



UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
Campus de Ilha Solteira

**PREVISÃO DE DEMANDA DE CARGAS ELÉTRICAS POR SELEÇÃO DE
VARIÁVEIS *STEPWISE* E REDES NEURAIS ARTIFICIAIS**

MARLEIDE FERREIRA ALVES

Ilha Solteira
2013

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

“Previsão de Demanda de Cargas Elétricas por Seleção de Variáveis Stepwise e Redes Neurais Artificiais”

Marleide Ferreira Alves

Orientadora: Prof. Dr^a. Anna Diva Plasencia Lotufo

Coorientadora: Prof^a Dr^a Mara Lúcia Martins Lopes

Dissertação apresentada à Faculdade de Engenharia - UNESP – Campus de Ilha Solteira, para obtenção do título de Mestre em Engenharia Elétrica.
Área de Conhecimento: Automação.

FICHA CATALOGRÁFICA
Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

A474p Alves, Marleide Ferreira.
Previsão de demanda de cargas elétricas por seleção de variáveis stepwise e redes neurais artificiais / Marleide Ferreira Alves. -- Ilha Solteira: [s.n.], 2013
73 f. : il.

Dissertação (mestrado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2013

Orientador: Anna Diva Plasencia Lotufo
Co-orientador: Mara Lúcia Martins Lopes
Inclui bibliografia

1. Rede neural perceptron multicamadas. 2. Algoritmo backpropagation. 3. Stepwise. 4. Previsão de cargas elétricas.



UNIVERSIDADE ESTADUAL PAULISTA
CAMPUS DE ILHA SOLTEIRA
FACULDADE DE ENGENHARIA DE ILHA SOLTEIRA

CERTIFICADO DE APROVAÇÃO

TÍTULO: Previsão de demanda de cargas elétricas por seleção de variáveis Stepwise e redes neurais artificiais

AUTORA: MARLEIDE FERREIRA ALVES

ORIENTADORA: Profa. Dra. ANNA DIVA PLASENCIA LOTUFO

CO-ORIENTADORA: Profa. Dra. MARA LÚCIA MARTINS LOPES

Aprovada como parte das exigências para obtenção do Título de Mestre em Engenharia Elétrica ,
Área: AUTOMAÇÃO, pela Comissão Examinadora:


Profa. Dra. ANNA DIVA PLASENCIA LOTUFO

Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira


Profa. Dra. MARIA DO CARMO G DA SILVEIRA

Departamento de Engenharia Elétrica / Universidade Estadual Paulista "Júlio de Mesquita Filho"


Profa. Dra. ELIZETE DE ANDRADE AMORIM

Centro de Engenharia e Ciências Exatas Cece / Universidade Estadual do Oeste do Paraná

Data da realização: 06 de setembro de 2013.

DEDICO

Á minha mãe Ernestina Ferreira Alves e ao meu pai Dejair Alves (*in memorian*) e aos meus irmãos Jean e Douglas.

AGRADECIMENTOS

A Deus que sempre esteve em meu caminho me guiando e me mostrando o quão é maravilhoso o mundo do conhecimento, por jamais ter me deixado desanimar em meu caminho e sempre que estive em dificuldades lá estava Ele para me ajudar.

À minha mãe e ao meu pai, que sempre estiveram ao meu lado guiando os meus passos e me aconselhando.

Às minhas amigas Ângela e Carol.

À minha orientadora Anna Diva pela acolhida e apoio dedicado.

À minha coorientadora Mara Lúcia pela dedicação e desprendimento em nosso trabalho.

Aos meus colegas de laboratório Cícero, Thays e Júnior pela torcida e os conselhos.

A CAPES pelo apoio financeiro.

RESUMO

Com o aumento na demanda por energia elétrica o planejamento de geração, transmissão e distribuição bem como a operação são importantes para uma prestação de serviços de forma eficiente, econômica e confiável. Uma das ferramentas para gestão desses recursos são os modelos de previsão de séries temporais. Há diversos modelos na literatura, como os modelos de regressão, modelos estatísticos, dentre outros. Outro modelo que vem se destacando na literatura é a previsão utilizando as redes neurais artificiais, pela sua capacidade de aprendizado. As redes neurais possuem várias arquiteturas, e uma em particular, que é considerada padrão na literatura, é a rede *perceptron* multicamadas com o algoritmo *backpropagation*. O presente trabalho propõe uma rede neural híbrida composta pelo método de regressão linear com seleção de variáveis *stepwise* juntamente com a rede neural artificial *perceptron* multicamadas com o algoritmo *backpropagation*. O objetivo é obter um método simples e eficaz para redução de variáveis sem perda de qualidade de previsão. O modelo de regressão linear com o método de seleção de variáveis *stepwise* tem a função de selecionar as variáveis mais relevantes para compor o conjunto de dados de entrada para treinamento/diagnóstico da rede neural *perceptron* multicamadas com o algoritmo *backpropagation* que, conseqüentemente, é a responsável em realizar a previsão de carga elétrica. Com esta proposta busca-se uma metodologia que seja capaz de reduzir a quantidade de variáveis de entrada da rede neural e obter resultados satisfatórios, ou seja, boas previsões. Para corroborar a metodologia proposta são apresentados os resultados da previsão de carga elétrica a curto prazo em um período de 24 e 48 horas a frente, considerando-se os dados históricos de uma companhia do setor elétrico.

Palavras-chave: Rede neural *Perceptron* multicamadas. Algoritmo *backpropagation*, *stepwise*. Previsão de cargas elétricas.

ABSTRACT

With the increase in electric energy demand the planning of generation, transmission and distribution as well as the operation are important to provide services efficiently, economically and reliably. One of the tools to manage those resources are time series model forecasting. There are several models in the literature, as the regression models, statistical models, among others. Other model that has been highlighted in the literature is the forecasting using artificial neural network, due to the capacity of learning. Neural networks have several architectures, and one in particular, that is considered standard in the literature is the multilayer perceptron network with the backpropagation algorithm. The present work proposes a hybrid neural network composed by the linear regression method with stepwise variable selection with the multilayer perceptron artificial neural network with the backpropagation algorithm. The aim is to provide a simple and effective method to reduce the variables without losing the forecasting quality. The function of the linear regression model with stepwise variable selection is to select the more relevant variables to compose the input data set to training/ diagnostic of the multilayer perceptron neural network with the backpropagation algorithm that, consequently, is the responsible to realize the electric load forecasting. The aim of this proposal is to find a methodology that reduces the amount of input variables of the neural network and obtain satisfactory results. To verify the proposed methodology results are presented for electric short-term load forecasting in a period of 24 and 48 hours ahead, considering the historical data obtained from a company pertaining to the electrical sector.

Keywords: Multilayer perceptron neural network. Backpropagation algorithm. Stepwise. Electric load forecasting.

LISTA DE ILUSTRAÇÕES

Figura 1 - Ilustração da classificação da correlação linear	20
Figura 2 - Exemplo de linha de regressão	21
Figura 3 - Desvios sobre a reta de regressão	23
Figura 4 - Fluxograma do método <i>forward</i>	27
Figura 5 - Fluxograma do método <i>backward</i>	28
Figura 6 - Fluxograma do método <i>stepwise</i>	30
Figura 7 - Neurônio de McCulloch-Pitts	31
Figura 8 - Função relé	32
Figura 9 - Função logística	33
Figura 10 - Função sigmóide	33
Figura 11 - Rede neural <i>perceptron</i> multicamadas	34
Figura 12 - Rede neural híbrida.	38
Figura 13 - Resultado da previsão de carga obtida pela RLM para o dia 01/08/1990 - Aplicação 1 no 1º Período	45
Figura 14 - Resultado da previsão de carga obtida pela RLM para os dias 01 e 02/08/1990 - Aplicação 1 no 1º Período	45
Figura 15 - Resultado da previsão de carga obtida pelo modelo híbrido para o dia 01/08/1990 - Aplicação 1 no 1º Período	46
Figura 16 - Resultado da previsão de carga obtida pelo modelo híbrido para os dias 01 e 02/08/1990 - Aplicação 1 no 1º Período	46
Figura 17 - Resultado da previsão de carga obtida pela RLM para o dia 01/08/1990 - Aplicação 2 no 1º Período	48
Figura 18 - Resultado da previsão de carga obtida pela RLM para os dias 01 e 02/08/1990 - Aplicação 2 no 1º Período	48
Figura 19 - Resultado da previsão de carga obtida pelo modelo híbrido para o dia 01/08/1990 - Aplicação 2 no 1º Período	49
Figura 20 - Resultado da previsão de carga obtida pelo modelo híbrido para os dias 01 e 02/08/1990 - Aplicação 2 no 1º Período	49
Figura 21 - Resultado da previsão de carga obtida pela RLM para o dia 01/08/1990 - Aplicação 3 no 1º Período	51
Figura 22 - Resultado da previsão de carga obtida pela RLM para os dias 01 e 02/08/1990 - Aplicação 3 no 1º Período	51
Figura 23 - Resultado da previsão de carga obtida pelo modelo híbrido para o dia 01/08/1990 - Aplicação 3 no 1º Período	52
Figura 24 - Resultado da previsão de carga obtida pelo modelo híbrido para os dias 01 e 02/08/1990 - Aplicação 3 no 1º Período	52
Figura 25 - Resultado da previsão de carga obtida pela RLM para o dia 01/08/1990 - Aplicação 1 no 2º Período	53
Figura 26 - Resultado da previsão de carga obtida pela RLM para os dias 01 e 02/08/1990 - Aplicação 1 no 2º Período	54

