

## 5 MODELO DE PREDIÇÃO UTILIZANDO REDES NEURAIAS

### 5.1. Introdução

As redes neurais emulam certas características próprias dos humanos, como a capacidade de memorizar e de associar fatos. Se forem examinados com atenção aqueles problemas que não se podem expressar através de um algoritmo, é possível observar que todos eles têm uma característica em comum: a experiência. O home é capaz de resolver estas situações acudindo a experiência acumulada. Então, as redes neurais simulam um modelo artificial e simplificado do cérebro humano capaz de adquirir conhecimento através da experiência. A aprendizagem significa que aqueles problemas que inicialmente não se podem resolver, podem ser resolvidos depois de se obter mais informações acerca do problema.

As redes neuronais consistem de unidades de processamento que intercambiam dados ou informação; utilizam-se para reconhecer padrões, incluindo imagens, manuscritos e seqüências de tempos (por exemplo: tendências financeiras); e têm capacidade de apreender e melhorar seu funcionamento.

### 5.2. Parâmetros Experimentais Analisados

#### 5.2.1. Rendimento Térmico

O rendimento térmico ou eficiência de uma máquina térmica é uma magnitude definida como a razão entre a energia que desejamos obter de dita máquina e a energia que se deve fornecer para o seu funcionamento. Designa-se com a letra grega  $\eta$ , como apresentado na equação a seguir.

$$\eta_{T,D/G} = \frac{E_{OBTIDA}}{E_{UTILIZADA}} \dots\dots\dots (7)$$

Para o estudo do rendimento térmico em motores de combustão a equação anterior fica:

$$\eta_{T,D/G} = \frac{P}{PCI_D \times \dot{m}_D + PCI_{GN} \times \dot{m}_{GN}} \dots\dots\dots (8)$$

Onde:

P é a potência no eixo do motor, W

$\eta_{T,D/G}$  é o rendimento térmico do motor,

$\dot{m}_D$  é o vazão mássica de combustível diesel, kg/s

$\dot{m}_{GN}$  é o vazão mássica de gás natural, kg/s

$PCI_D$  é o poder calorífico do diesel, J / kg

$PCI_{GN}$  é o poder calorífico do gás natural, J / kg

### 5.2.2. Consumo de Combustíveis

O Consumo de diesel é um parâmetro associado diretamente à eficiência do motor. No caso de funcionamento com o gás natural, o diesel cumpre a função de iniciar a combustão dentro da câmara.

O consumo de gás natural é um parâmetro que determina a taxa de substituição e, em conseqüência, a economia por diminuição do consumo de diesel.

### 5.2.3. Taxa de substituição

A taxa de substituição representa a quantidade de diesel que foi substituída por gás natural. Como o diesel e o gás natural têm características termo-físicas diferentes, a taxa de substituição é definida com base na relação da vazão do diesel atual e a vazão correspondente original (operação 100% diesel).

$$TS_{D/G} = \left( 1 - \left( \frac{\dot{m}_D}{\dot{m}_{D,O}} \right) \right) \times 100\% \dots\dots\dots (9)$$

$TS_{D/G}$  é a taxa de substituição, %

$\dot{m}_D$  é o vazão mássica do diesel, kg/h

$\dot{m}_{D,O}$  é o vazão mássica original de diesel (100% diesel), kg/h

#### 5.2.4. Monóxido de Carbono (CO)

O monóxido de carbono é um gás inodoro, incolor e de sabor ácido que tende a depositar-se nas zonas baixas por ser mais pesado que o ar. É um químico produzido a partir da queima incompleta de alguns combustíveis fósseis que contém carbono, como: a queima de carvão, gasolina, querosene, diesel, propano ou madeira. A queima pode ser em motores de combustão, grelha ou forno de carvão de lenha, sistemas de calefação, aquecedores de propano, estufas, aquecedores de água, etc. Quando inalado, o CO substitui o oxigênio no sangue e em consequência, o coração, o cérebro e o corpo padecem sem este.

