## 2. REVISÃO BIBLIOGRÁFICA

Segundo Corrêa (2001), com o constante avanço da tecnologia surgiu a necessidade de controlar os processos industriais e junto disso o desenvolvimento de modelos que reproduzam com eficiência as características estáticas e dinâmicas desses processos.

Alves (2004) destaca que umas das primeiras soluções para aplicação de comportamentos dinâmicos de sistemas físicos são as equações diferenciais que modelam uma grande variedade de tais comportamentos. Com o aumento da capacidade de observação, armazenamento e processamento de dados, o método de identificação de sistemas se destaca na obtenção de modelos matemáticos.

Ljung (1999) define que a identificação de sistemas segue um processo de etapas dentre as quais, destacam-se: testes dinâmicos e coletas de dados, escolha da representação matemática, determinação do modelo, estimação dos parâmetros e validação do modelo.

Quanto a representação matemática podem ser definidas as seguintes abordagens para identificação de sistemas: (1) modelagem caixa-branca em que a aquisição dos modelos é fundamentada pelas leis e princípios físicos, (2) modelagem caixa-preta na qual não se tem conhecimento prévio do sistema a ser modelado, para este tipo de modelagem apenas os dados de entrada e saída do processo são usados durante a identificação e a (3) modelagem caixa-cinza nesta há algum tipo de conhecimento prévio além dos dados de entrada e saída que são utilizados na identificação do sistema a ser modelado.

Nesse contexto, Corrêa (2004) destaca como desvantagem da modelagem caixa-branca, a dificuldade de aquisição do modelo devido as equações físicas envolvidas no processo, assim como seus parâmetros, são por demais complexas e por muitas vezes, não podem ser determinadas.

Para minimizar esse problema, a identificação de sistemas desenvolve modelos matemáticos a partir de um sistema real de dados de entrada que são observados e controlados com objetivo de reproduzir as características na saída.

Dessa forma, para Romio (2013) a identificação de Sistemas consiste na utilização de técnicas para obter modelos do tipo caixa-preta ou caixa-cinza, cujo

modelo é estruturado sem relacioná-lo com as leis físicas envolvidas no processo, na qual apenas são utilizados os dados observados do sistema e alguma informação prévia. Os modelos do processo podem ser paramétricos, não-paramétricos e no domínio da frequência.

Campos (2008) afirma que diversas formas de representar o comportamento de um mesmo modelo podem ser utilizadas, podendo ser lineares ou não lineares. Uma modelagem que se destaca na sua importância para sistemas dinâmicos lineares é a função de transferência, outra que podemos destacar é a representação em espaço de estados, ambos apresentados em sistemas contínuos e no tempo.

No caso de representações de sistemas lineares discretos pode-se citar os modelos ARX, ARMAX, ARMA, ARIMA, ARIMAX, *Output Error* e *Box-Jenkins*. Para as representações não lineares pode-se citar os modelos de Hammerstein e de Wiener, modelo NARX, NARMAX, Redes Neurais Artificiais, dentre outras.

Esses modelos são aplicados a um banco de dados e, em seguida, identifica-se a estrutura que apresenta uma melhor estimação dos parâmetros, bem como sua validação. Com isso, o desenvolvimento de aplicações desse tipo de representação pode ser variado.

Neto (2010) utilizou a identificação de sistemas onde aplicou o modelo ARX para a escolha de um modelo polinomial que possibilite a observação do comportamento da temperatura de um retificador de corrente elétrica utilizado para suprimento dos motores de tração de uma Locomotiva Diesel-Elétrica.

Santos (2007), desenvolveu controladores preditivos baseados no modelo de Hammerstein visando aliar a capacidade de representação da não-linearidade de um processo com a simplicidade de projeto. Além disso, apresentou resultados de simulação e experimentais em uma planta solar de climatização, obtendo-se um desempenho satisfatório e os modelos mostraram-se representativos.

Com base nas afirmações apontadas pelas referências acima, optou-se nesse trabalho de conclusão de curso pelo uso de identificação de sistemas do tipo paramétricos lineares com modelos do tipo ARX e ARMAX e não lineares do tipo *Hammerstein-Wiener* para a predição de dados de radiação solar.

## 2.1 IDENTIFICAÇÃO DE SISTEMAS

A identificação de sistemas modela sistemas elaborados a partir de dados de entrada e saída, através de modelos matemáticos. Diversas técnicas podem ser encontradas para obter modelos dos sistemas, no qual há diferentes graus de formalização matemática. Adotando-se as modelagens: caixa branca, modelagem caixa preta e modelagem caixa cinza (SOUSA, 2005).

O princípio básico da identificação de sistemas consiste em excitar o processo para obter uma representação, para isso um sinal conhecido com um conjunto de variáveis manipuláveis é aplicado e no decorrer do processo as repostas são determinadas com o objetivo de encontrar uma função matemática que relacione esses sinais, comumente denominados entrada e saída (ORENSTEIN, 2013).

De acordo com Ljung (1999), para a teoria da identificação de sistemas, os métodos desenvolvidos no processo podem ser divididos em três grupos:

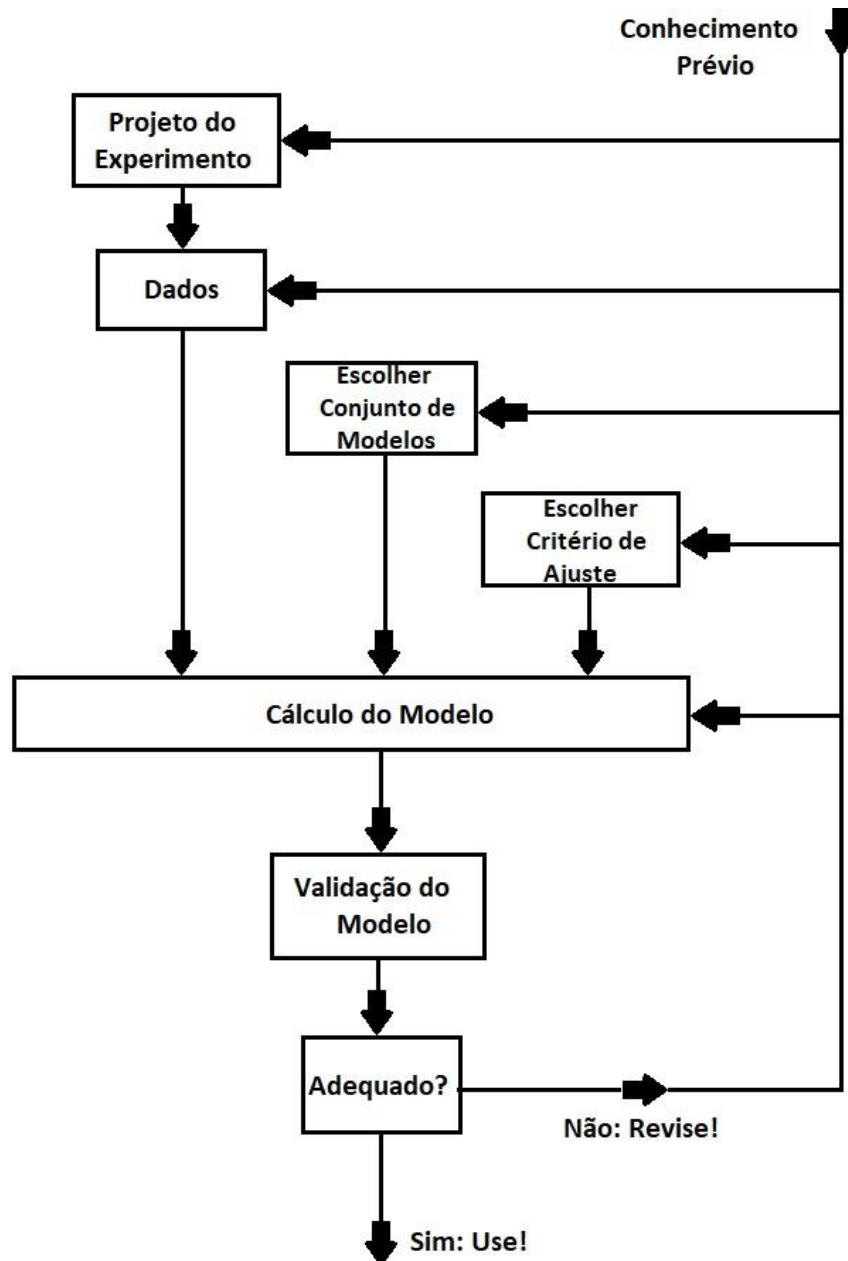
- Métodos paramétricos;
- Métodos não-paramétricos;
- Métodos do domínio da frequência.

Segundo Sousa (2005), faz-se necessário seguir os seguintes passos para a identificação de um sistema:

- Coleta e pré-processamento dos dados;
- Detecção de não-linearidade do sistema;
- Escolha da representação do sistema;
- Escolha da estrutura do modelo;
- Ajuste dos parâmetros do modelo;
- Validação do modelo.

O fluxograma apresentado na Figura 1 aponta as principais etapas do processo de identificação de sistemas:

**Figura 1** – Etapas do processo de identificação de sistemas



**Fonte** – Ljung (1999).

Uma vez que a identificação propõe-se avaliar um determinado modelo a obter modelo a partir de dados, torna-se necessário coletar tais dados. Na maioria das vezes os únicos dados disponíveis serão dados de “operação normal”, mas em outros casos será possível e desejável efetuar testes de forma a extrair informações dinâmicas do sistema (AGUIRRE, 2007).