Figura 27 - Resultado da previsão de carga obtida pelo modelo híbrido para o dia 01/08/1990 - Aplicação 1 no 2º Período	54
Figura 28 - Resultado da previsão de carga obtida pelo modelo híbrido para os dias 01 e 02/08/1990 - Aplicação 1 no 2º Período	55
Figura 29 - Resultado da previsão de carga obtida pela RLM para o dia 01/08/1990 - Aplicação 2 no 2º Período.	56
Figura 30 - Resultado da previsão de carga obtida pela RLM para os dias 01 e 02/08/1990 - Aplicação 2 no 2º Período	56
Figura 31 - Resultado da previsão de carga obtida pelo modelo híbrido para o dia 01/08/1990 - Aplicação 2 no 2º Período	57
Figura 32 - Resultado da previsão de carga obtida pelo modelo híbrido para os dias 01 e 02/08/1990 - Aplicação 2 no 2º Período	57
Figura 33 - Resultado da previsão de carga obtida pela RLM para o dia 01/08/1990 - Aplicação 3 no 2º Período	59
Figura 34 - Resultado da previsão de carga obtida pela RLM para os dias 01 e 02/08/1990 - Aplicação 3 no 2º Período	59
Figura 35 - Resultado da previsão de carga obtida pelo modelo híbrido para o dia 01/08/1990 - Aplicação 3 no 2º Período	60
Figura 36 - Resultado da previsão de carga obtida pelo modelo híbrido para os dias 01 e 02/08/1990 - Aplicação 3 no 2º Período	60
Figura 37 - Resultado da previsão de carga obtida pela RLM para o dia 01/08/1990 - Aplicação 1 no 3º Período.	62
Figura 38 - Resultado da previsão de carga obtida pela RLM para os dias 01 e 02/08/1990 - Aplicação 1 no 3º Período	62
Figura 39 - Resultado da previsão de carga obtida pelo modelo híbrido para os dias 01 e 02/08/1990 - Aplicação 1 no 3º Período	63
Figura 40 - Resultado da previsão de carga obtida pelo modelo híbrido para os dias 01 e 02/08/1990 - Aplicação 1 no 3º Período	63
Figura 41 - Resultado da previsão de carga obtida pela RLM para o dia 01/08/1990 - Aplicação 2 no 3º Período	65
Figura 42 - Resultado da previsão de carga obtida pela RLM para os dias 01 e 02/08/1990 - Aplicação 2 no 3º Período	65
Figura 43 - Resultado da previsão de carga obtida pelo modelo híbrido para os dias 01 e 02/08/1990 - Aplicação 2 no 3º Período	66
Figura 44 - Resultado da previsão de carga obtida pelo modelo híbrido para os dias 01 e 02/08/1990 - Aplicação 2 no 3º Período	66
Figura 45 - Resultado da previsão de carga obtida pela RLM para o dia 01/08/1990 - Aplicação 3 no 3º Período	68
Figura 46 - Resultado da previsão de carga obtida pela RLM para os dias 01 e 02/08/1990 - Aplicação 3 no 3º Período	68
Figura 47 - Resultado da previsão de carga obtida pelo modelo híbrido para os dias 01 e 02/08/1990 - Aplicação 3 no 3º Período	69
Figura 48 - Resultado da previsão de carga obtida pelo modelo híbrido para os dias 01 e 02/08/1990 - Aplicação 3 no 3º Período	69

LISTA DE TABELAS

Tabela 1 - Conjunto das variáveis com maiores correlações nos períodos analisados.	39
Tabela 2 - Conjuntos de variáveis escolhidas para a fase <i>perceptron</i> .	40
Tabela 3 - Períodos utilizados para os testes da rede híbrida.	41
Tabela 4 - Parâmetros utilizados pela rede neural <i>perceptron</i> para o 1º período.	42
Tabela 5 - Parâmetros utilizados pela rede neural <i>perceptron</i> para o 2º período.	42
Tabela 6 - Parâmetros utilizados pela rede neural <i>perceptron</i> para o 3º período.	43
Tabela 7 - Análise comparativa - Aplicação 1 no 1º Período.	47
Tabela 8 - Análise comparativa - Aplicação 2 no 1º Período.	50
Tabela 9 - Análise comparativa - Aplicação 3 no 1º Período.	53
Tabela 10 - Análise comparativa - Aplicação 1 no 2º Período.	55
Tabela 11 - Análise comparativa - Aplicação 2 no 2º Período.	58
Tabela 12 - Análise comparativa - Aplicação 3 no 2º Período.	61
Tabela 13 - Análise comparativa - Aplicação 1 no 3º Período.	64
Tabela 14 - Análise comparativa - Aplicação 2 no 3º Período.	67
Tabela 15 - Análise comparativa - Aplicação 3 no 3º Período.	70
Tabela 16 - Síntese dos resultados obtidos - regressão linear múltipla com seleção <i>stepwise</i> .	72
Tabela 17 - Síntese dos resultados obtidos - modelo híbrido.	72

LISTA DE SÍMBOLOS

X - conjunto de variáveis dos padrões de entrada;

Y - conjunto de variáveis dos padrões de saída;

r - coeficiente de correlação linear;

$x_1, x_2, \dots, x_n$ - componentes do conjunto de variáveis dos padrões de entrada;

$\hat{y}$ - saída prevista;

m_k - coeficiente angular da equação de regressão linear;

b - coeficiente linear da equação de regressão linear;

r^2 - coeficiente de determinação;

$w_1, w_2, \dots, w_m$ - componentes do conjunto de pesos sinápticos da rede *perceptron*;

w_0 - peso correspondente ao “bias” da rede *perceptron*;

$s_j(n)$ - saída linear do j -ésimo neurônio;

φ_j - função não linear;

φ'_j - derivada da função não linear;

$e_j(n)$ - erro produzido na última camada pela j -ésima saída na n -ésima iteração da rede *perceptron*;

d_j - j -ésima saída desejada;

y_j - j -ésima saída calculada pela rede neural;

$\delta_j(n)$ - gradiente local do j -ésimo neurônio;

$\Delta w_{ji}(n)$ - ajuste dos pesos sinápticos;

$\mathcal{E}(n)$ - erro instantâneo;

$\mathcal{E}_{med}$ - erro médio dos erros instantâneos;

N - número total de padrões apresentados à rede;

$L_n(h)$ - carga elétrica referente a hora (h);

$\underline{L}(h)$ - carga prevista na hora h ;

nh - número total de horas;

MAPE - erro percentual médio.