#### 5.2.5. Hidrocarbonetos não queimados (HC)

Os hidrocarbonetos não queimados são uma mistura de compostos que se produzem por falta de oxigênio no processo de combustão incompleta de todo o hidrocarboneto fornecido, formando a conhecida névoa fotogênica.

#### 5.2.6. Óxidos de Nitrogênio (NO<sub>x</sub>)

A emissão deste tipo de poluente é Independente do processo de combustão, devido a que em altas pressões e temperaturas, que se geram na câmara de combustão, o nitrogênio e o oxigênio presentes no ar reagem, dando lugar aos óxidos de nitrogênio. As altas temperaturas e o excesso de O<sub>2</sub> favorecem a aparição destes gases.

Esta substância é muito danosa para o meio ambiente, sendo responsável pelo efeito estufa, além de provocar a destruição da camada de ozônio

estratosférico. O  $\text{NO}_x$  é um gás incolor, que rapidamente se combina com o  $\text{O}_2$  na atmosfera formando  $\text{NO}_2$ , que ao se decompor em contato com a água, produz ácido nitroso ( $\text{HNO}_2$ ) e ácido nítrico ( $\text{HNO}_3$ ) os quais são altamente corrosivos. Quando ascende à atmosfera e faz contato com a chuva, se forma a conhecida chuva ácida.

### **5.3. Parâmetros Avaliados**

Para a avaliação da rede neural foram utilizados os dados experimentais do trabalho de CUISANO 0. Os parâmetros foram os seguintes.

#### **5.3.1. Variáveis Independentes**

Rotação (1000 RPM, 1300 RPM, 1600 RPM, 1850 RPM, 2100 RPM e 2600 RPM).

Carga (10%, 25%, 50%, 75% e 100%).

Taxa de substituição (valores entre 0% e 90%).

#### **5.3.2. Variáveis Dependentes**

Temperatura dos gases de escapamento.

Consumo de ar.

Emissões (CO, HC,  $\text{NO}_x$ ).

Consumo de diesel.

Consumo de gás natural.

Rendimento térmico.