### 2.1.2. Sistemas Lineares

Alguns modelos utilizados na identificação de sistemas possuem uma estrutura em tempo discreto. Esses modelos podem ser moldados a partir da seguinte equação geral (AGUIRRE, 2007):

$$\begin{aligned}A(z)y(k) &= \frac{B(q)}{F(q)}u(k) + \frac{C(q)}{D(q)}v(k) \\y(k) &= \frac{B(q)}{F(q)A(z)}u(k) + \frac{C(q)}{D(q)A(z)}v(k) \\y(k) &= H(q)u(k) + G(q)v(k)\end{aligned}\tag{2.1}$$

Onde,  $H(q)$  é a função transferência do processo,  $G(q)$  a função de transferência do ruído,  $v(k)$  o ruído branco e  $A(q)$ ,  $B(q)$ ,  $C(q)$ ,  $D(q)$  e  $F(q)$  são definidos pelos polinômios a seguir:

$$A(q) = 1 - a_1q^{-1} - \dots - a_{n_y}q^{-n_y};\tag{2.2}$$

$$B(q) = b_1q^{-1} + \dots + b_{n_u}q^{-n_u};\tag{2.3}$$

$$C(q) = 1 - c_1q^{-1} + \dots + c_{n_v}q^{-n_v};\tag{2.4}$$

$$D(q) = 1 - d_1q^{-1} + \dots + d_{n_d}q^{-n_d}\tag{2.5}$$

$$F(q) = 1 - f_1q^{-1} + \dots + f_{n_f}q^{-n_f}\tag{2.6}$$

Sendo  $q^{-1}$  o operador de atraso, de forma que  $y(k)q^{-1} = y(k-1)$ . Os parâmetros  $a_1 \dots a_{n_y}$ ,  $b_1 \dots b_{n_u}$ ,  $c_1 \dots c_{n_v}$ ,  $d_1 \dots d_{n_d}$  e  $f_1 \dots f_{n_f}$  são estimados de acordo com o modelo selecionado e  $n_y$ ,  $n_u$ ,  $n_v$ ,  $n_d$  e  $n_f$  indicam a ordem de cada polinômio.

### 2.1.2.1 Modelo ARX

O modelo ARX (do inglês: *Autoregressive with exogenous inputs*), pode ser obtido a partir da Equação (2.1), assumindo  $C(q) = D(q) = F(q) = 1$  sendo  $A(q)$  e  $B(q)$  polinômios arbitrários, resultando na seguinte relação:


$$A(q)y(k) = B(q)u(k) + v(k) \quad (2.7)$$

Essa relação do modelo ARX pode ser reescrita da seguinte forma:

$$y(k) = \frac{B(q)}{A(q)}u(k) + \frac{1}{A(q)}v(k) \quad (2.8)$$

Com isso, as funções de transferência são definidas para o modelo em questão como sendo  $H(q) = B(q)/A(q)$  do processo e  $C(q)/[D(q)A(q)] = 1/A(q)$  do ruído, ambos possuem o polinômio  $A(q)$  como fator comum. A Figura 2 ilustra uma representação esquemática do modelo ARX, no qual  $e(k) = v(k)/A(k)$  é o ruído adicionado na saída:

**Figura 2** – Representação do modelo ARX



Fonte – Aguirre (2000).

### 2.1.2.2 Modelo ARMAX

O modelo ARMAX (do inglês *Autoregressive moving average with exogenous input*), pode ser obtido a partir da Equação (2.1), agora assumindo que  $D(q) = F(q) = 1$  e  $A(q)$ ,  $B(q)$  e  $C(q)$  como polinômios arbitrários, resultando na seguinte relação:


$$A(q)y(k) = B(q)u(k) + C(q)v(k) \quad (2.9)$$

Essa relação do modelo ARMAX pode ser reescrita da seguinte forma:

$$y(k) = \frac{B(q)}{A(q)}u(k) + \frac{C(q)}{A(q)}v(k) \quad (2.10)$$

cuja representação esquemática é dada na Figura 3, a seguir:

**Figura 3** - Representação do modelo ARMAX



**Fonte** – Aguirre (2000).

### 2.1.2.3 Modelo *Output Error*

Por sua vez, o modelo de erro da saída OE (do inglês *output error*), assumindo-se que  $A(q) = C(q) = 1$ ,  $D(q) = 1$ ,  $B(q)$  e  $F(q)$  como polinômios arbitrários, resultando na seguinte relação:

$$y(k) = \frac{B(q)}{F(q)}u(k) + v(k) \quad (2.11)$$


Ao representar a Equação (2.1) como modelo ARX é possível chegar na seguinte relação que contém uma variável sem ruído auxiliar  $w(k)$ :

$$F(q)w(k) = B(q)u(k)$$

$$y(k) = w(k) + v(k) \quad (2.12)$$

A Figura 4 é uma representação esquemática do modelo OE:

**Figura 4** - Representação do modelo OE



**Fonte** – Aguirre (2000).

## 2.2. SISTEMAS NÃO LINEARES

Em algumas situações as aproximações lineares são suficientes em aplicações práticas, no entanto em outras não serão satisfatórias, sendo necessária a representação em modelos não lineares (AGUIRRE, 2007). O comportamento de um sistema não linear é representado por blocos interconectados com funções e operadores que se relacionam entre a entrada e saída do sistema.

Um dos blocos modela a não linearidade estática do sistema enquanto o outro modela a dinâmica de um modelo linear. Quando o bloco estático é posicionado antes do bloco dinâmico, ele é definido como modelo de *Hammerstein*, a representação inversa e denominada de modelo de *Wiener* (COELHO, 2002). A estrutura desses modelos é apresentada a seguir junto com o modelo *Hammerstein-Wiener* utilizado neste trabalho para estimar o modelo não linear.


### 2.2.1. O Modelo de *Hammerstein*

O modelo de *Hammerstein* é uma estrutura de modelo com blocos orientados com atuadores não lineares ou com efeitos não lineares que podem ocorrer na entrada do sistema. Aplicações para este tipo são utilizadas para modelar vários tipos de sistemas não lineares, como sistemas elétricos e sistemas térmicos (FERREIRA, 2017).



A estrutura do modelo de *Hammerstein* é composta de um modelo dinâmico linear  $H(s)$  em cascata com a função estática não linear  $f(\cdot)$  (AGUIRRE, 2000). A Figura 5 apresenta o diagrama desse tipo de modelo, cuja função  $f(\cdot)$  representa o bloco não linear e  $G(q)$  o bloco linear, a estrutura consiste de um um sinal de entrada,  $u(k)$ , aplicado ao bloco não linear. A partir disso é obtido a saída da parte não linear  $v(k)$  e logo após, o sinal passa pelo bloco dinâmico linear resultando no sinal de saída,  $y(k)$ .

**Figura 5** – Representação modelo de *Hammerstein*.



**Fonte** – Ferreira (2017)

As equações que descrevem este modelo são:

$$v(k) = f(u(k)) \quad (2.13)$$


$$y(k) = G(q)v(k) \quad (2.14)$$

### 2.2.2. O Modelo de *Wiener*

O modelo de Wiener é uma estrutura de modelo com blocos orientados com sensores não lineares ou outros efeitos não lineares na saída desse sistema. A identificação dos modelos que para esse tipo de estrutura envolvem a estimação de parâmetros descritos por dinâmicas lineares e saídas estáticas de blocos não lineares (Ferreira, 2017).

A estrutura do modelo de Wiener assim como de *Hammerstein* também é composta de um modelo dinâmico linear  $H(s)$  em cascata com a função estática não linear  $f(\cdot)$ . A Figura 6 apresenta o diagrama desse tipo de modelo, no qual  $f(\cdot)$  representa o bloco não linear e  $G(q)$  o bloco linear, O sinal de entrada,  $u(k)$ , passa pelo bloco do modelo dinâmico linear, gerando a saída da parte linear,  $v(k)$ , e logo após, o sinal passa pelo bloco não linear resultando no sinal de saída,  $y(k)$ .

**Figura 6 - Modelo de wiener.**



**Fonte – Ferreira (2017)**

As equações que descreve este modelo são:

$$v(k) = G(q)u(k) \quad (2.15)$$


$$y(k) = f(v(k)) \quad (2.16)$$

### 2.2.3. O Modelo de *Hammerstein-Wiener*

Por sua vez, o modelo de *Hammerstein-Wiener* é composto de três blocos, um com modelo não linear estático, outro com modelo de um sistema dinâmico linear e outro não linear estático (LARICO, 2020).

Os blocos não lineares obtêm as não linearidades estáticas do sistema e o bloco linear o restante da dinâmica envolvida. Esse modelo pode ser aplicado como uma estrutura caixa-preta devido a flexibilidade da parametrização e como caixa-cinza obtendo o conhecimento físico envolvido no processo. A Figura 7 apresenta o diagrama desse tipo de modelo.

**Figura 7 - Modelo de Hammerstein-Wiener.**



**Fonte – Larico (2020).**

As equações que descreve este modelo são:

$$w_1(k) = f_1[u(k)]$$

$$w(k) = w_2(k) + v(k) = G(q)w_1(k) + v(k)$$

$$y(k) = f_2[w(k)] = f_2[G(q)f_1[u(k)] + v(k)] \quad (2.17)$$

O bloco linear tem a estrutura *Output Error* (OE) representado pela Equação (2.11). As ordens de  $n_b$  e  $n_f$  dos polinômios (2.3) e (2.6) são testadas através de diferentes combinações. As estruturas não lineares que podem representar o modelo nos blocos de entrada e saída podem ser: *pwlinear*, *sigmoidnet*, *saturation*, *deadzone* e *wavenet*. Para este trabalho optou-se por utilizar as funções *pwlinear* e *sigmoidnet* para desenvolver os modelos.


### 2.2.3.1. Função *pwlinear*

A função é representada por:

$$y = F_{pw}(x, \theta) \quad (2.18)$$

Sendo  $y$  e  $x$  escalares e  $\theta$  os números de ponto de ruptura e o valor de não linearidade desses respectivos pontos. Na Figura 8 observa-se esse tipo de função, na qual as partes direita e esquerda são constantes, e na parte central, ela é composta por duas funções lineares (LARICO, 2020).

**Figura 8** - Função *Pwlinear*



**Fonte** – Larico (2020)

### 2.2.3.2. Função *Sigmoidnet*

Esse tipo de função é representado por:

$$y = F_{sig}(x) \quad (2.19)$$

Sendo  $y$  escalar e  $x$  um vetor com dimensões  $m$ . Esse tipo de função baseia-se na expressão a seguir:

$$F(x) = (x - r)PL + a_1(f(x - r)Q_{b1} + C_1) + \dots + a_n(f(x - r)Q_{bn} + C_n) + d \quad (2.20)$$

Em que,  $f$  é uma função sigmoide dada pela equação (LARICO, 2020):

$$f(a) = \frac{1}{e^{-a} + 1} \quad (2.21)$$

### 2.2.4. Predição de Erro Final

Segundo Binkowski (2016), o método de predição do erro final (FPE – *Final Prediction Error*) utilizado para comparar modelos estimados, ele foi primeiramente proposto por Akaike, Clements e Hendy (1969). O critério FPE dá uma estimativa da qualidade do modelo desenvolvido a partir de um conjunto de dados diferentes dos dados de estimação.