SUMÁRIO

1	INTRODUÇÃO	16
2	REGRESSÃO LINEAR E SELEÇÃO DE VARIÁVEIS	19
2.1	REGRESSÃO LINEAR	19
2.1.1	Correlação Linear	19
2.1.2	Coefficiente de Correlação Linear	20
2.1.3	Linha de Regressão Linear	21
2.1.4	Coefficiente de Determinação	22
2.1.5	Método dos Mínimos Quadrados - MMQ	24
2.2	MÉTODOS DE SELEÇÃO DE VARIÁVEIS	26
2.2.1	Método <i>Forward</i>	26
2.2.2	Método <i>Backward</i>	28
2.2.3.	Método <i>Stepwise</i>	29
3	REDES NEURAIS ARTIFICIAIS	31
3.1	CONCEITOS GERAIS	31
3.1.1	Rede <i>Perceptron</i> Multicamadas	34
3.1.1.1	Algoritmo de Treinamento <i>Backpropagation</i>	34
4	METODOLOGIA PROPOSTA - REDE NEURAL HÍBRIDA	38
4.1	FASE <i>STEPWISE</i>	39
4.2	FASE <i>PERCEPTRON</i> MULTICAMADAS	39
5	TESTES E RESULTADOS	44
5.1	PREVISÃO DE CARGA ELÉTRICA - HORA E CARGA (H) REFERENTES AO 1º PERÍODO	44
5.2	PREVISÃO DE CARGA ELÉTRICA - HORA, CARGA (H) E CARGA (H-1) REFERENTES AO 1º PERÍODO	47
5.3	PREVISÃO DE CARGA ELÉTRICA - HORA, CARGA (H), CARGA (H-1) E CARGA (H-2) REFERENTES AO 1º PERÍODO	50
5.4	PREVISÃO DE CARGA ELÉTRICA - HORA E CARGA (H) REFERENTES AO 2º PERÍODO	50
5.5	PREVISÃO DE CARGA ELÉTRICA - HORA, CARGA (H) E CARGA (H-1) REFERENTES AO 2º PERÍODO	56
5.6	PREVISÃO DE CARGA ELÉTRICA - HORA, CARGA (H), CARGA (H-1) E CARGA (H-2) REFERENTES AO 2º PERÍODO	58

5.7	PREVISÃO DE CARGA ELÉTRICA - HORA E CARGA (H) REFERENTES AO 3º PERÍODO	61
5.8	PREVISÃO DE CARGA ELÉTRICA - HORA, CARGA (H) E CARGA (H-1) REFERENTES AO 3º PERÍODO	64
5.9	PREVISÃO DE CARGA ELÉTRICA - HORA, CARGA (H), CARGA (H-1) E CARGA (H-2) REFERENTES AO 3º PERÍODO	67
6	CONSIDERAÇÕES FINAIS E SUGESTÃO DE TRABALHOS FUTUROS	71
	REFERÊNCIAS	74

1 INTRODUÇÃO

A carga elétrica exerce um papel importante no planejamento e operação de sistemas elétricos de potência, uma vez que, estas atividades necessitam, entre outros recursos, do conhecimento futuro do seu perfil (GROSS; GALIANA, 1987; MOHGRAM; RAHMAN, 1989). Dentre as aplicações nas quais se destacam na análise da carga elétrica tem-se: geração econômica de potência, controle de distribuição e operação, planejamento de manutenção, segurança do sistema, entre outras.

Os métodos de previsão de cargas elétricas que tem se destacado na literatura são: ARIMA de Box & Jenkins, regressão linear simples ou múltipla, alisamento exponencial, filtro de Kalman, etc. (BOX; JENKINS, 1976; GROSS; GALIANA, 1987; MOHGRAM; RAHMAN, 1989; O' DONOVAN, 1983).

Um método de previsão que vem se destacando são as redes neurais artificiais (RNA) que são modelos computacionais baseados no funcionamento do cérebro humano. As redes neurais artificiais são capazes de aprender através de dados observados e uma de suas vantagens é que a sua fase de aprendizado é feita em modo *off-line*, desta forma, tem-se na fase de operação um tempo computacional relativamente baixo (HAYKIN, 2001). Quando se utiliza as redes neurais artificiais não é necessário realizar a modelagem prévia dos dados, ou seja, a rede neural tem a capacidade de modelar a carga sem a necessidade de estabelecer a correlação entre as grandezas que influenciam o seu comportamento.

Dentre as arquiteturas de redes neurais artificiais destaca-se a rede neural *perceptron* multicamadas com o algoritmo de treinamento *backpropagation* que é considerado padrão dentro da literatura. O algoritmo de treinamento *backpropagation* baseia-se no método do gradiente descendente do erro quadrático para a adaptação dos pesos sinápticos.

Um método de previsão muito utilizado é o Método de Regressão (Simples ou Múltipla) que é uma técnica estatística, no qual, modela a relação entre o consumo de carga e de outros fatores, como por exemplo: condições meteorológicas (temperatura, vento, etc.), tipos de dia (típico e atípico), etc. Este método assume que a carga elétrica pode ser dividida numa tendência de carga padrão e uma tendência linearmente dependente de alguns fatores que influenciam a carga (MOHGRAM; RAHMAN, 1989).

Uma vertente do método de regressão linear múltipla é o critério de seleção de variáveis *stepwise* o qual tem o papel de identificar as variáveis mais relevantes dentro de um conjunto de observações com a finalidade de reduzir o número de variáveis de entrada sem a perda significativa na qualidade na previsão.

Na literatura tem se destacado o uso de modelos híbridos em diversas aplicações, inclusive na previsão de cargas elétricas. Um exemplo é o modelo híbrido apresentado por Silva (2012) que é um modelo predictor de cargas a curto prazo no qual utiliza os modelos ARIMA de Box & Jenkins e as redes neurais artificiais *perceptron* multicamadas com o algoritmo de treinamento de Levenberg-Maquardt. Outro exemplo de rede neural híbrida, aplicada na previsão de carga elétrica a curto prazo, é apresentada por Oliveira (2012), denominada rede neural híbrida *Back Art-Fuzzy* que é uma rede neural composta pela rede neural *Art-Fuzzy* e a rede neural *perceptron* multicamadas com algoritmo de treinamento *backpropagation*.

Existem na literatura trabalhos envolvendo a regressão linear múltipla e a rede neural *perceptron* multicamadas, porém, trata-se apenas de trabalhos comparativos entre o método de regressão e a rede neural. Fung e Tummala (1993) comparam a análise de regressão com os modelos de redes neurais, e Sarani et. al. (2012) utilizam a previsão de relação de absorção de sódio comparativamente entre as redes neurais e a regressão linear múltipla.

Silva, Moita e Almeida (2010) descrevem uma arquitetura híbrida para a classificação de *e-mails*, conhecidos como filtros *anti-spam*. A proposta é utilizar a regressão linear múltipla para diminuir o número de características empregadas no agente classificador, com o objetivo de melhorar a resposta computacional. Os critérios de seleção para o *stepwise* foram os métodos estatísticos para seleção de características informação mútua, Qui *statistic* e as variações do método de distribuição de frequência. A rede neural *perceptron* multicamadas atuou como agente classificador de *e-mails*.

A proposta deste trabalho é desenvolver uma técnica híbrida utilizando a regressão linear múltipla com o critério de seleção de variáveis *stepwise* com a rede neural artificial *perceptron* multicamadas via algoritmo *backpropagation*.

A metodologia híbrida proposta é realizada em duas fases, sendo que, a primeira fase é composta pelo método de regressão linear múltipla através da utilização do critério de seleção de variáveis *stepwise*. Esta fase tem como finalidade selecionar as variáveis mais importantes

para compor o conjunto de dados de entrada da rede neural artificial descartando, assim, as variáveis menos relevantes.

Uma vez selecionadas as variáveis mais importantes do conjunto de dados, estas serão utilizadas na segunda fase da rede híbrida que é composta pelo *perceptron* multicamadas com o uso do algoritmo de aprendizado *backpropagation*.

Uma das vantagens desta metodologia é a redução do número de variáveis selecionadas para compor o conjunto de dados de entrada para a rede neural *perceptron*. Para realizar o treinamento da rede neural *perceptron* é necessário definir parâmetros (taxa de treinamento, inclinação da função de ativação, etc.) que são importantes no processo de modelagem e convergência da rede neural. Este procedimento envolve várias tentativas de forma a encontrar uma boa arquitetura e, portanto, a redução do número de variáveis de entrada diminui a amplitude do espaço de busca da arquitetura ideal.

A arquitetura proposta por Silva, Moita e Almeida (2010) difere da arquitetura proposta pelo fato de que neste trabalho o critério de seleção utilizado na fase *stepwise* foi o coeficiente de correlação linear e a rede *perceptron* multicamadas foi utilizada como um agente previsor.

2 REGRESSÃO LINEAR E SELEÇÃO DE VARIÁVEIS

Neste capítulo, serão apresentadas as principais definições relacionadas ao Método de Regressão Linear, abordando a equação de regressão, o Método dos Mínimos Quadrados que auxilia na determinação da equação de regressão e o Método de Seleção de Variáveis que tem como objetivo selecionar as variáveis mais apropriadas para descrever o Modelo de Regressão.

2.1 REGRESSÃO LINEAR

Esta modelagem é realizada a partir das relações existentes entre as variáveis (ou dados) com a finalidade de encontrar uma função que a melhor descreva. Esta função é denominada regressão linear, e esta pode ser, simples ou múltipla dependendo da quantidade de variáveis envolvidas no problema (HOFFMANN; VIEIRA, 1977; MORETTIN et al., 2006).