### **5.4. Arquitetura do modelo da Rede Neuronal**

Um esquema de funcionamento da rede pode ser observado no diagrama de blocos da

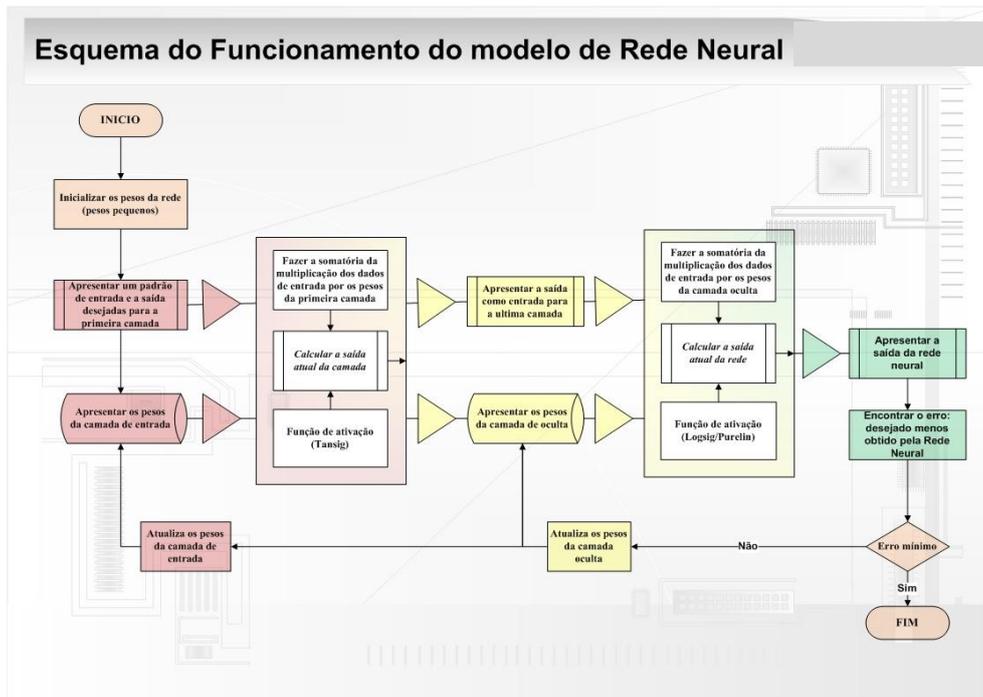


Figura 18.

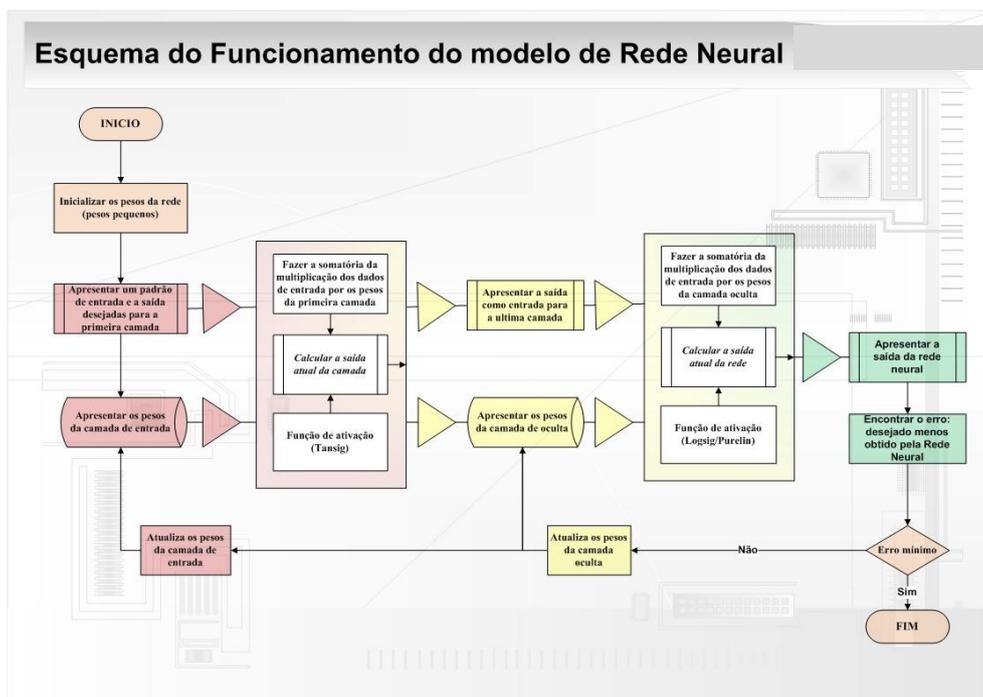


Figura 18. Diagrama de blocos do funcionamento da rede neural.

Para poder modelar a rede neural, é necessário determinar o tipo de arquitetura; neste caso optou-se por uma arquitetura de multicamadas.

As redes multicamada são aquelas que dispõem de conjuntos de neurônios agrupados em vários níveis ou camadas. Normalmente todos os

neurônios de uma camada recebem sinais de entrada de outra camada anterior e enviam os sinais de saída para uma camada posterior. Às conexões se lhes denominam “*feed-forward*”. A Figura 19 mostra esta distribuição. A partir de sua situação dentro da rede, podem-se distinguir três tipos de camadas:

- De entrada: É a camada que recebe diretamente a informação proveniente das fontes externas da rede.
- Ocultas: São internas à rede e não têm contato direto com o entorno exterior. O número de níveis ocultos pode ser zero, um ou mais.
- De Saída: Transferem informação da rede para o exterior.