De acordo com Akaike, Clements e Hendy (1969), o melhor modelo possui o menor valor de FPE. O critério é calculado pela relação:

$$FPE = \frac{1 + \left(\frac{P}{N}\right)}{N} \sum_{t=1}^N e^2(k, \theta_n) \quad (2.22)$$

Onde,

- $e$  é o erro de estimação;
- $N$  é o número de amostras utilizadas;
- $P$  é o número de parâmetros do modelo.

### **3 RADIAÇÃO SOLAR**

O sol é uma fonte essencial de energia para o planeta, a radiação solar impulsiona os movimentos atmosféricos e outros processos que ocorrem na atmosfera terrestre, como os processos térmicos, dinâmicos e químicos (FIORIN, 2011).

A radiação solar se propaga com velocidade de 300.000 km/s, produzindo características ondulatórias e corpusculares. O processo de conversão de energia solar em eletricidade ocorre devido a incidência no meio material na qual pode ser refletida, transmitida e absorvida. A potência de um feixe luminoso é representada pelo movimento dos fótons com energia unitária  $hf$ , onde  $f$  é a frequência da onda eletromagnética associada e  $h$  é a Constante de Planck ( $6,62 \times 10^{-34}$  Js) (CRESESB, 2004).

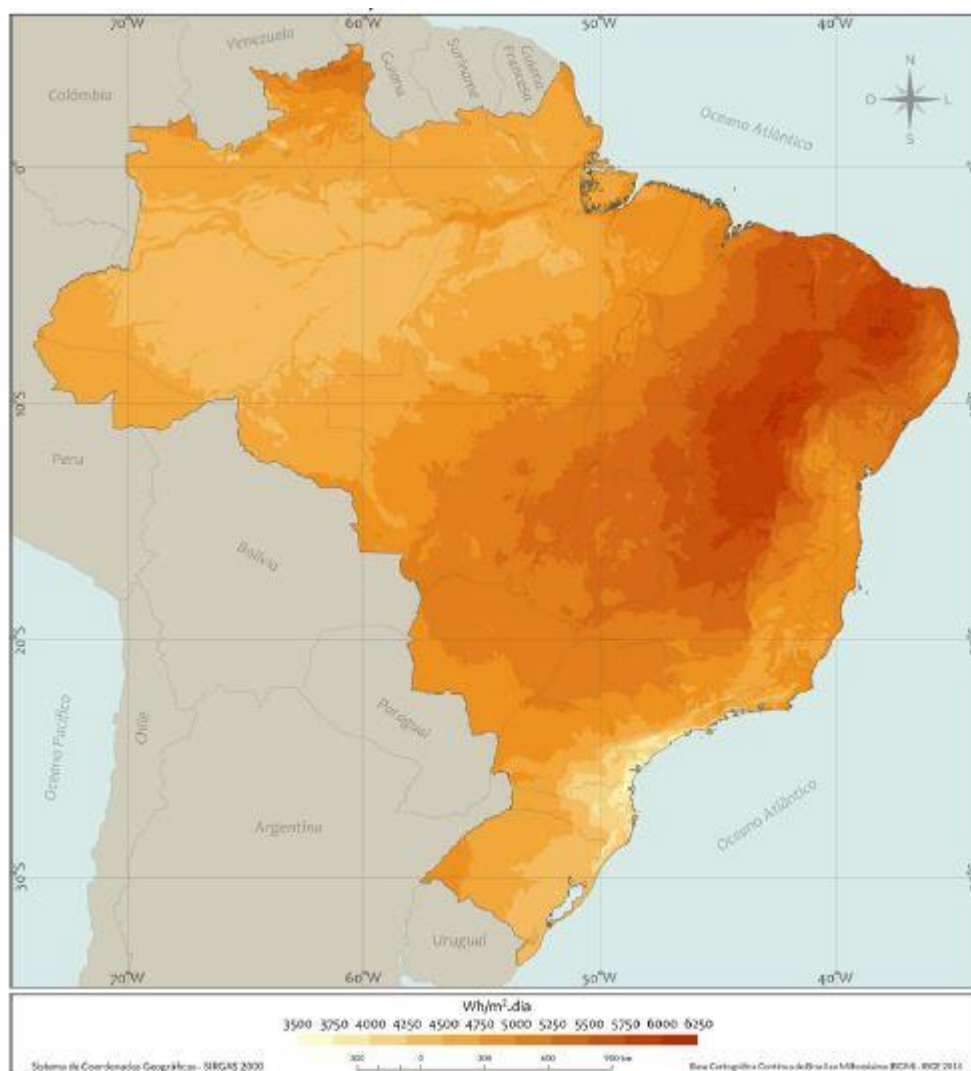
Com o conhecimento da radiação solar de um determinado local, é possível caracterizar o clima de uma determinada região. Sendo utilizada na produção de energia para diferentes fontes (SILVA, 2016). As previsões de curto prazo voltadas ao setor de energia solar podem ser empregadas no planejamento de operação de sistemas fotovoltaicos, por exemplo, visando uma otimização no aproveitamento deste recurso energético (SILVA, 2009).

#### **3.1 Energia Solar**

A energia solar é uma fonte de energia promissora proveniente do sol, considerando o tempo de vida do planeta ela é tida como inesgotável. A energia irradiada pelo sol é aproximadamente constante com uma potência de  $3,86 \times 10^{26}$ W, sua irradiação ocorre devido a fusões nucleares de átomos de hidrogênio resultando em átomos de hélio. Os processos térmicos, dinâmicos e químicos que integram o ciclo de vida do planeta, sejam eles artificiais ou naturais como a fotossíntese por exemplo, são alimentados por essa energia (ATLAS, 2017).

O Brasil apresenta grande potencial de aproveitamento de energia solar anual. A radiação solar pode ser diretamente convertida em energia elétrica, através do efeito fotovoltaico (EPE, 2016). A Figura 9 ilustra o índice médio anual de radiação solar no Brasil, segundo o Atlas Brasileiro de Energia Solar (2017), onde pode-se observar que a região Nordeste corresponde aos melhores índices de radiação do país.

**Figura 9 - Média anual de radiação solar global diária (Wh/m<sup>2</sup>/dia)**

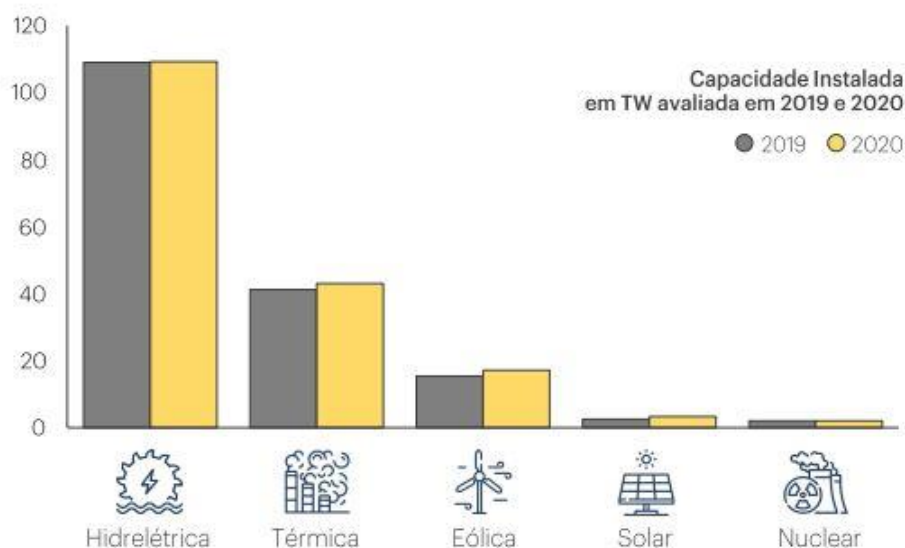


**Fonte:** Atlas (2017).

Segundo a Empresa de Pesquisa Energética - EPE (2012), a irradiação global pode-se considerar bem distribuída pelas regiões do país. A região Nordeste apresenta maior média de valores de irradiação solar global e menor variabilidade anual entre as regiões geográficas, com destaque para a região central do estado da Bahia (6,5 kWh/m<sup>2</sup>/dia). A região Sul apresenta menor média de valores de irradiação solar global no Brasil e a maior variabilidade média anual, com destaque para a costa norte do estado de Santa Catarina (4,25 kWh/m<sup>2</sup>/dia).

O Balanço energético nacional - BEN (2021) mostra que dentre as fontes de energia que representam a matriz energética brasileira, a solar está entre as que apresentaram maior destaque na variação da capacidade instalada de 2019 a 2020, obtendo-se um aumento de 32,9 % como ilustra a Figura 10.

**Figura 10** – Capacidade instalada da matriz elétrica brasileira



**Fonte** – BEN (2021).

A expansão da participação da energia solar demanda o aprimoramento de métodos científicos para a produção de informações meteorológicas específicas, como a radiação, para o planejamento e controle de sistemas de energia (ATLAS, 2017).

O registro de dados de radiação de uma determinada região é feito através de estações meteorológicas que operam por meio de um conjunto de instrumentos ou sensores. As estações podem ser automáticas (EMA) ou convencionais (EMC).

### 3.2 Dados meteorológicos

A automação de dados meteorológicos permite a coleta e o monitoramento de dados em tempo real. Com esse avanço tecnológico surgiu a questão substituir uma tecnologia antiga (convencional) por uma nova (eletrônica), ou seja, uma estação meteorológica convencional (EMC) por uma automática (EMA), sem interromper a série de dados históricos existentes (ALMEIDA, 2013). A primeira requer a presença diária de um observador para a coleta dos dados o a segunda utiliza sensores eletrônicos que são captados através de registro contínuo (PEREIRA, 2008).

A avaliação desses dados era feita através de estações meteorológicas convencionais administradas pelo Instituto Nacional de Meteorologia (INMET), onde

técnicos responsáveis coletavam os dados três vezes ao dia. Além dessa quantidade pequena de medições, também ocorriam erros de natureza sistemática ou aleatória. A criação de estações meteorológicas automáticas aumenta a precisão dos dados, apresentando bom desempenho, praticidade e confiabilidade, porém possuem um alto custo (TORRES, 2015).