2.1.1 Correlação Linear

Dados dois conjuntos de observações $X = \{x_1, x_2, \dots, x_n\}$ e $Y = \{y_1, y_2, \dots, y_n\}$, sendo X o conjunto de variáveis independentes (ou variáveis de entrada) e Y o conjunto de variáveis dependentes (ou variáveis de saída).

A correlação é a relação de dependência entre o conjunto das variáveis independentes e o conjunto das variáveis dependentes. A correlação é dita linear quando essa dependência possui um comportamento próximo de uma reta, de forma crescente ou decrescente (LARSON; FABER, 2010).

A correlação linear pode ser classificada em positiva ou negativa, fraca ou forte. Na Figura 1 é possível verificar algumas classificações da correlação linear, como por exemplo: correlação linear positiva forte, correlação linear negativa forte e correlação linear positiva fraca (LARSON; FABER, 2010).

Figura 1 - Ilustração da classificação da correlação linear.



Fonte: Adaptado de Larson e Faber (2010).

Além dessa classificação existe também a possibilidade dos conjuntos não possuírem correlação linear.

2.1.2 Coeficiente de Correlação Linear

É importante também saber o quanto a variável independente influencia a variável dependente. No caso da correlação linear ao grau desta influência dá-se o nome de coeficiente de correlação linear.

O coeficiente de correlação linear é a medida da força em que a variável independente influencia variável dependente e é dado por (LARSON; FABER, 2010):

$$r = \frac{n \sum xy - (\sum x)(\sum y)}{\sqrt{n \sum x^2 - (\sum x)^2} \sqrt{n \sum y^2 - (\sum y)^2}} \quad (1)$$

O valor do coeficiente de variação r varia entre -1 e 1 e a determinação do tipo de correlação é dada da seguinte forma (LARSON; FABER, 2010):


- a) r próximo de 1 - Correlação linear positiva forte;
- b) r próximo de -1 - Correlação linear negativa forte;
- c) r próximo de 0 - Não há correlação linear.

Uma forma de visualizar a correlação é utilizar o gráfico de dispersão para verificar as tendências, por exemplo, se os dados possuem uma correlação forte os dados do gráfico de dispersão esboçam em pontos uma linha (reta).

2.1.3 Linha de Regressão Linear

Desde que haja uma correlação linear forte, seja ela positiva ou negativa, é possível estabelecer uma reta (linha de regressão) que melhor se aproxima dos dados observados e a partir desta equação obter previsões de valores futuros. Na Figura 2 ilustra-se a representação de uma linha de regressão linear.

Figura 2 - Exemplo de linha de regressão.



Fonte: Adaptado de Larson e Faber (2010).

Todos os pontos sobre essa reta são chamados de valor previsto, pois é uma estimativa muito próxima dos valores observados. A diferença entre os valores previstos e os valores observados denotada por d é chamada de resíduos. A reta que melhor se ajusta aos dados observados é a reta onde a soma do quadrado dos resíduos seja mínima.

Definição: Uma linha de regressão, também chamada de linha de melhor ajuste, é a linha para a qual a soma dos quadrados dos resíduos é um mínimo (LARSON; FARBER, 2010).

Uma linha de regressão é obtida através de equação de regressão linear e esta pode ser simples, que possui uma variável de entrada x e uma variável de saída y , ou múltipla, com várias variáveis de entrada $x_1, x_2, \dots, x_n$ e uma variável de saída y , e possuem as respectivas formas (LARSON; FARBER, 2010):

Equação de regressão linear simples

$$\hat{y} = mx + b$$

Equação de regressão linear múltipla

$$\hat{y} = b + m_1x_1 + m_2x_2 + \dots + m_nx_n$$

no qual:


- $\hat{y}$: valor previsto;
- x_i : valor observado (variáveis independentes);
- m_i : coeficiente angular (ou inclinação) da reta;
- b : coeficiente linear (ou intercepto em y) da reta.

2.1.4 Coeficiente de Determinação

A Equação (1) é adequada para calcular o coeficiente de correlação para somente o uso de uma variável de entrada x . Para os casos que envolvem mais de uma variável de entrada é mais adequado o uso do coeficiente de determinação que é o quadrado do coeficiente de correlação (LARSON; FARBER, 2010).

Para definir o coeficiente de determinação, se faz necessário a apresentação dos desvios sobre a linha de regressão. Esses desvios são mostrados na Figura 3.

Figura 3 - Desvios sobre a reta de regressão.



Fonte: Adaptado de Larson e Faber (2010).

A variação total sobre uma linha de regressão é a soma dos quadrados das diferenças entre o valor y e a média $\bar{y}$ (LARSON; FARBER, 2010).

$$\text{variação total} = \sum (y_i - \bar{y})^2$$

A variação explicada é a soma dos quadrados das diferenças entre cada valor $\hat{y}$ previsto e a média $\bar{y}$ (LARSON; FARBER, 2010).

$$\text{variação explicada} = \sum (\hat{y}_i - \bar{y})^2$$

O coeficiente de determinação r^2 é relação da variação explicada com a variação total, isto é:

$$r^2 = \frac{\text{variação explicada}}{\text{variação total}}$$

2.1.5 Método dos Mínimos Quadrados - MMQ

Para encontrar a equação de regressão linear, simples ou múltipla, é utilizado o Método dos Mínimos Quadrados que é o método de computação matemática pelo qual se define a curva de regressão. Esse método definirá uma reta (curva) que minimizará a soma das distâncias ao quadrado entre os pontos e esta reta é denominada curva de regressão. Esse método encontra uma função que seja uma boa aproximação de dados observados (RUGGIERO; LOPES, 1996).

Considerando o caso discreto, dado os pontos conhecidos $(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)$ e funções $g_1, g_2, \dots, g_m$ escolhidas tem-se a equação (2)

$$\hat{y}(x_k) = m_1 g_1(x_k) + m_2 g_2(x_k) + \dots + m_n g_n(x_k) \quad (2)$$

O objetivo do método dos mínimos quadrados é encontrar os coeficientes $m_1, m_2, \dots, m_n$ de tal forma que $\hat{y}(x_k)$ se aproxime de $y(x_k)$. Para isso a soma do quadrado dos resíduos descrita na equação (3) deve ser mínima (RUGGIERO; LOPES, 1996).

$$\sum_{k=1}^m [d_k]^2 = \sum_{k=1}^m [y(x_k) - \hat{y}(x_k)]^2 \quad (3)$$

Substituindo (2) em (3)

$$\sum_{k=1}^m [d_k]^2 = \sum_{k=1}^m [y(x_k) - m_1 g_1(x_k) - m_2 g_2(x_k) - \dots - m_n g_n(x_k)]^2 \quad (4)$$

A equação (4) é uma função que depende dos coeficientes $m_1, m_2, \dots, m_n$. Reescrevendo a equação (4) tem-se:

$$F(m_1, m_2, \dots, m_n) = \sum_{k=1}^m [y(x_k) - m_1 g_1(x_k) - m_2 g_2(x_k) - \dots - m_n g_n(x_k)]^2$$

Para que $F(m_1, m_2, \dots, m_n)$ tenha um ponto de mínimo é necessário encontrar seus pontos críticos, ou seja, encontrar $m_1, m_2, \dots, m_n$ em que suas derivadas parciais se anulam (RUGGIERO; LOPES, 1996).