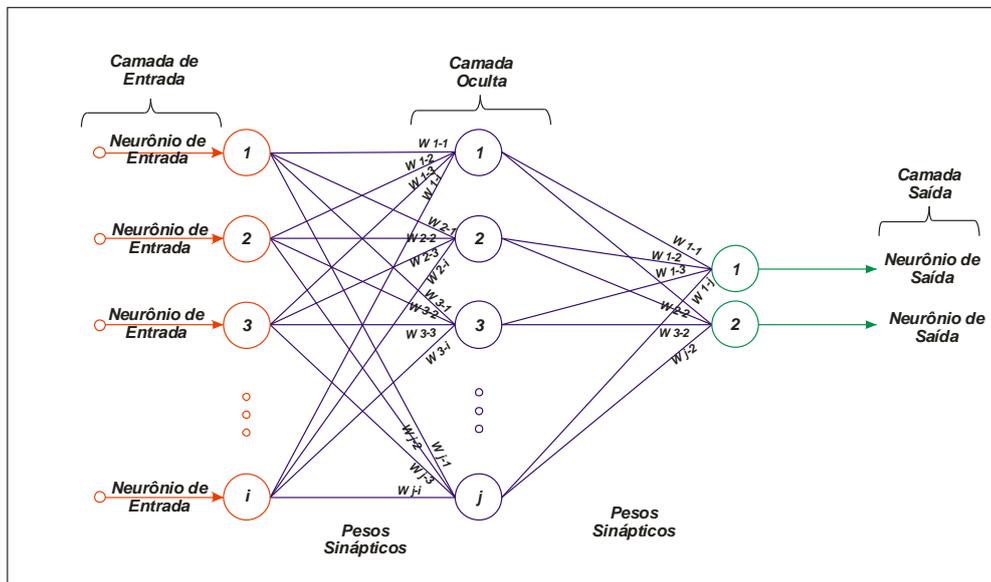


Figura 19. Estrutura de uma rede multicamada.

Para o modelo de rede escolhido, têm-se duas arquiteturas (Figura 20 e Figura 21). Na primeira arquitetura (Figura 20) tem-se uma distribuição de três camadas (camada de entrada, oculta, e saída).

Para a camada de entrada são fornecidos os dados experimentais para rede neural:

- Rotação (RPM).
- Porcentagem de carga (%).
- Vazão de ar Seco (kg/h).
- Vazão de gás natural (kg/h).

Para a camada de saída tem-se:

- Rendimento térmico (%).
- Vazão de diesel (kg/h).
- Temperatura dos gases de escapamento (°C).

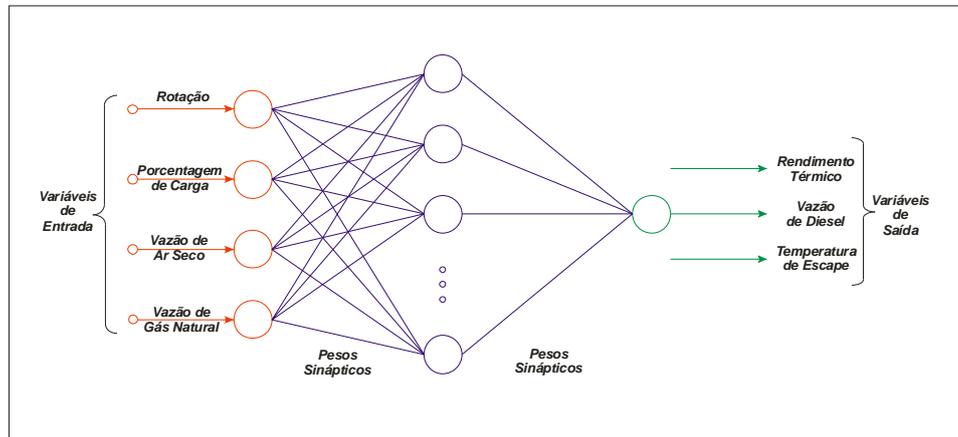


Figura 20. Primeiro Modelo de Rede Neuronal

Na segunda arquitetura (Figura 21) tem-se, também, uma distribuição de três camadas (camada de entrada, oculta e saída).