Segundo Fernandes (2017), a estação meteorológica automática (EMA) coleta informações ambientais automaticamente, ela inclui elementos como: (i) subsistema de coleta de dados; (ii) subsistema de controle e armazenamento; (iii) subsistema de energia e (iv) subsistema de comunicação. A Figura 11 apresenta a estrutura desse tipo de estação:

**Figura 11:** Estação meteorológica automática (EMA)



**Fonte:** Mundo clima (2021).

Os dados que são coletados por meio de sensores são processados em um período com intervalo de uma hora, os parâmetros meteorológicos obtidos pelo processo são:



- Temperatura (Instantânea, máxima e mínima) do ar [°C];
- Umidade relativa (Instantânea, máxima e mínima) do ar [%];
- Temperatura (Instantânea, máxima e mínima) do ponto de orvalho [°C];
- Pressão atmosférica (Instantânea, máxima e mínima) [Pa];
- Velocidade do vento [m/s];
- Direção do vento [°];
- Radiação Solar [W/m<sup>2</sup>];
- Precipitação [mm];

Os dados de entrada para os modelos de identificação de sistemas lineares e não lineares neste trabalho foram coletados da estação meteorológica automática de Jaguaruana no estado do Ceará. Os dados estão disponíveis gratuitamente na plataforma (<https://portal.inmet.gov.br>), organizados em planilhas do Excel divididos em períodos horários.

Após a coleta, os dados foram pré-processados selecionando períodos com o banco de dados mais completo e organizados por médias diárias. Para todos os modelos preditivos de radiação foram adotados os dados referentes ao ano de 2020, mais especificamente dos meses que apresentaram melhor distribuição de dados, que foram treinados e validados no software MATLAB.

Uma série de dados meteorológicos, mais especificamente em relação a radiação solar, possibilita a construção de um modelo matemático preditivo devido seu comportamento preciso ser registrado durante um período contínuo de tempo. Com isso, neste trabalho foram selecionados dois métodos de estimação de dados de radiação, a identificação de sistemas lineares e não lineares que serão abordados no próximo capítulo.

#### 4. System Identification Toolbox do MATLAB

A Toolbox identificação de sistemas (*system identification Toolbox* em inglês) consiste de uma ferramenta que o MATLAB disponibiliza para desenvolver modelos matemáticos de sistemas dinâmicos através de dados de entrada e saída, podendo ser em tempo discreto e no domínio da frequência, identificando modelos em formato de função de transferência, polinômios etc (SILVA, 2015).

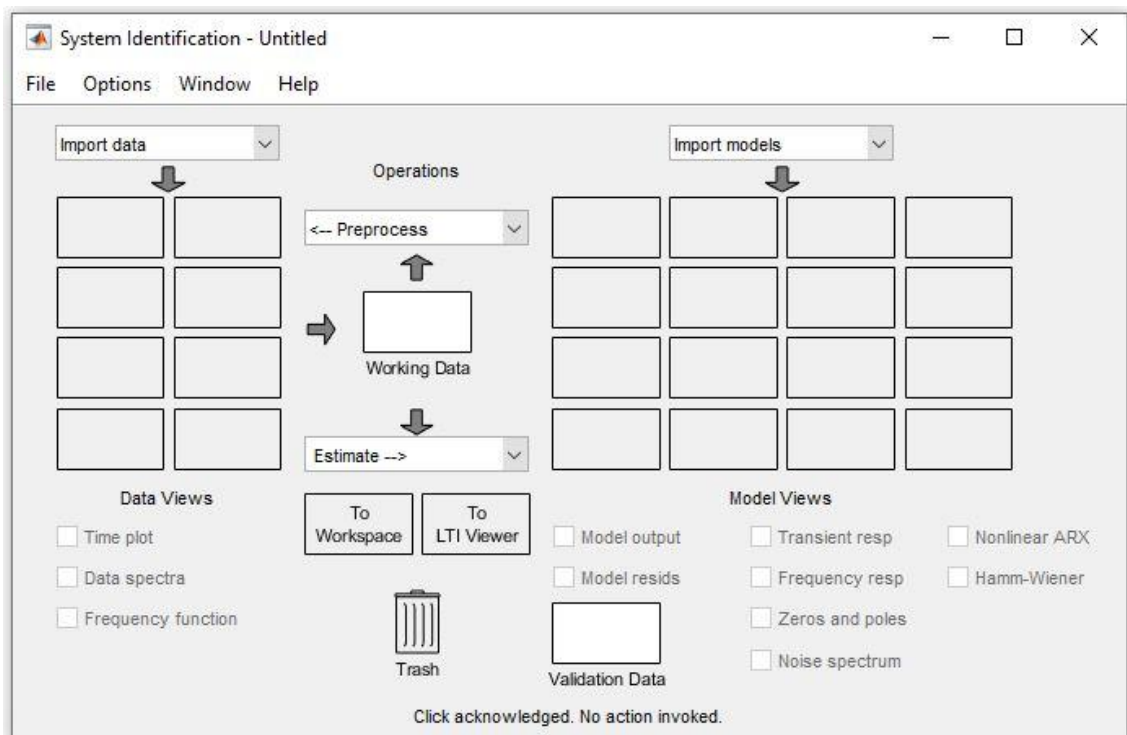
Os modelos obtidos pela ferramenta podem ser comparados com seus respectivos sistemas reais de entrada e saída apresentando o erro dessa relação. Com isso, é possível verificar qual modelo possui o menor erro.

A seguir serão apresentados os passos de treinamento e validação realizados no desenvolvimento dos modelos através da *Toolbox* do MATLAB utilizando-se o comando *systemIdentification*.

##### 4.1. ESTIMAÇÃO DE PARÂMETROS LINEARES

Com a aquisição dos dados de estimação e validação, abre-se o Toolbox digitando "*systemIdentification*" no "*Command Window*" do software Matlab. A Figura 12 mostra a interface do comando utilizado:

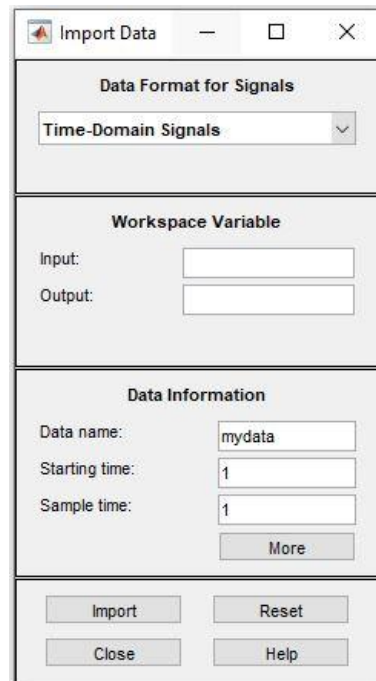
Figura 12 – Interface da systemIdentification toolbox



Fonte – MATLAB (2021)

Em seguida clica-se na opção “*Import data*” e seleciona-se “*Time domain data*” com isso é iniciada a importação de dados de estimação e segue-se um padrão no qual os dados foram nomeados de acordo com a quantidade de dias a serem estimados. A Figura 13 ilustra a janela de importação de dados:

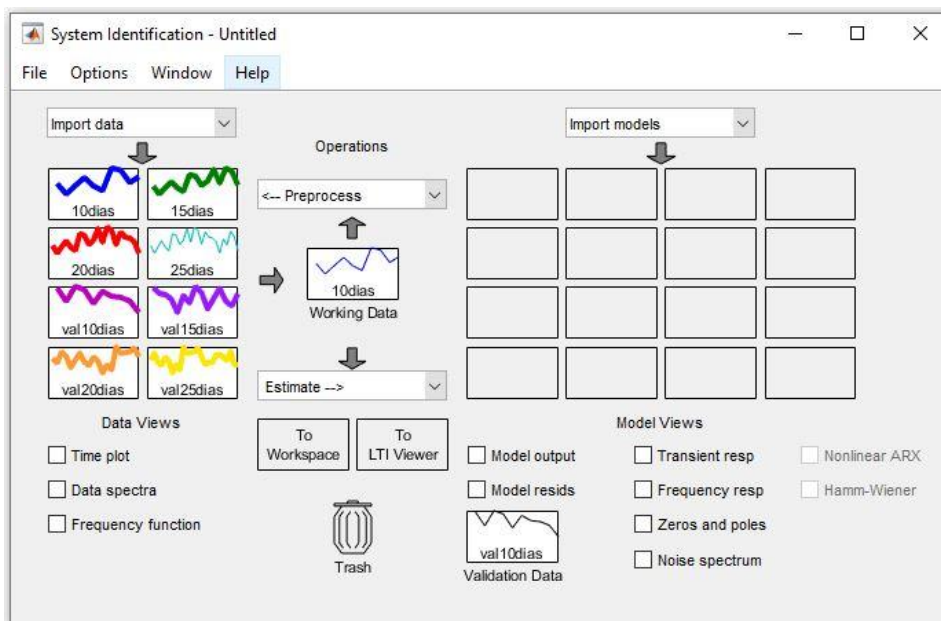
**Figura 13** – Janela de importação de dados



**Fonte** – MATLAB (2021)

Os dados de entrada referentes ao tempo em dias são inseridos na seção “*input*” e os dados de saída referentes a radiação na seção “*output*”, os conjuntos de dados importados são nomeados na seção “*data name*”. A Figura 14 apresenta a interface do *systemIdentification toolbox* com dados importados:

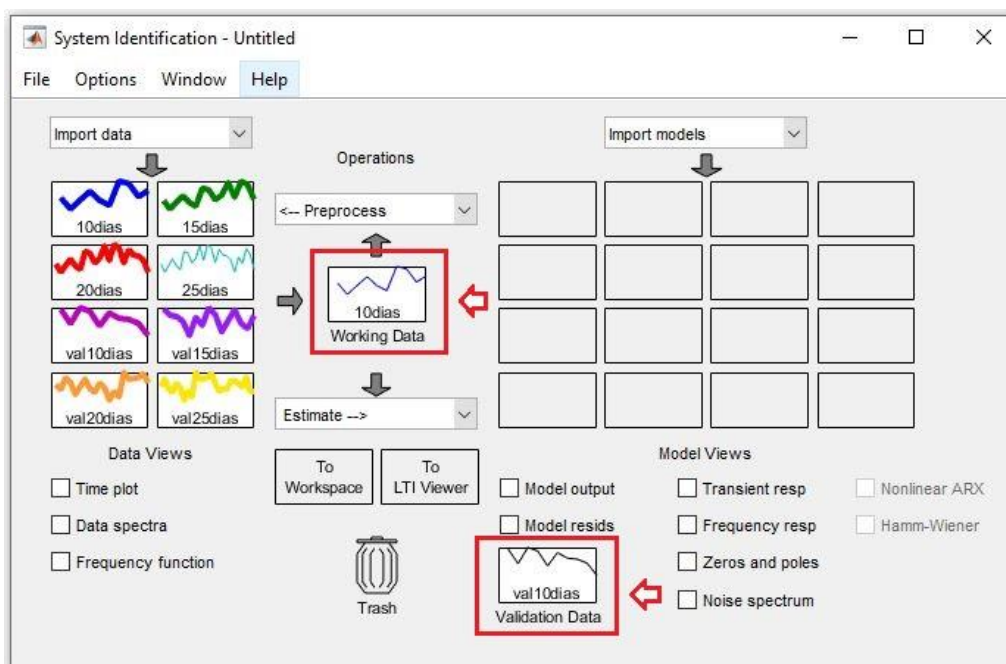
Figura 14 – Interface com dados importados



Fonte – MATLAB (2021)

Para iniciar a estimação, os dados de utilizados para estimar o melhor modelo devem ser colocados no espaço '*Working Data*' e os dados de validação no espaço '*Validation Data*', para isso, basta clicar e arrastar o quadro de dados escolhido até o seu respectivo local. A Figura 15 enfatiza os campos onde devem estar inseridos cada dado:

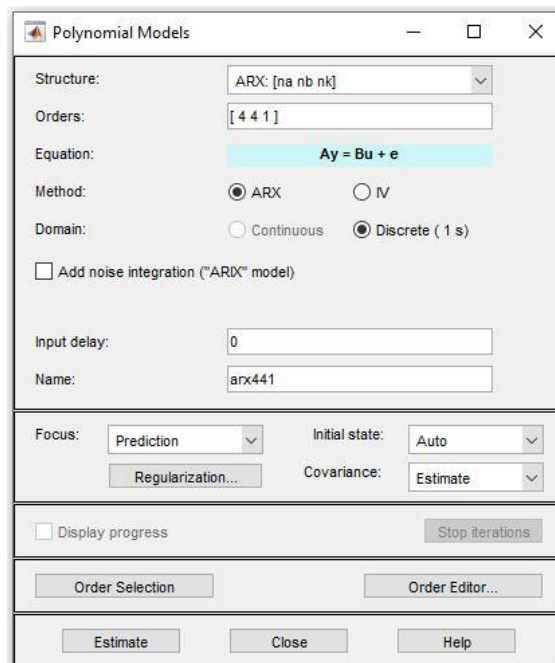
Figura 15 – Interface da systemIdentification toolbox



Fonte – MATLAB (2021)

Clicando em “*estimate*” são apresentadas várias opções de estimadores, a janela “*polynomial Models...*” contém os parâmetros escolhidos. Com isso, escolhe-se da estrutura de modelo paramétrico linear e da ordem dos polinômios a serem estimados. A Figura 16 representa a seção *polynomial Models*:

**Figura 16** – Seleção da estrutura e ordem do modelo linear



**Fonte** – MATLAB (2021)

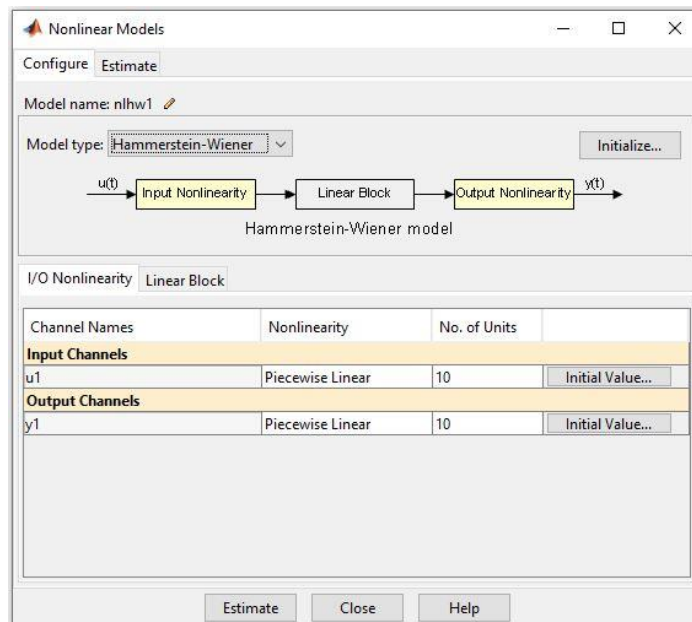
Na sequência, com a janela *polynomial Models* aberta, clica-se em “*Structure*” para selecionar a estrutura de modelo paramétrico ARX, ARMAX, OE ou BJ, e em seguida preenche-se o campo “*Orders*” com a ordem dos parâmetros a serem estimados. Aqui é possível estimar diferentes tipos de modelos e ordens em um mesmo teste.

Após realizar as estimações pode-se então compará-las de acordo com o erro e verificar qual modelo apresenta uma melhor estrutura de dados estimados. É possível obter informações de cada modelo, como a equação de relação entre entrada e saída.

## 4.2 ESTIMAÇÃO DE PARÂMETROS NÃO-LINEARES

Com os dados de entrada inseridos, obtêm-se também os modelos não lineares clicando-se em “*estimate*” onde são apresentadas várias opções de estimadores, a janela “*nonlinear Models...*” contém o parâmetro escolhido. Com isso, escolhe-se a estrutura de modelo não linear e da ordem dos polinômios a serem estimados. A Figura 17 representa a seção *nonlinear Models*:

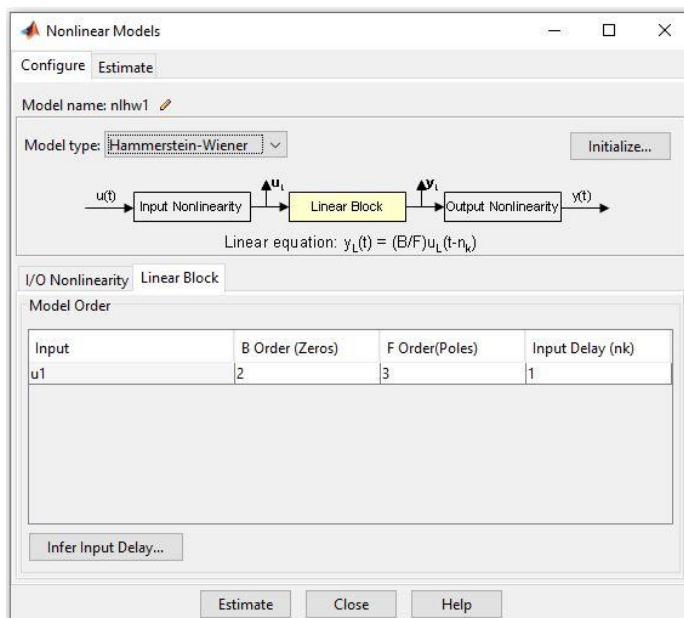
Figura 17 – Seleção do tipo do modelo não linear



Fonte – MATLAB (2021)

Com a janela *polynomial Models* aberta, clica-se em “*model type*” para selecionar a estrutura de modelo não linear *hammerstein-wiener*, e em seguida na aba “*linear block*” preenche-se com a ordem dos parâmetros a serem estimados. A Figura 18 ilustra a aba *linear block*:

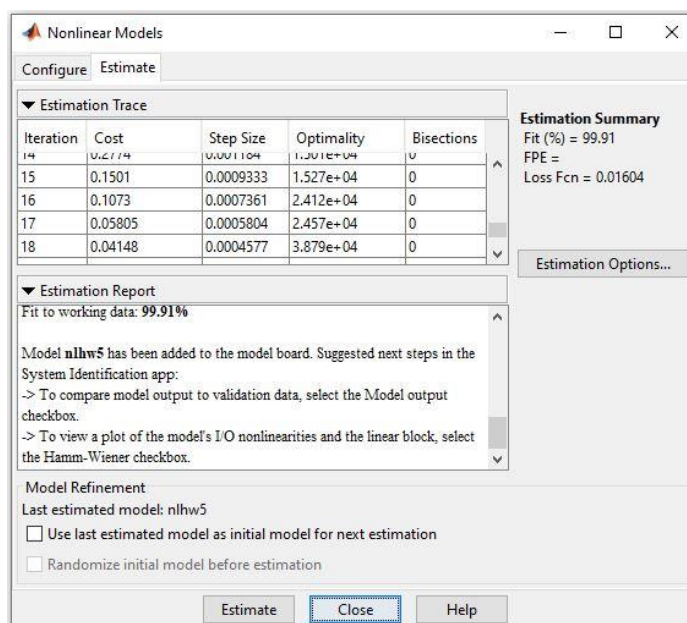
**Figura 18 – Seleção da ordem do modelo não linear**



Fonte – MATLAB (2021)

Clicando em “*estimate*” é apresentada a aba de estimações como mostra a Figura 19, e verifica-se os resultados do experimento na seção “*estimation summary*”.

**Figura 19 – Janela de estimação dos parâmetros**



Fonte – MATLAB (2021)

Após realizar as estimações pode-se então compará-las de acordo com o erro e verificar qual modelo apresenta uma melhor estrutura de dados estimados, assim como a equação de relação entre saída e entrada.

## 5. RESULTADOS E DISCUSSÕES

Os dados selecionados foram dos meses de setembro, outubro e novembro de 2020. Utilizou-se amostras de radiação para 10 e 15 dias para estimar os parâmetros das estruturas de modelos paramétricos lineares ARX e ARMAX e do modelo não linear *Hammerstein-Wiener*. Além disso, 50 % das amostras foram destinadas a modelagem e 50% à validação de cada modelo.

Após cada teste com diferentes ordens selecionou-se para cada mês o conjunto de amostras que apresentaram um modelo validado com comportamento mais próximo do real.

Com a estimação e validação dos modelos matemáticos: ARX, ARMAX e *Hammerstein-Wiener*, o *Toolbox systemIdentification* retorna à comparação entre a curva real de radiação e a curva dos modelos matemáticos estimados ARX, ARMAX e *Hammerstein-Wiener*. O *toolbox* também retornará para o usuário a porcentagens de adequação da saída do modelo em relação à saída do sistema real de cada modelo. A seguir são apresentados os melhores resultados para cada mês.