Calculando as derivadas parciais para cada $j = 1, 2, \dots, n$:

$$\begin{aligned} & (m_1, m_2, \dots, m_n) \\ \frac{\partial F}{\partial m_j} &= 2 \sum_{k=1}^m [y(x_k) - m_1 g_1(x_k) - m_2 g_2(x_k) - \dots \\ & \quad - m_n g_n(x_k)] [-g_j(x_k)] \end{aligned} \quad (5)$$

Impondo a condição para determinação de mínimo, tem-se:

$$\frac{\partial F}{\partial m_j} (m_1, m_2, \dots, m_n) = 0 \quad (6)$$

$$\sum_{k=1}^m [y(x_k) - m_1 g_1(x_k) - m_2 g_2(x_k) - \dots - m_n g_n(x_k)] [-g_j(x_k)] = 0 \quad (7)$$

$$\sum_{k=1}^m g_1(x_k) g_j(x_k) m_1 + \dots + \sum_{k=1}^m g_n(x_k) g_j(x_k) m_n = \sum_{k=1}^m y(x_k) g_j(x_k) \quad (8)$$

para $j = 1, 2, \dots, n$, é possível obter então:

$$\left\{ \begin{array}{l} \sum_{k=1}^m g_1(x_k) g_1(x_k) m_1 + \dots + \sum_{k=1}^m g_n(x_k) g_1(x_k) m_n = \sum_{k=1}^m y(x_k) g_1(x_k) \\ \sum_{k=1}^m g_1(x_k) g_2(x_k) m_1 + \dots + \sum_{k=1}^m g_n(x_k) g_2(x_k) m_n = \sum_{k=1}^m y(x_k) g_2(x_k) \\ \vdots \\ \sum_{k=1}^m g_1(x_k) g_n(x_k) m_1 + \dots + \sum_{k=1}^m g_n(x_k) g_n(x_k) m_n = \sum_{k=1}^m y(x_k) g_n(x_k) \end{array} \right. \quad (9)$$

que é um sistema de equações com n incógnitas. O sistema dado pela equação (9) pode ser representado na forma matricial $Am = b$ descrito na equação (10).

$$\begin{cases} a_{11}m_1 + a_{12}m_2 + \cdots + a_{1n}m_n = b_1 \\ a_{21}m_1 + a_{22}m_2 + \cdots + a_{2n}m_n = b_2 \\ \vdots \\ a_{n1}m_1 + a_{n2}m_2 + \cdots + a_{nn}m_n = b_n \end{cases} \quad (10)$$

em que

$$a_{ij} = \sum_{k=1}^m g_j(x_k)g_i(x_k) = a_{ji} \quad \text{e} \quad b_{ij} = \sum_{k=1}^m y(x_k)g_i(x_k) \quad (11)$$

sendo que A é uma matriz simétrica, ou seja, $a_{ij} = a_{ji}$.

O sistema linear descrito na equação (10) admite solução única que é o ponto em que $F(m_1, m_2, \dots, m_n)$ é mínimo.

2.2 MÉTODOS DE SELEÇÃO DE VARIÁVEIS

Um conjunto de observações pode envolver um grande número de variáveis de entrada x_i e, portanto, quais dessas variáveis realmente influenciam na resposta? O método de seleção de variáveis tem como objetivo selecionar as variáveis mais importantes em um modelo de regressão, descartando as variáveis menos significativas.

Existem três métodos de seleção de variáveis que são: *forward*, *backward* e *stepwise*, e estes são métodos iterativos de inclusão ou remoção de variáveis utilizando um critério estatístico (TABACHNICK; FIDEL, 2007). Um dos critérios de seleção mais usados é o teste F, mas também pode ser feito com o coeficiente correlação linear, erro quadrático total, critério de informação de Akaike (HOCKING, 1976).


2.2.1 Método *Forward*

O método consiste na inclusão de variáveis, sendo adicionada uma variável por vez satisfazendo algum critério estatístico para a seleção (TABACHNICK; FIDEL, 2007). Neste trabalho o critério de seleção utilizado foi a correlação linear, em que o procedimento é da seguinte forma:

- a) a variável que tiver o maior coeficiente de correlação com a variável de saída será a variável selecionada para iniciar o método;
- b) seja x_i a variável inicialmente adicionada e x_k a variável ser introduzida no modelo calcula-se, então, o coeficiente de correlação com a nova variável no modelo;
- c) se o coeficiente de correlação gerado com a adição de x_k for maior do que o valor do coeficiente de correlação no modelo anterior, então, x_k fica no modelo, caso contrário x_k sai do modelo;
- d) o processo continua até que não existam mais variáveis a serem introduzidas no modelo.

Na Figura 4 é apresentado o fluxograma do método *forward*.

Figura 4 – Fluxograma do método *forward*.




Fonte: Elaborado pela própria autora.

2.2.2 Método *Backward*

O método *backward* é iniciado com todas as variáveis no modelo e elas são retiradas se satisfazem algum critério estatístico para a seleção de variáveis (TABACHNICK; FIDEL, 2007). Neste trabalho o critério adotado foi a correlação linear com o seguinte procedimento:

- seja x_k a variável retirada do modelo no qual é calculado o coeficiente de correlação com as variáveis que ficaram no modelo;
- se o coeficiente de correlação calculado com a retirada de x_k for maior do que o coeficiente de correlação anterior, então x_k fica fora do modelo, caso contrário x_k volta ao modelo;
- o processo é repetido até que todas as variáveis sejam testadas.

Figura 5 - Fluxograma do método *backward*.



Fonte: Elaborado pela própria autora.

A Figura 5 ilustra o fluxograma do método *backward*.

2.2.3 Método *Stepwise*

O método *stepwise* envolve os métodos *forward* e *backward* (TABACHNICK; FIDEL, 2007).

Este método é iniciado pelo passo *forward*, ou seja:

- a) a variável que tiver o maior coeficiente de correlação com a variável de saída será a variável selecionada para iniciar o método;
- b) seja x_i a variável inicialmente adicionada e x_k a variável a ser introduzida no modelo calcula-se, então, o coeficiente de correlação com a nova variável no modelo;
- c) se o coeficiente de correlação gerado com a adição de x_k for maior do que o valor do coeficiente de correlação no modelo anterior, então, x_k fica no modelo, caso contrário x_k sai do modelo;
- d) o processo continua até que não existam mais variáveis a serem introduzidas no modelo.


Terminado o passo *forward* é iniciado o passo *backward*, ou seja:

- a) seja x_k a variável retirada do modelo no qual é calculado o coeficiente de correlação com as variáveis que ficaram no modelo;
- b) se o coeficiente de correlação calculado com a retirada de x_k for maior do que o coeficiente de correlação anterior, então x_k fica fora do modelo, caso contrário x_k volta ao modelo;
- c) o processo é repetido até que todas as variáveis sejam testadas.

Todo o processo *stepwise* continua até que não existam mais variáveis para entrar ou sair do modelo.

Na Figura 6 é descrito o fluxograma do método *stepwise*.

Figura 6 - Fluxograma do método *stepwise*.



Fonte: Elaborado pela própria autora.

3 REDES NEURAIS ARTIFICIAIS


Neste capítulo, será feita uma revisão sobre os conceitos de redes neurais artificiais, abordando o modelo do neurônio artificial bem como sua estrutura e funcionamento. Também, será apresentada a rede neural *perceptron* e o algoritmo *Backpropagation* que é um algoritmo de adaptação de pesos baseado no método do gradiente descendente.

3.1 CONCEITOS GERAIS

As redes neurais artificiais são modelos computacionais baseados no funcionamento do cérebro humano. Compostas por neurônios artificiais que possuem a capacidade de armazenar conhecimento, sua principal característica é aprender através da experiência (HAYKIN, 2001).

Um neurônio artificial é uma unidade de processamento de uma rede neural. O neurônio de McCulloch-Pitts, desenvolvido em 1943 (HAYKIN, 2001), é o mais empregado na resolução de diversos problemas como o reconhecimento de padrões. Na Figura 7 é ilustrado um modelo do neurônio de McCulloch-Pitts.

Figura 7 - Neurônio de McCulloch-Pitts.



Fonte: Adaptado de Haykin (2001).

As variáveis $x_1, x_2, \dots, x_m$ são os sinais de entrada do neurônio e as variáveis $w_1, w_2, \dots, w_m$ são os pesos sinápticos, que são os parâmetros livres a serem ajustados na fase

de aprendizado, o parâmetro w_0 é denominado “bias”, o qual também é ajustado na fase de aprendizado.

Os sinais de entrada $x_1, x_2, \dots, x_m$, são combinados com os pesos sinápticos $w_1, w_2, \dots, w_m$, fornecendo a saída s , mostrada na equação (12) (HAYKIN, 2001; WIDROW; LEHR, 1990).

$$s = \sum_{j=1}^m w_j x_j + w_0 x_0 \quad (12)$$

em que w_0 é peso correspondente ao “bias”.


E a saída do neurônio é calculada utilizando a equação (13) (HAYKIN, 2001).

$$y = \varphi(s) \quad (13)$$

A função φ , é uma função de ativação do neurônio, ela é um limitador da resposta da rede neural e pode ser linear ou não-linear (HAYKIN, 2001). Nas Figuras 8, 9 e 10 são mostradas as funções de ativação mais utilizadas.

- Função relé $\rightarrow \varphi(s) = \begin{cases} +1, & \text{se } s \geq 0 \\ -1, & \text{se } s < 0 \end{cases}$ (HAYKIN, 2001)


Figura 8 - Função relé.



Fonte: Haykin (2001).

- Função logística $\rightarrow \varphi(s) = \frac{1}{1+e^{-\lambda s}}$ (HAYKIN, 2001)

Figura 9 - Função logística.