Para a camada de entrada são fornecidos os dados para rede neural:

- Rotação (RPM).
- Porcentagem de carga (%).
- Vazão de ar seco (kg/h).
- Vazão de consumo de gás natural (kg/h).
- Rendimento térmico (%).
- Temperatura dos gases de escapamento (°C).

E para a camada de saída temos:

- Emissões de CO (PPM).
- Emissões de HC (PPM).
- Emissões de NO<sub>x</sub> (PPM).

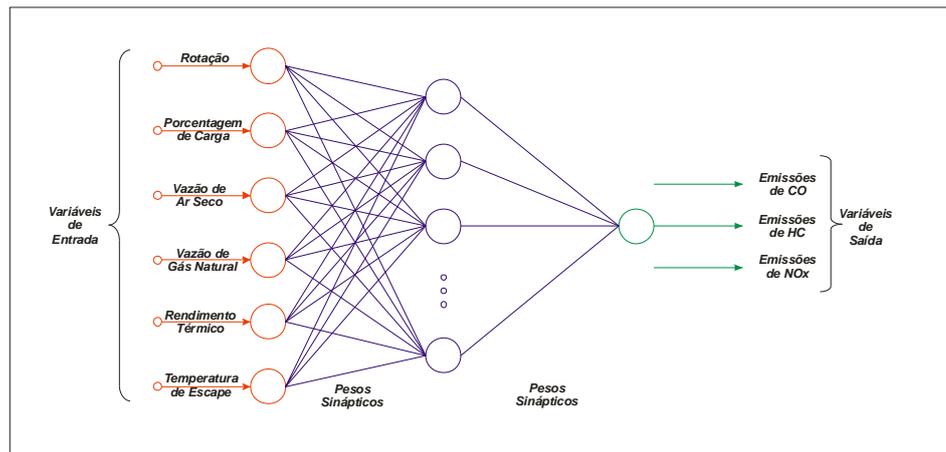


Figura 21. Segundo Modelo de Rede Neuronal

### 5.5. Função de Ativação

Para o modelo foram empregados os três tipos mais conhecidos de funções de ativação (Figura 22).

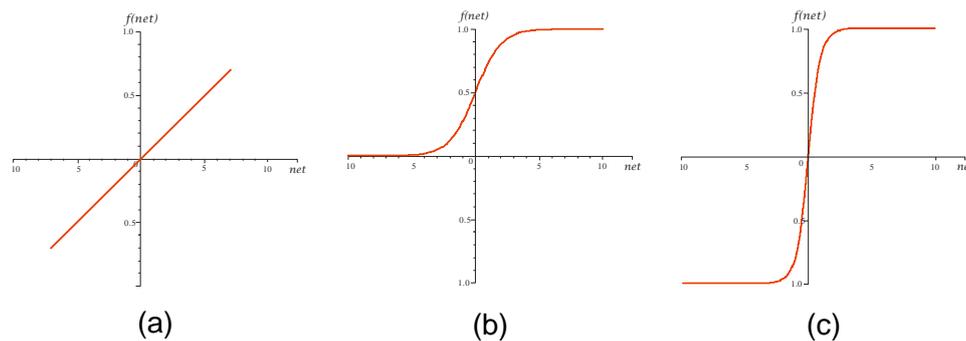


Figura 22. Funções de Ativação: (a) Linear, (b) Sigmóide, (c) Tangente Sigmóide.

A Tabela 3 mostra as funções de ativação com cada parâmetro avaliado.

Tabela 3 Lista das funções de ativação dos modelos neuronais.