### 5.1 MODELO ARX

Considerando a estrutura do modelo ARX, na Equação (2.8), apresentada na Seção 2.1.2.1, para a determinação da ordem do modelo testou-se várias combinações para dados de 10 e 15 dias, foram então selecionadas as que obtiveram melhor desempenho, os valores são apresentados na segunda coluna da Tabela 1, em seguida é apresentada a acurácia (FIT) de cada modelo através da validação implementados na *toolbox* do Matlab.

**Tabela 1** - Resultados obtidos para o modelo ARX.

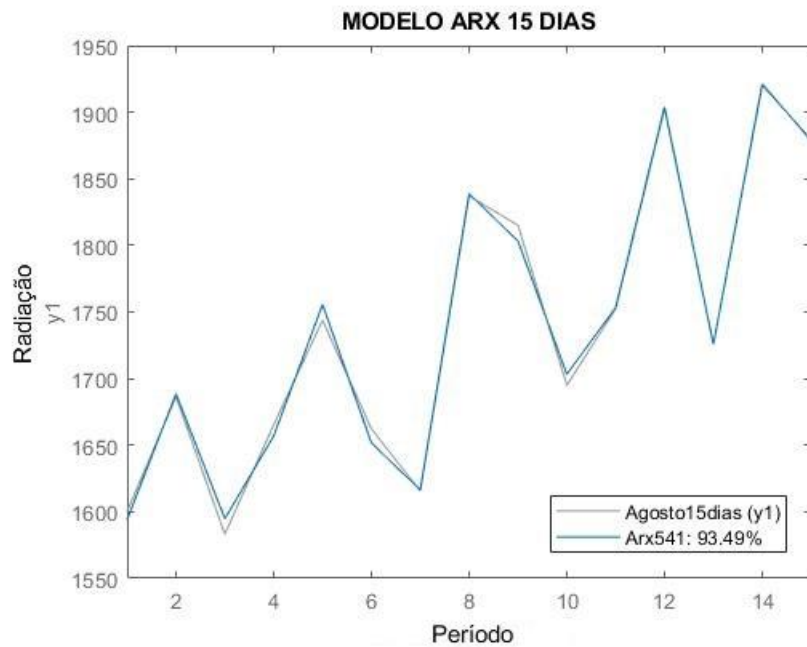
AGOSTO		
PERÍODO	ORDEM	FIT (%)
10 DIAS	331	74,11
15 DIAS	541	93,49
SETEMBRO		
10 DIAS	333	75,33
15 DIAS	541	70,97
OUTUBRO		
10 DIAS	321	87,43
15 DIAS	531	84,05

Fonte –Elaborado pelo autor (2021)



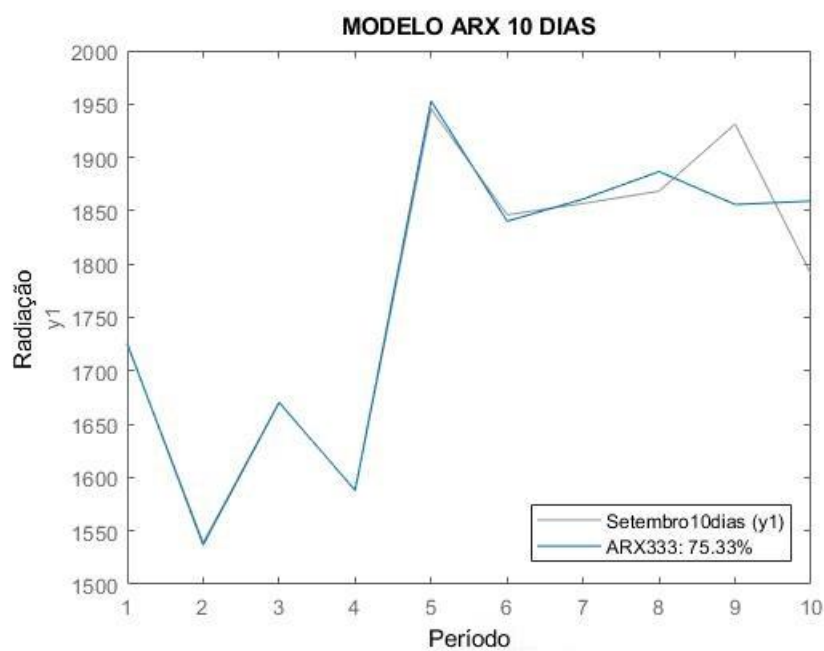
Nas Figuras 20, 21 e 22 são apresentados os gráficos de radiação do melhor modelo ARX para cada mês, com sua respectiva acurácia comparado aos dados reais experimentais nomeados de acordo com o mês e o período de referência.

**Figura 20:** Curvas do Modelo ARX de agosto 15 dias.




Fonte – O Autor (2021)

**Figura 21:** Curvas do Modelo ARX de setembro 10 dias.



Fonte – O Autor (2021)

**Figura 22:** Curvas do Modelo ARX de outubro 10 dias.



**Fonte – O Autor (2021)**

O modelo ARX é representado por dois polinômios:  $A(q)$  e  $B(q)$ , sendo o  $A(q)$  responsável por determinar a ordem do modelo matemático. Observa-se que o melhor modelo obtido foi referente ao mês de agosto, para amostras de 15 dias com ordem 541 e acurácia de 93,49%. Os polinômios gerais para um modelo ARX foram apresentados na Seção 2.1.2.

Com aplicação das amostras de entrada no *systemIdentification toolbox*, foram obtidos os valores dos parâmetros. Substituindo os parâmetros são obtidos os seguintes polinômios:

$$A(z) = 1 + 1,251z^{-1} + 1,517z^{-2} + 2,101z^{-3} + 0,9863z^{-4} + 1,417z^{-5}$$

$$B(z) = 4442z^{-1} - 4285z^{-3}$$

Substituindo os parâmetros do modelo ARX na Equação (2.8/), obtêm-se assim a equação de relação entre saída e entrada do modelo, dada neste caso por:

$$y(k) = \frac{4442z^{-1} - 4285z^{-3}}{1 + 1,251z^{-1} + 1,517z^{-2} + 2,101z^{-3} + 0,9863z^{-4} + 1,417z^{-5}} u(k) + \frac{1}{1 + 1,251z^{-1} + 1,517z^{-2} + 2,101z^{-3} + 0,9863z^{-4} + 1,417z^{-5}} v(k) \quad (5.1)$$

## 5.2 MODELO ARMAX

Considerando a estrutura do modelo ARMAX, na Equação (2.10), apresentada na Seção 2.1.2.2, para a determinação da ordem do modelo testou-se várias combinações para dados de 10 e 15 dias, onde foram selecionadas as que obtiveram melhor desempenho, os valores são apresentados na segunda coluna da Tabela 2, em seguida é apresentada a acurácia (FIT) de cada modelo através da validação implementados na toolbox do Matlab.

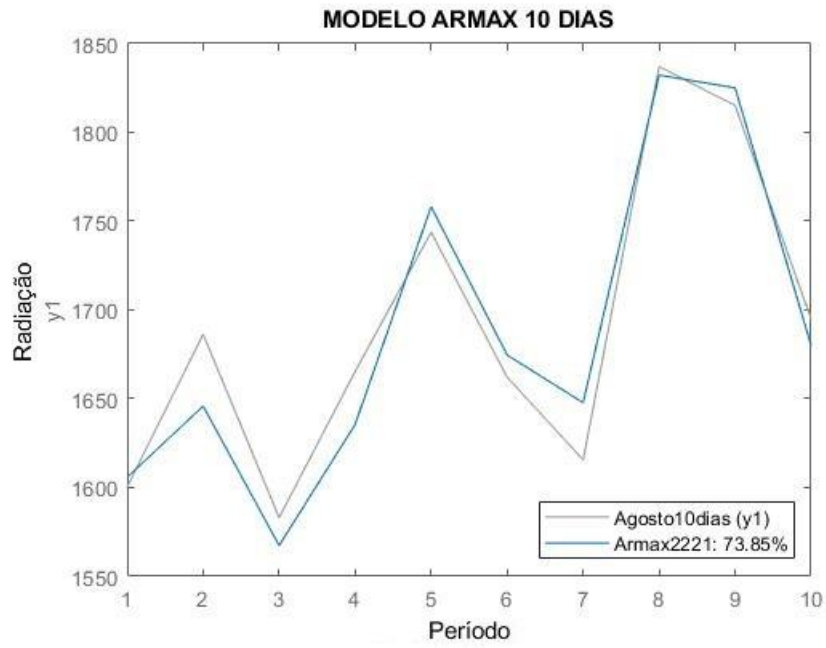
**Tabela 2:** Resultados obtidos para o modelo ARX.

AGOSTO		
PERÍODO	ORDEM	FIT (%)
10 DIAS	2221	73,85
15 DIAS	3211	68,29
SETEMBRO		
10 DIAS	2221	53,15
15 DIAS	3211	40,47
OUTUBRO		
10 DIAS	2222	64,08
15 DIAS	3322	49,63

Fonte –Elaborado pelo autor (2021)


Nas Figuras 23, 24 e 25 são apresentados os gráficos de radiação do melhor modelo ARMAX para cada mês, com sua respectiva acurácia comparado aos dados reais experimentais nomeados de acordo com o mês e o período de referência.

**Figura 23:** Curvas do Modelo ARMAX de agosto 10 dias.




Fonte – O Autor (2021)

**Figura 24:** Curvas do Modelo ARMAX de setembro 10 dias.



Fonte – O Autor (2021)

**Figura 25:** Curvas do Modelo ARMAX de outubro 10 dias.



**Fonte – O Autor (2021)**

O modelo ARMAX é representado por três polinômios:  $A(z)$ ,  $B(z)$  e  $C(z)$ , sendo o  $A(z)$  responsável por determinar a ordem do modelo matemático. Observa-se que o melhor modelo obtido foi para amostras de 10 dias com ordem 2221 e acurácia de 73,85%. Os polinômios gerais para um modelo ARMAX foram apresentados na Seção 2.1.2.