Fonte: Haykin (2001).

sendo λ a inclinação da curva.

- Função sigmóide $\rightarrow \varphi(s) = \frac{1-e^{-\lambda s}}{1+e^{-\lambda s}}$ (HAYKIN, 2001)

Figura 10 - Função sigmóide.




Fonte: Haykin (2001).

3.1.1 Rede *Perceptron* Multicamadas

A rede neural *Perceptron* Multicamadas (PMC) é uma importante arquitetura de redes neurais e também uma das mais utilizadas, pois podem ser aplicadas em diversos tipos de problemas (HAYKIN, 2001).

A rede neural PMC é uma arquitetura que utiliza vários neurônios de McCulloch-Pitts dispostos em camadas (HAYKIN, 2001; SIMPSON, 1989; WIDROW; LEHR, 1990). Na Figura 11 é apresentada uma rede neural PMC com três camadas, uma camada de entrada, uma camada intermediária ou camada escondida e uma camada de saída.

Figura 11 - Rede neural *Perceptron* multicamadas.



Fonte: Adaptado de Haykin (2001).

A rede neural apresentada na Figura 11 é do tipo *feedforward*, ou seja, o sinal de entrada é combinado com os pesos sinápticos e propagado através da rede, a saída de cada neurônio das camadas de entrada e intermediárias se tornam a entrada da próxima camada, até gerar uma saída y .

3.1.1.1 Algoritmo de Treinamento *Backpropagation*

Como dito anteriormente, uma das principais características das redes neurais é a sua capacidade de aprendizado (HAYKIN, 2001) e para isso é necessário adotar um algoritmo de

treinamento. Neste trabalho, será abordado o algoritmo *backpropagation*, também conhecido como retropropagação. Este algoritmo utiliza a técnica do gradiente descendente para o ajuste dos pesos sinápticos de tal forma que o erro produzido pela rede atinja um limite pré-estabelecido (HAYKIN, 2001; WIDROW; LEHR, 1990).

Os passos que descrevem a rede neural PMC com o algoritmo *backpropagation* são:

Passo *forward*

1. Um conjunto de dados de entrada X é apresentado e o sinal propagado através da rede. A saída linear de cada neurônio é dada pela equação (14) (HAYKIN, 2001; WIDROW; LEHR, 1990).

$$s = \sum_{i=1}^m w_i x_i + b \quad (14)$$

no qual:

- w_i : i -ésimo peso sináptico;
- x_i : i -ésima entrada;
- b : peso correspondente as “bias”;
- m : número total de entradas.

A saída não linear de cada neurônio é representada através da equação (15) (HAYKIN, 2001; WIDROW; LEHR, 1990):

$$y_j(n) = \varphi_j(s_j(n)) \quad (15)$$

sendo:

$y_j(n)$: saída do j -ésimo neurônio na iteração n ;

φ_j : função não linear.

2. O erro da rede neural na camada de saída da n -ésima iteração é dado pela equação (16) (HAYKIN, 2001; WIDROW; LEHR, 1990).

$$e_j(n) = d_j(n) - y_j(n) \quad (16)$$

no qual:

d_j : j -ésima saída desejada;

y_j : j -ésima saída calculada pela rede neural.

3. É calculado o gradiente local $\delta_j(n)$ referente à última camada através do erro gerado na camada de saída e da derivada do erro através da equação (17) (HAYKIN, 2001) (WIDROW AND LEHR, 1990).

$$\delta_j(n) = e_j(n)\varphi'_j(s_j(n)) \quad (17)$$

A função φ escolhida deve ser diferenciável.

Passo *backward*

4. O gradiente local $\delta_j(n)$ de cada neurônio das camadas anteriores será calculado através da equação (18) (HAYKIN, 2001; WIDROW; LEHR, 1990).

$$\delta_j(n) = \varphi'_j(s_j(n)) \sum_k \delta_k(n)w_{kj}(n) \quad (18)$$

no qual:

j : índice do neurônio da camada atual;

k : índice do neurônio da camada imediatamente posterior.

5. Ajustar os pesos sinápticos, ou seja, uma vez calculado cada gradiente local, o ajuste dos pesos sinápticos é dado pela equação (19) (HAYKIN, 2001; WIDROW; LEHR, 1990).

$$\Delta w_{ji}(n) = \eta \delta_j(n) y_j(n) \quad (19)$$

sendo η a taxa de aprendizagem da rede.

A adaptação dos pesos é realizada pela equação (20) (HAYKIN, 2001; WIDROW; LEHR, 1990).

$$w_{ji}^{k+1}(n) = w_{ji}^k(n) + \Delta w_{ji}(n) \quad (20)$$

Para cada padrão apresentado à rede é medido o erro instantâneo $\mathcal{E}(n)$, representado na equação (21) (HAYKIN, 2001; WIDROW; LEHR, 1990).

$$\mathcal{E}(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (21)$$

sendo C o conjunto de todos os neurônios da camada de saída.

O algoritmo continua até que todos os padrões sejam apresentados à rede, formando uma época. O método atinge a convergência quando o erro médio dos erros instantâneos alcança uma tolerância pré-estabelecida conforme a equação (22) (HAYKIN, 2001; WIDROW; LEHR, 1990).

$$\mathcal{E}_{med} = \frac{1}{N} \sum_{n=1}^N \mathcal{E}(n) \quad (22)$$


no qual N é número total de padrões apresentados à rede.

4 METODOLOGIA PROPOSTA - REDE NEURAL HÍBRIDA

A metodologia proposta baseia-se no uso de uma rede neural híbrida, composta pelo método *stepwise* para seleção de variáveis de entrada e a arquitetura *perceptron* multicamadas via algoritmo *backpropagation*, aplicada ao problema de previsão de cargas elétricas.

Inicialmente todas as variáveis de entrada serão avaliadas usando o método *stepwise* e as variáveis mais correlacionadas serão utilizadas na fase de aprendizado da rede neural. O diagrama da Figura 12 descreve o processo da rede neural híbrida.

Figura 12 - Rede neural híbrida.



Fonte: Elaboração da própria autora.

As variáveis utilizadas no processo *stepwise* foram dia da semana, tipo do dia (sábados, domingos, feriados, dias úteis), temperatura máxima, temperatura mínima, temperatura média, hora (h), carga (h-2), carga (h-1), carga (h) e a saída foi carga (h+1).

Para os testes com a rede neural híbrida foram utilizados dados de uma companhia de energia elétrica do ano de 1990. Estes dados englobam as seguintes variáveis: carga elétrica horária, dia da semana, tipo do dia, temperatura (máxima, mínima e média).

4.1 FASE *STEPWISE*

O método *stepwise* é iniciado com a variável que apresentar o maior coeficiente de correlação. Dentre as variáveis apresentadas: tipo do dia, temperatura máxima, temperatura mínima, temperatura média, hora (h), carga (h-2), carga (h-1), carga (h), o maior valor de correlação foi dado pela variável carga (h).

Em seguida, através do método *stepwise* foram sendo adicionadas e retiradas variáveis de forma a serem encontrados os conjuntos de variáveis mais correlacionadas.

Portanto, as variáveis selecionadas pelo método *stepwise* a compor o banco de entrada de dados de treinamento da rede neural *perceptron* foram as variáveis que apresentaram maior correlação linear em todos os períodos analisados. A apresenta Tabela 1 as variáveis que tiveram maior correlação linear e que foram separadas para os testes da seguinte forma:

Tabela 1 - Conjunto das variáveis com maiores correlações nos períodos analisados.

Conjunto 1	Conjunto 2	Conjunto 3
Carga (h)	Carga (h - 1)	Carga (h - 2)
	Carga (h)	Carga (h - 1)
		Carga (h)

Fonte: Elaboração da própria autora.

O processo realizado pelo método *stepwise* é de suma importância, uma vez que, ele seleciona através de processos estatísticos as variáveis que realmente são importantes na análise do problema.

4.2 FASE *PERCEPTRON* MULTICAMADAS

Uma vez selecionado o conjunto de dados de entrada da rede neural artificial através método *stepwise* dá-se início a fase de treinamento da rede neural *perceptron*. Para evitar problemas de convergência e saturação e visando um melhor desempenho da rede neural

artificial os valores das cargas elétricas, ou seja, carga (h-2), carga (h-1), carga (h) e a saída carga (h+1), foram normalizadas utilizando a equação (23).

$$\text{carga normalizada} = \frac{\text{carga}}{\max(\text{carga})} \quad (23)$$

Após o processo de normalização as variáveis foram submetidas à fase de treinamento. O primeiro conjunto a ser utilizado foi o conjunto 2, ilustrado na **Erro! Fonte de referência não encontrada.**, referente ao período de 01/07/1990 e 31/07/1990 com o objetivo de prever a carga elétrica para o dia 01/08/1990. Os resultados obtidos para este conjunto de dados (carga (h - 1) e carga (h)) não foram satisfatórios, pois a rede não convergiu para a tolerância de erro estabelecida, estacionando em mínimo local.