Variáveis	FUNÇÃO DE ATIVAÇÃO	
	CAMADA ENTRADA - ESCONDIDA	CAMADA ESCONDIDA - SAIDA
Emissões de CO	Tangente sigmóide	Sigmóide
Emissões de Nox	Tangente sigmóide	Sigmóide
Emissões de HC	Tangente sigmóide	Sigmóide
Temperatura de Escape	Tangente sigmóide	Linear
Consumo de diesel	Tangente sigmóide	Sigmóide
Rendimento Térmico	Tangente sigmóide	Linear

Um neurônio pode estar ativo (excitado) ou inativo (não excitado); ou seja, que tem um “estado de ativação”. A função de ativação calcula o estado de atividade de um neurônio; transformando as entrada em um valor (estado) de

ativação, cujo intervalo normalmente vai de 0 até 1 ou de -1 até 1. Este é assim porque um neurônio pode estar totalmente inativo (0 ou -1) ou ativo (1). A função de ativação produz um novo estado de ativação de um neurônio a partir do estado atual que existia e a combinação das entradas com os pesos das conexões (net). Cada uma das funções de ativação é mostrada a seguir.

Funções de Ativação Linear

$$f(x) = net \dots\dots\dots(10)$$

Funções de Ativação Sigmóide

$$f(x) = \frac{1}{1 + e^{-\lambda net}} \dots\dots\dots(11)$$

Funções de Ativação Tangente Sigmóide

$$f(x) = \frac{e^{\lambda x} - e^{-\lambda x}}{e^{\lambda x} + e^{-\lambda x}} \dots\dots\dots(12)$$

Onde:

- net      é o somatório das multiplicações de cada peso por sua respectiva entrada.
- x        valor da entrada da função
- λ        é um parâmetro de aprendizagem

**5.6. Mecanismos de Aprendizagem**

A aprendizagem pode ser compreendida como a modificação de comportamento induzido pela interação com o entorno, ou seja, como o resultado de experiências conduz ao estabelecimento de novos modelos de resposta a estímulos externos. No cérebro humano o conhecimento se encontra na sinapse (conexão que existem entre neurônios biológicos). No caso das RNA

o conhecimento se encontra nos pesos das conexões entre neurônios. Todo processo de aprendizagem implica em certo número de mudanças nestas conexões. Uma rede é treinada de maneira que uns conjuntos de valores de entrada produzam a saída desejada. Durante o treinamento ou aprendizagem, os pesos se vão ajustando/modificando gradualmente, até determinar aqueles que gerem as saídas desejadas.

Existem dois tipos de treinamento da RNA: treinamento com supervisão e treinamento sem supervisão. No caso em questão, tem-se um treinamento supervisionado, porque os dados de entrada são relacionados com uma saída desejada. A cada par de dados que representam os valores de entrada e saída desejada, dá-se o nome de par de treinamento.

Foi usado o método conhecido como *Back-propagation*, baseado na generalização da regra delta e, apesar das suas próprias limitações, têm ampliado de forma considerável o intervalo de aplicações nas redes neuronais.

O algoritmo de propagação *Back-propagation* é uma regra de aprendizagem que se pode aplicar em modelos de redes com mais de duas camadas de células. Uma característica importante deste algoritmo é a representação interna do conhecimento que é capaz de organizar na camada intermediária das células para conseguir qualquer correspondência entre a entrada e a saída para a resolução do problema.

## **5.7. Processo de Convergência**

Uma ferramenta padrão da estatística conhecida como “validação cruzada” fornece um princípio orientador atraente onde, primeiramente, o conjunto de dados é dividido aleatoriamente em um conjunto de treinamento e num conjunto de teste. O conjunto de treinamento é dividido adicionalmente em dois subconjuntos disjuntos.

- a) Subconjunto de estimação, usado para selecionar o modelo.
- b) Subconjunto de validação, usado para testar ou validar o modelo.