Com aplicação das amostras de entrada no *systemIdentification toolbox*, foram obtidos os valores dos parâmetros. Substituindo os parâmetros são obtidos os seguintes polinômios:

$$A(z) = 1 + 0,5885z^{-1} + 1,187z^{-2}$$

$$B(z) = 4372z^{-1} - 4302z^{-2}$$

$$C(z) = 1 + 0,7813z^{-1} - 0,9505z^{-2}$$

Substituindo os parâmetros do modelo ARMAX na Equação (2.10), obtêm-se assim a equação de relação entre saída e entrada do modelo, dada neste caso por:

$$y(k) = \frac{2498z^{-1} - 2435z^{-3}}{1 + 0,5813z^{-1} + 1,181z^{-2} + 0,2997z^{-3}}u(k) + \frac{1}{1 + 0,5813z^{-1} + 1,181z^{-2} + 0,2997z^{-3}}v(k) \quad (5.2)$$

### 5.3. MODELO DE HAMMERSTEIN-WIENER

Para encontrar o melhor modelo *Hammerstein-Wiener* realizou-se várias iterações combinando as funções *pwnlinear* e *sigmoidnet* e variando a ordem parâmetros da função do bloco linear, obtendo-se os índices FIT e FPE de cada modelo. As combinações das funções não lineares dos blocos de entrada e saída são apresentadas na Tabela 3.

**Tabela 3:** Estrutura dos blocos de entrada e saída

	Entrada	Saída
1	<i>Pwnlinear</i>	<i>Pwnlinear</i>
2	<i>Pwnlinear</i>	<i>Sigmoidnet</i>
3	<i>Sigmoidnet</i>	<i>Sigmoidnet</i>
4	<i>Sigmoidnet</i>	<i>Pwnlinear</i>

Fonte –Elaborado pelo autor (2021)

Testou-se várias ordens para o bloco linear para dados de radiação de 10 e 15 dias dos meses de agosto, setembro e outubro de 2020, onde foram selecionadas as que obtiveram melhor desempenho, os valores são apresentados nas Tabelas 4, 5 e 6 de acordo com as estruturas dos blocos não lineares. Os dados foram implementados na *toolbox* do Matlab, e através da sua validação encontrou-se a acurácia de cada modelo (FIT) e seu FPE.

**Tabela 4:** Desempenhos dos modelos de agosto

AGOSTO					
10 DIAS			15 DIAS		
ENTRADA	SAÍDA		ENTRADA	SAÍDA	
PWLINEAR	PWLINEAR		PWLINEAR	PWLINEAR	
ORDEM	FIT (%)	FPE	ORDEM	FIT (%)	FPE
231	87,11	110,7	221	99,5	0.2827
PWLINEAR	SIGMOIDNET		PWLINEAR	SIGMOIDNET	
ORDEM	FIT	FPE	ORDEM	FIT	FPE
222	99,87	370.4	222	86,75	385.5
SIGMOIDNET	SIGMOIDNET		SIGMOIDNET	SIGMOIDNET	
ORDEM	FIT	FPE	ORDEM	FIT	FPE
231	99,09	0.5546	231	99,94	246.9
SIGMOIDNET	PWLINEAR		SIGMOIDNET	PWLINEAR	
ORDEM	FIT	FPE	ORDEM	FIT	FPE
222	99,86	370.4	231	93,17	53.12

Fonte –Elaborado pelo autor (2021)

**Tabela 5:** Desempenhos dos modelos de setembro

SETEMBRO					
10 DIAS			15 DIAS		
ENTRADA	SAÍDA		ENTRADA	SAÍDA	
PWLINEAR	PWLINEAR		PWLINEAR	PWLINEAR	
ORDEM	FIT (%)	FPE	ORDEM	FIT (%)	FPE
221	99,91	0.01604	222	95,38	1153
PWLINEAR	SIGMOIDNET		PWLINEAR	SIGMOIDNET	
ORDEM	FIT	FPE	ORDEM	FIT	FPE
222	95,32	1730	231	95,21	1153
SIGMOIDNET	SIGMOIDNET		SIGMOIDNET	SIGMOIDNET	
ORDEM	FIT	FPE	ORDEM	FIT	FPE
222	95,32	1730	211	79,73	566
SIGMOIDNET	PWLINEAR		SIGMOIDNET	PWLINEAR	
ORDEM	FIT	FPE	ORDEM	FIT	FPE
221	99,96	0.002215	222	96,06	1153

Fonte –Elaborado pelo autor (2021)

**Tabela 6:** Desempenhos dos modelos de outubro

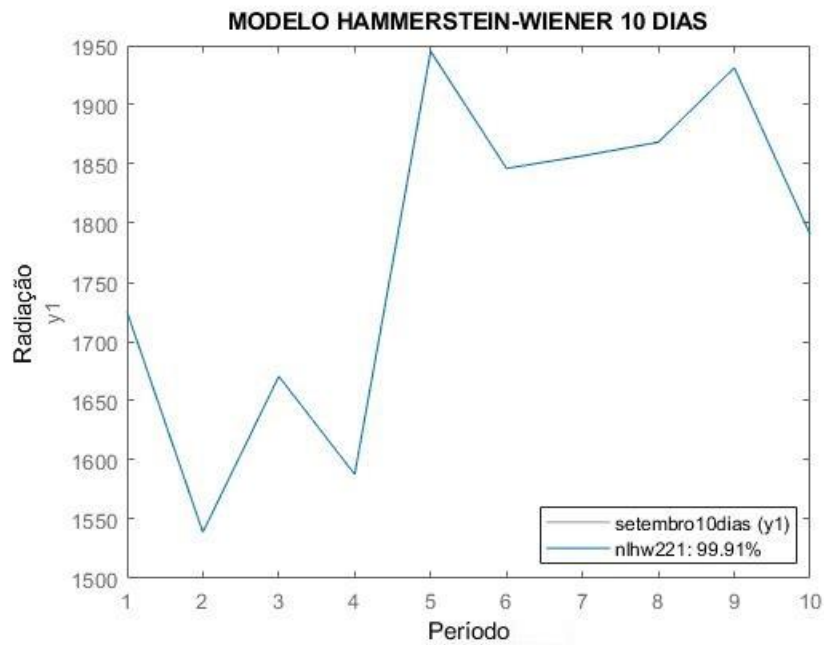
OUTUBRO					
10 DIAS			15 DIAS		
ENTRADA	SAÍDA		ENTRADA	SAÍDA	
PWLINEAR	PWLINEAR		PWLINEAR	PWLINEAR	
ORDEM	FIT (%)	FPE	ORDEM	FIT (%)	FPE
222	99,04	1566	231	97,32	1,14E-22
PWLINEAR	SIGMOIDNET		PWLINEAR	SIGMOIDNET	
ORDEM	FIT	FPE	ORDEM	FIT	FPE
222	99,73	1566	231	94,22	35.99
SIGMOIDNET	SIGMOIDNET		SIGMOIDNET	SIGMOIDNET	
ORDEM	FIT	FPE	ORDEM	FIT	FPE
222	99,78	1566	231	98,69	1.799
SIGMOIDNET	PWLINEAR		SIGMOIDNET	PWLINEAR	
ORDEM	FIT	FPE	ORDEM	FIT	FPE
222	99,03	1566	221	99,3	0.5129

Fonte –Elaborado pelo autor (2021)

As tabelas estão organizadas de acordo com o período de dados utilizados, as combinações das funções não lineares dos blocos de entrada e saída com seu respectivo modelo, a ordem do modelo e seus índices de comparação acurácia (FIT) e FPE – *Final Prediction Error*.

Nas Figuras 26, 27, 28 e 29 são apresentados os gráficos de radiação do melhor modelo *Hammerstein-Wiener* para cada combinação de estruturas dos blocos de entrada e saída apresentados na tabela 3, foram selecionados os modelos que apresentaram melhor desempenho de acurácia e FPE, sendo comparados aos dados reais experimentais.


**Figura 26:** Modelo *Pwlinear-Pwlinear*.



Fonte - O Autor (2021).




**Figura 27:** Modelo *Pwlinear-Sigmoidnet*



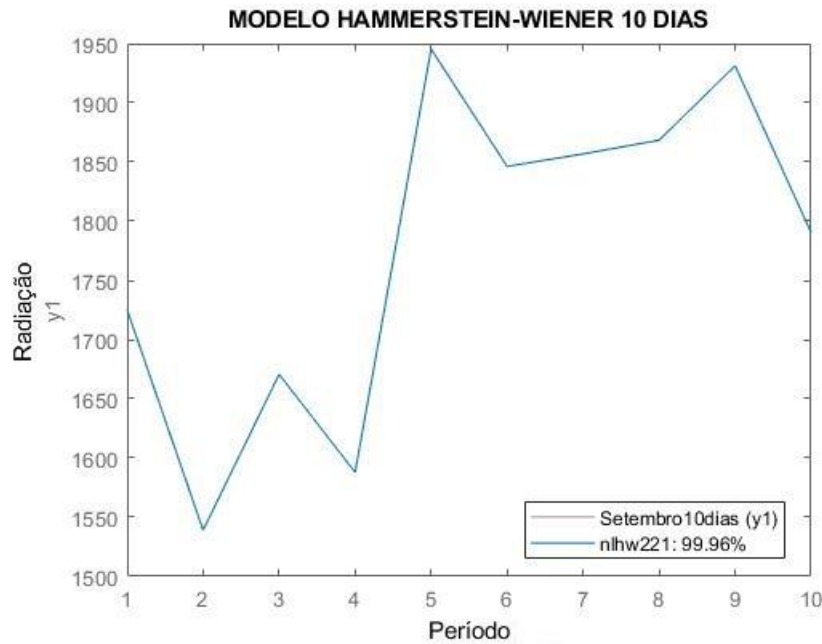
Fonte - O Autor (2021).

**Figura 28:** Modelo *Sigmoidnet-Pwlinear*



Fonte - O Autor (2021).