Segundo (HAYKIN, 2001) a rede *Perceptron* multicamadas faz melhores previsões com informações de conteúdos diversos e como os dados de cargas elétricas são basicamente o mesmo tipo de informação foi preciso introduzir mais uma variável no modelo com o objetivo de obter a diversificação. Assim retornou-se ao passo *stepwise* e a variável hora foi introduzida.

A escolha da variável hora se deu ao fato de que entre todas as variáveis que saíram do modelo ela foi a variável que mais influenciou no coeficiente de correlação juntamente com as variáveis de carga e, também, por apresentar conteúdo mais diverso. As outras variáveis, dia da semana, tipo do dia e temperatura são variáveis com conteúdo muito redundante e praticamente não alteraram o coeficiente de correlação.

Desta forma, os conjuntos utilizados para os testes na rede neural *Perceptron*, são representados pelas Aplicações 1, 2 e 3, respectivamente como mostra a Tabela 2.

Tabela 2 - Conjuntos de variáveis escolhidas para a fase *perceptron*.

Aplicação 1	Aplicação 2	Aplicação 3
Hora - h	Hora - h	Hora - h
Carga (h)	Carga (h - 1)	Carga (h - 2)
	Carga (h)	Carga (h - 1)
		Carga (h)

Fonte: Elaboração da própria autora.

A variável hora foi apresentada em código binário (-1 e 1), sendo assim, representada em um total de 5 bits. Esta representação foi escolhida pelo fato de produzir uma convergência mais rápida da rede neural artificial, tornando-se assim, mais eficiente.

Portanto, os dados que compõem o vetor de entrada e saída para a rede neural *perceptron* podem ser representados da seguinte forma:

$$\mathbf{X}(h) = [\text{hora}^{bin} \text{ conjunto}_i^{norm}]^T, \quad i = 1, 2 \text{ e } 3, \quad \mathbf{X} \in R^m$$

$$\mathbf{Y}(h) = [\text{carga}(h + 1)], \quad \mathbf{Y} \in R^1$$

em que:

m : dimensão do vetor $\mathbf{X}$.

Para avaliar a metodologia proposta (rede neural híbrido) foram realizados testes considerando três períodos de tempo distintos descritos na Tabela 3.

Tabela 3 - Períodos utilizados para os testes da rede híbrida.

1º Período	2º Período	3º Período
01/07/1990 a 31/07/1990	01/06/1990 a 31/07/1990	01/05/1990 a 31/07/1990

Fonte: Elaboração da própria autora.

Os períodos 1, 2 e 3 contêm dados de cargas horárias referentes a períodos de 1, 2 e 3 meses, respectivamente. O objetivo é realizar a previsão de carga horária a curto prazo, ou seja, prever a carga elétrica em um período de 24 horas a frente.

Para avaliar a metodologia proposta realizou a previsão de carga elétrica no período de 24 horas que corresponde à previsão da carga horária do dia 01/08/1990 e para o período de 48 horas que é equivalente a previsão de carga elétrica horária dos dias 01/08/1990 e 02/08/1990.

Nas Tabelas 4, 5 e 6 são apresentados os principais parâmetros utilizados na fase de treinamento e diagnóstico da rede neural *Perceptron*.

Tabela 4 - Parâmetros utilizados pela rede neural *perceptron* para o 1º período.

Parâmetros	1º Período		
	Aplicação 1	Aplicação 2	Aplicação 3
Número de vetores	744	744	744
Número de Camadas	3	3	3
Número neurônios por camada	6-13-1	7-13-1	8-15-1
Tolerância	0,0001	0,0001	0,0001
Taxa de treinamento	1,5	1,5	1,5
Inclinação da função sigmóide	0,6	0,6	0,6

Fonte: Elaboração da própria autora.

A Tabela 4 indica os valores dos parâmetros utilizados pela rede neural *Perceptron* para o 1º período que compreende os dias 01/07/1990 a 31/07/1990 e para os três conjuntos utilizados como dados de entrada da rede neural (aplicações 1, 2 e 3).

Os parâmetros utilizados pela rede neural *Perceptron* para o 2º período (01/06/1990 a 31/07/1990) e para as aplicações 1, 2 e 3, respectivamente, estão ilustrados na Tabela 5.

Tabela 5 - Parâmetros utilizados pela rede neural *perceptron* para o 2º período.

Parâmetros	2º Período		
	Aplicação 1	Aplicação 2	Aplicação 3
Número de vetores	1464	1464	1464
Número de Camadas	3	3	3
Número neurônios por camada	6-13-1	7-13-1	8-15-1
Tolerância	0,0001	0,0001	0,0001
Taxa de treinamento	1,5	1,5	1,5
Inclinação da função sigmóide	0,6	0,6	0,6

Fonte: Elaboração da própria autora.

Tabela 6 - Parâmetros utilizados pela rede neural *perceptron* para o 3º período.

Parâmetros	3º Período		
	Aplicação 1	Aplicação 2	Aplicação 3
Número de vetores	2208	2208	2208
Número de Camadas	3	3	3
Número neurônios por camada	6-13-1	7-13-1	8-17-1
Tolerância	0,0001	0,0001	0,0001
Taxa de treinamento	1,5	0,9	0,9
Inclinação da função sigmóide	0,6	0,5	0,5

Fonte: Elaboração da própria autora.

Para o 3º período, 01/05/1990 a 31/07/1990, a Tabela 6 mostra os parâmetros usados na rede neural *Perceptron* relacionados a cada aplicação.

5 TESTES E RESULTADOS

Com o objetivo de avaliar a metodologia proposta são calculados o erro percentual médio (MAPE) e o erro máximo percentual os quais estão descritos nas equações (24), (25) respectivamente.

$$\text{MAPE} = \frac{1}{nh} \sum_{h=1}^{nh} \frac{L(h) - \underline{L}(h)}{L(h)} \times 100 \quad (24)$$

$$\text{Erro máximo (\%)} = \text{máx} \left(\frac{L(h) - \underline{L}(h)}{L(h)} \right) \times 100 \quad (25)$$

sendo:

$L(h)$: carga elétrica referente a hora (h);

$\underline{L}(h)$: carga elétrica prevista pela rede neural híbrida na hora h;

nh : número total de horas.

Os resultados obtidos com a rede neural híbrida foram analisados levando-se em consideração os três períodos indicados pela Tabela 3 e os conjuntos de dados ilustrados na Tabela 2 referentes às aplicações 1, 2 e 3.


Os resultados obtidos das simulações serão apresentados em forma de tabelas e gráficos, tanto para método de Regressão Linear Múltipla (RLM) utilizando os dados obtidos através da fase *stepwise*, quanto para a rede neural híbrida. O horizonte de previsão a curto prazo foi realizado nos períodos de 24 e 48 horas a frente.

5.1 PREVISÃO DE CARGA ELÉTRICA - HORA E CARGA (H) REFERENTES AO 1º PERÍODO

Foi realizada a previsão de carga elétrica levando-se em consideração um conjunto de dados com valores da hora (h) e carga elétrica correspondente à hora (h) (Aplicação 1) de um período compreendido entre os dias 01 a 31 de julho de 1990.


A Figura 13 ilustra os valores da carga elétrica real e da carga prevista pelo método de regressão linear múltipla (RLM) com variáveis selecionadas pelo método *stepwise* para o dia 01 de agosto de 1990.

Figura 13 - Resultado da previsão de carga obtida pela RLM para o dia 01/08/1990 - Aplicação 1 no 1º Período.



Fonte: Elaboração da própria autora.


Figura 14 - Resultado da previsão de carga obtida pela RLM para os dias 01 e 02/08/1990 - Aplicação 1 no 1º Período.



Fonte: Elaboração da própria autora.


A Figura 14 mostra valores da carga elétrica real e da carga prevista pelo método de regressão linear múltipla (RLM) com variáveis selecionadas pelo método *stepwise* para os dias 01 e 02 de agosto de 1990.

Figura 15 - Resultado da previsão de carga obtida pelo modelo híbrido para o dia 01/08/1990 - Aplicação 1 no 1º Período.



Fonte: Elaboração da própria autora.