O objetivo é validar o modelo com um conjunto de dados diferentes daquele que foi usado para estimar os parâmetros. Desta forma, pode-se usar o conjunto de treinamento para validar vários candidatos e, assim, escolher o “melhor”. Porém, para evitar que o modelo ajuste excessivamente o subconjunto de validação e lograr um bom desempenho de generalização, o desempenho é

medido sobre um subconjunto de teste, diferente do subconjunto de validação. Assim a rede neural será selecionada por aquela que tenha o menor erro possível num ponto. Se, a partir deste ponto o erro dos dados de treinamento cresce, então o treinamento finaliza (Figura 23).

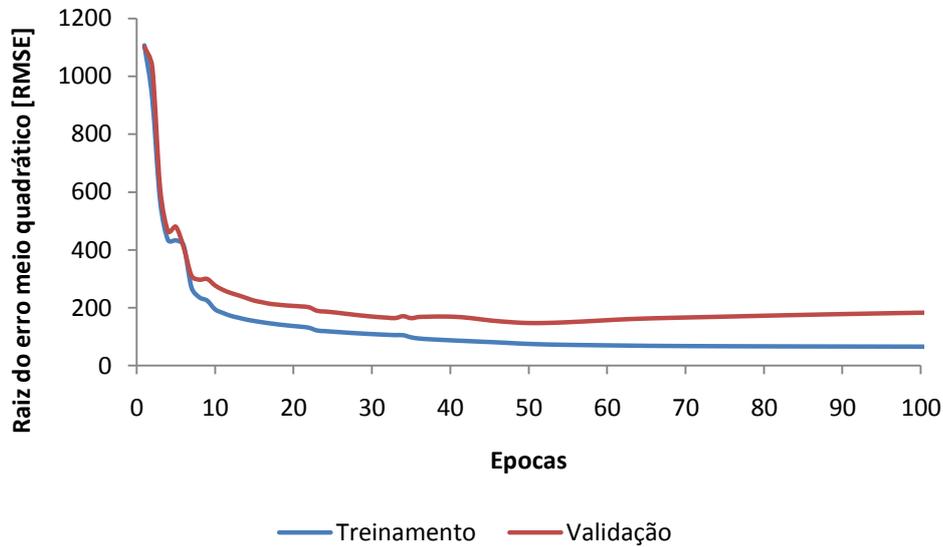


Figura 23. Validação cruzada y/o convergência de dados.

**5.8. Métricas do erro.**

Há vários métodos de medidas de erro que permitem a comparação do desempenho da predição com os valores observados. Os dois métodos comumente usados são o RMSE (Raiz do erro quadrático médio) e o MAPE (Erro médio absoluto porcentual). Onde definimos como:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N y_i - a_i}{N}} \dots\dots\dots(13)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - a_i}{a_i} \right| \dots\dots\dots(14)$$

Onde:

$y_i$  = O valor previsto.

$a_i$  = O valor observado/original.

$N$  = O número de observações.

A desvantagem do RMSE é sua sensibilidade a valores anômalos e a desvantagem da medida MAPE é que impõe uma penalidade maior às previsões que excedem os valores atuais do que àquelas que subestima. Visto que RMSE e o MAPE apresentam vantagens e desvantagens, eles foram igualmente utilizados neste trabalho, admitindo-se que o menor desses valores indica a previsão mais precisa.

Para auxiliar no julgamento do desempenho de um modelo de regressão, THEIL propôs um índice conhecido na literatura como índice U-Theil.

$$U - Theil = \frac{\sqrt{\frac{1}{N} \sum_{i=1}^N y_i - a_i^2}}{\sqrt{\frac{1}{N} \sum_{i=1}^N y_i^2 + \frac{1}{N} \sum_{i=1}^N a_i^2}} \dots\dots\dots(15)$$

Onde:

$y_i$  = O valor previsto.

$a_i$  = O valor observado/original.

$N$  = O número de observações.

Onde o índice de desigualdade de Theil (U-Theil ) avalia o ajuste da série prevista à série original. Quanto mais perto de zero, melhor o ajuste da série prevista em relação à série original. Porém, quando tem valores maiores do que zero, próximos a um, significa que o modelo não conseguiu fazer boas previsões.