**Figura 29:** Modelo *Sigmoidnet-Sigmoidnet*



**Fonte – O Autor (2021)**

O modelo dinâmico do bloco linear OE é representado por dois polinômios:  $B(q)$  e  $F(q)$ . O melhor modelo obtido foi referente ao mês de setembro, com amostras de 10 dias, ordem 221, acurácia de 99,96% e FPE de 0,002215. Substituindo os parâmetros determinados são obtidos os seguintes polinômios:

$$B(q) = q^{-1} - 0,9984q^{-2}$$

$$F(q) = 1 - 0,1767q^{-1} - 0,06963q^{-2}$$

Substituindo os parâmetros do bloco linear na equação 2.11, obtêm-se assim a equação de relação entre saída e entrada do modelo, dada neste caso por:

$$y(k) = \frac{q^{-1} - 0,9984q^{-2}}{1 - 0,1767q^{-1} - 0,06963q^{-2}}u(k) + v(k) \quad (5.3)$$

## 6. CONCLUSÃO

O trabalho teve como objetivo aplicar o método de identificação de sistemas por meio da ferramenta *System Identification Toolbox* disponibilizada pelo programa *MATLAB* que é muito utilizado em algumas áreas da engenharia. Através de várias funções da ferramenta envolvendo a teoria, foi possível desenvolver uma compreensão melhor acerca do que foi proposto pelo trabalho.

Para a modelagem realizada neste trabalho foram utilizados dados meteorológicos de radiação solar, a escolha da aplicação foi devida sua relação direta com a energia solar, podendo ser uma alternativa para auxiliar na previsão do potencial solar de determinada região. Foram utilizadas 2 estruturas de modelos paramétricos lineares, sendo elas: ARX e ARMAX, também foi utilizado uma estrutura não linear *Hammerstein-Wiener* para estimar um modelo do perfil de dados de radiação.

Os modelos ARX, ARMAX, e *Hammerstein-Wiener* foram implementados e validados na ferramenta *System Identification Toolbox*. A partir dos resultados da validação dos modelos estimados ARX, ARMAX, e *Hammerstein-Wiener* foi selecionado o modelo não linear *Hammerstein-Wiener* como melhor para estimação dos dados de radiação, pelo fato de apresentar uma maior acurácia, quando comparado aos demais modelos, além de um melhor FPE. O modelo não linear *Hammerstein-Wiener* apresentou uma acurácia de 99,96% e um FPE de 0,002215, enquanto os modelos discretos ARX e ARMAX apresentaram uma acurácia de 93,49% e 73,85 respectivamente.

Conclui-se que o modelo não linear *Hammerstein-Wiener* possui os melhores resultados, quando utilizado para modelar matematicamente estimar dados de radiação, pois apresenta uma melhor acurácia.

Recomendações para trabalhos futuros:

- Aplicação em outras áreas como energia eólica;
- Aplicar em outras estruturas de modelos paramétricos lineares e não lineares;
- Utilizar banco de dados disponível na UNILAB.

## REFERÊNCIAS

AGUIRRE, L. **Introdução à identificação de sistemas**. Belo Horizonte: UFMG, 2007.

AKAIKE, H; CLEMENTS, M. P.; HENDY, D. F.; Fitting autoregressive models for prediction. **Annals of the Institute of Statistical Mathematics**, v. 21, p. 243-247, 1969.

Almeida, H. A. e Hermenegidio, G. M. S. 2013. Comparação de dados meteorológicos obtidos por estações meteorológicas convencional e automática. *Ver. Brasil. Climatol.* 12(1):32-47.

ALVES, G. B. **Propriedades das funções de base radiais aplicadas à identificação de sistemas dinâmicos não-lineares**. 2004. 158 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Escola de Engenharia, Universidade Federal de Minas Gerais, Belo Horizonte, 2004.

Atlas Brasileiro de Energia Solar – LABREN / CCST / INPE (Instituto Nacional de Pesquisas Espaciais), 2017.

Balanço Energético Nacional – EPE (Empresa de Pesquisa Energética), 2021.

BEZERRA, F. D. **Energia solar. Caderno Setorial ETENE**, Ano 5, nº 110, março de 2020. Banco do Nordeste do Brasil, 2020. Disponível em: <https://www.bnb.gov.br/s482-dspace/handle/123456789/227>. Acesso em 13 junho 2021.

BINKOWSKI, C. **Síntese das técnicas de identificação de sistemas não lineares: estruturas de modelo de hammerstein wiener e narmax**. 2016. 150 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Unidade Acadêmica de Pesquisa e Pós-Graduação, Universidade do Vale do Rio dos Sinos, São Leopoldo, 2016.

CAMPOS, R. J. **Previsão de séries temporais com aplicações a séries de consumo de energia elétrica**. Belo Horizonte, 2008, 110p. Dissertação (mestrado) - Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Minas Gerais, Belo Horizonte, 2008.

CORRÊA, M. V.; AGUIRRE, L. A. **Identificação não-linear caixa-cinza: uma revisão e novos resultados**. Sba: Controle & Automação Sociedade Brasileira de Automatica, Minas Gerais, v. 15, n. 2, p. 109-126, jun. 2004.

CORRÊA, M. V. **Identificação caixa-cinza de sistemas não lineares utilizando representações narmax racionais e polinomiais**. 2001. 289 f. Tese (Doutorado em Engenharia Elétrica) Universidade Federal de Minas Gerais, Belo Horizonte, 2001.

COELHO, M. C. D. S. **Modelos de Hammerstein e Wiener: Conexões com Modelos NARX e sua Aplicação em Identificação de Sistemas Não Lineares**. Dissertação de Mestrado. Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Minas Gerais, 2002.

CRESESB. **Radiação Solar**. Disponível: [http://www.cresesb.cepel.br/index.php?section=com\\_content&lang=pt&cid=301](http://www.cresesb.cepel.br/index.php?section=com_content&lang=pt&cid=301). Acesso em: 05 de julho de 2021.

DOMINGOS, S. F., MONTEIRO, L. G., & Boaventura, W. C. **Estado da Arte para Previsão da Radiação Solar**. VIII Congresso Brasileiro de Energia Solar. Fortaleza, 2020.

EPE – Empresa de Pesquisa Energética. **Nota Técnica. Análise da Inserção da Geração Solar na Matriz Elétrica Brasileira**. Rio de Janeiro. 2012.

EPE – Empresa de Pesquisa Energética. Nota Técnica. **ENERGIA SOLAR PARA SUPRIMENTO DE SISTEMAS ISOLADOS DO AMAZONAS**: Avaliação da atratividade econômica de solução híbrida em sistemas do Grupo B do Projeto de Referência da Eletrobras Distribuição Amazonas. Rio de Janeiro. 2012.

Mundo Clima. **Estação Meteorológica Automática Mercury**. Disponível em <https://www.mundoclima.com.br/produtos/estacao-meteorologica-automatica-mercury/>. Acesso em: 15 de ago. de 2021.

FERREIRA, F. E. **Identificação de Modelos de Hammerstein e Wiener com Curva Estática Intervalar**. 2017. 66 f. TCC (Graduação) - Curso de Engenharia Elétrica,

Departamento de Engenharia Elétrica, Universidade Federal de Ouro Preto, João Monlevade, 2017.

FERNANDES, C. V. **Modelagem de banco de dados não relacional em plataforma Big Data visando dados de Internet das Coisas**. Trabalho de Conclusão de Curso (Especialização)-Universidade Federal de Mato Grosso (UFMT), Mato Grosso, 2017.

FIORIN, D. V.; MARTINS, F. R.; SCHUCH, N. J. **Aplicações de redes neurais e previsões de disponibilidade de recursos energéticos solares**. Revista Brasileira de Ensino de Física, v. 33, n. 1, p. 1309 1-1309 20, 2011.

LJUNG, L. **System Identification Theory for the user**. E ed. Upper Saddle River, NJ, EUA: Prentice Hall, 1999.

LARICO, E. R. E. **Identificação de modelos não-lineares com estruturas NARX e Hammertein-Wiener aplicados a uma planta de neutralização de pH**. 2020. 124 f. Dissertação (Mestrado) - Curso de Engenharia de Sistemas, Escola Politécnica da Universidade de São Paulo, Universidade de São Paulo, São Paulo, 2020.

NETO, B. N. **IDENTIFICAÇÃO DO COMPORTAMENTO DA TEMPERATURA DO RETIFICADOR PRINCIPAL DE UMA LOCOMOTIVA DIESEL-ELÉTRICA**. 2010. 93 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Centro de Ciências Exatas e Tecnologia, Universidade Federal do Maranhão, São Luís, 2010.

ORENSTEIN, L. P. **Procedimento para identificação de sistemas dinâmicos em ambiente industrial**. Rio de Janeiro: Universidade Federal do Rio de Janeiro, 2013.

PEREIRA, L.M.P.; CARAMORI, P.H.; RICCE, W.S.; CAVIGLIONE, J.H. **Análise comparativa de dados meteorológicos obtidos por estação convencional e automática em Londrina**. **Semina: Ciências Agrárias**, v. 29, n. 2, p. 299-306, 2008.

ROMIO, L. C. **Modelagem matemática do tempo de vida de baterias utilizando a teoria de Identificação de Sistemas**. Dissertação de Mestrado, Universidade Regional do Noroeste do Estado do Rio Grande do Sul, Ijuí-RS, mar. 2013.

SANTOS, J. E. S. **Controle Preditivo Não-Linear para Sistemas de Hammerstein**. Tese de Doutorado. Universidade Federal de Santa Catarina, Florianópolis: 2007.

SILVA, R. P. **Introdução à Identificação de Sistemas utilizando o System Identification Toolbox do MATLAB em conjunto com o Arduino para o Laboratório de Controle Linear**. 2015. 61 f. Trabalho de Graduação (Graduação em Engenharia Elétrica) – Faculdade de Engenharia do Campus de Guaratinguetá, Universidade Estadual Paulista, Guaratinguetá, 2010.

SILVA, F. D. L, CARVALHO, C.C.M. **APLICAÇÃO DE REDES NEURAIS NA PREVISÃO DA RADIAÇÃO SOLAR**. In: CONGRESSO BRASILEIRO DE REDES NEURAIS / INTELIGÊNCIA COMPUTACIONAL (IX CBRN), 9., 2009, Fortaleza. Anais do IX Congresso Brasileiro de Redes Neurais. Ouro Preto: Sbrn, 2009. p. 1-4.

SOUSA, J. **Aplicação das técnicas de identificação de sistemas não-lineares à modelagem de fornos elétricos a arco**, Dissertação de Mestrado, Pontifícia Universidade Católica de Minas Gerais, Minas Gerais, 2005.

TORRES, João Delfino et al. **Aquisição de dados meteorológicos através da plataforma Arduino: construção de baixo custo e análise de dados**. Scientia Plena, v. 11, n. 2, 2015.