Figura 16 - Resultado da previsão de carga obtida pelo modelo híbrido para os dias 01 e 02/08/1990 - Aplicação 1 no 1º Período.



Fonte: Elaboração da própria autora.

As Figuras 15 e 16 mostram os valores da carga elétrica real e as previsões de demanda carga elétrica obtidas pelo modelo híbrido para o horizonte de 24 horas (01/08/1990) e 48 horas (01 e 02/08/1990), respectivamente.

Tabela 7 - Análise comparativa - Aplicação 1 no 1º Período.

Coeficiente Correlação	Métodos	Períodos			
		24 horas		48 horas	
		MAPE (%)	Erro Máximo (%)	MAPE (%)	Erro Máximo (%)
0,9703	RLM - <i>Stepwise</i>	4,79	10,94	4,61	12,60
	Modelo Híbrido	1,35	4,62	1,31	4,62

Fonte: Elaboração da própria autora.


A Tabela 7 mostra a análise comparativa entre os erros: erro percentual médio (MAPE) e erro máximo, obtidos através do uso dos métodos, RLM e modelo híbrido, nos horizontes de previsão de 24 e 48 horas para o conjunto de variáveis composto pela hora (h) e carga (h).

5.2 PREVISÃO DE CARGA ELÉTRICA - HORA, CARGA (H) E CARGA (H-1) REFERENTES AO 1º PERÍODO

Também, foi efetuada a previsão de carga elétrica para o mesmo período, porém com um conjunto de dados composto com os valores da hora (h), carga elétrica correspondente à hora (h) e carga elétrica correspondente a hora (h-1) (Aplicação 2).


Através das Figuras 17 e 18 é possível observar os valores da carga elétrica real e carga prevista pelo método de regressão linear múltipla (RLM) com variáveis selecionadas pelo método *stepwise* realizadas, respectivamente, no dia 01 de agosto de 1990 e para os dias 01 e 02 de agosto de 1990.

Figura 17 - Resultado da previsão de carga obtida pela RLM para o dia 01/08/1990 - Aplicação 2 no 1º Período.



Fonte: Elaboração da própria autora.

Figura 18 - Resultado da previsão de carga obtida pela RLM para os dias 01 e 02/08/1990 - Aplicação 2 no 1º Período.




Fonte: Elaboração da própria autora.

Levando-se em consideração o conjunto de dados composto por variáveis: hora (h), carga (h) e carga (h-1) descritas em um período de 01 a 31/07/1990, têm-se através das Figuras, 19 e 20, os valores da carga elétrica real e as previsões de demanda carga elétrica


obtidas pelo modelo híbrido para o horizonte de 24 horas (01/08/1990) e 48 horas (01 e 02/08/1990), respectivamente.

Figura 19 - Resultado da previsão de carga obtida pelo modelo híbrido para o dia 01/08/1990 - Aplicação 2 no 1º Período.



Fonte: Elaboração da própria autora.

Figura 20 – Resultado da previsão de carga obtida pelo modelo híbrido para os dias 01 e 02/08/1990 - Aplicação 2 no 1º Período.



Fonte: Elaboração da própria autora.

A Tabela 8 mostra a análise comparativa entre MAPE e erro máximo, obtidos através do uso dos métodos, RLM e modelo híbrido, nos horizontes de previsão de 24 e 48 horas para o conjunto de variáveis composto pela hora (h), carga (h) e carga (h-1).

Tabela 8 - Análise comparativa - Aplicação 2 no 1º Período.

Coeficiente Correlação	Métodos	Períodos			
		24 horas		48 horas	
		MAPE (%)	Erro Máximo (%)	MAPE (%)	Erro Máximo (%)
0,9836	RLM - Stepwise	2,97	10,11	2,83	10,11
	Modelo Híbrido	1,32	4,52	1,19	4,52


Fonte: Elaboração da própria autora.

5.3 PREVISÃO DE CARGA ELÉTRICA - HORA, CARGA (H), CARGA (H-1) E CARGA (H-2) REFERENTES AO 1º PERÍODO

Fez-se a previsão de carga elétrica usando um conjunto de dados composto pela hora (h), carga elétrica na hora (h), carga elétrica na hora (h-1) e carga elétrica na hora (h-2) (Aplicação 3) de um período de 01 a 31/07/1990.


Os valores da carga elétrica real e carga prevista pelo método de regressão linear múltipla (RLM) com variáveis selecionadas pelo método *stepwise* realizadas, respectivamente, no dia 01 de agosto de 1990 e nos dias 01 e 02 de agosto de 1990, podem ser visualizadas nas Figuras 21 e 22.

Figura 21 - Resultado da previsão de carga obtida pela RLM para o dia 01/08/1990 - Aplicação 3 no 1º Período.



Fonte: Elaboração da própria autora.


Figura 22 - Resultado da previsão de carga obtida pela RLM para os dias 01 e 02/08/1990 - Aplicação 3 no 1º Período.



Fonte: Elaboração da própria autora.


Para o conjunto de dados composto por variáveis: hora (h), carga (h), carga (h-1) e carga (h-2) no período de 01 a 31/07/1990, as Figuras, 23 e 24 apresenta os valores da carga elétrica real e as previsões de demanda carga elétrica obtidas pelo modelo híbrido para o horizonte de 24 horas (01/08/1990) e 48 horas (01 e 02/08/1990), respectivamente.

Figura 23 - Resultado da previsão de carga obtida pelo modelo híbrido para o dia 01/08/1990 - Aplicação 3 no 1º Período.



Fonte: Elaboração da própria autora.

Figura 24 – Resultado da previsão de carga obtida pelo modelo híbrido para os dias 01 e 02/08/1990 - Aplicação 3 no 1º Período.



Fonte: Elaboração da própria autora.

Na Tabela 9 tem-se uma análise comparativa entre MAPE e erro máximo, obtidos através do uso dos métodos, RLM e modelo híbrido, nos horizontes de previsão de 24 e 48 horas para o conjunto de variáveis composto pela hora (h), carga (h), carga (h-1) e carga (h-2).

Tabela 9 - Análise comparativa - Aplicação 3 no 1º Período.


Coeficiente Correlação	Métodos	Períodos			
		24 horas		48 horas	
		MAPE (%)	Erro Máximo (%)	MAPE (%)	Erro Máximo (%)
0,9837	RLM - Stepwise	2,94	10,47	2,79	10,47
	Modelo Híbrido	1,55	5,52	1,45	5,52

Fonte: Elaboração da própria autora.

5.4 PREVISÃO DE CARGA ELÉTRICA - HORA E CARGA (H) REFERENTES AO 2º PERÍODO


A previsão de carga elétrica foi realizada levando-se em consideração um conjunto de dados com valores da hora (h) e carga elétrica correspondente à hora (h) (Aplicação 1) de um período compreendido entre os dias 01 de junho de 1990 a 31 de julho de 1990. As Figuras 25 e 26 ilustram os valores da carga elétrica real e da carga prevista pelo método de regressão linear múltipla (RLM) com variáveis selecionadas pelo método *stepwise* para os horizontes de previsão correspondentes, respectivamente, ao dia 01 de agosto de 1990 e aos dias 01 e 02 de agosto de 1990.

Figura 25 - Resultado da previsão de carga obtida pela RLM para o dia 01/08/1990 - Aplicação 1 no 2º Período.



Fonte: Elaboração da própria autora.


Figura 26 - Resultado da previsão de carga obtida pela RLM para os dias 01 e 02/08/1990 - Aplicação 1 no 2º Período.



Fonte: Elaboração da própria autora.


Levando-se em consideração o conjunto de dados composto por variáveis: hora (h) e carga (h) descritas em um período de 01/06/1990 a 31/07/1990, têm-se através das Figuras 27 e 28 os valores da carga elétrica real e as previsões de demanda carga elétrica obtidas pelo modelo híbrido para o horizonte de 24 horas (01/08/1990) e 48 horas (01 e 02/08/1990), respectivamente.

Figura 27 - Resultado da previsão de carga obtida pelo modelo híbrido para o dia 01/08/1990 - Aplicação 1 no 2º Período.



Fonte: Elaboração da própria autora.

Figura 28 - Resultado da previsão de carga obtida pelo modelo híbrido para os dias 01 e 02/08/1990 - Aplicação 1 no 2º Período.



Fonte: Elaboração da própria autora.

Tabela 10 - Análise comparativa - Aplicação 1 no 2º Período.

Coeficiente Correlação	Métodos	Períodos			
		24 horas		48 horas	
		MAPE (%)	Erro Máximo (%)	MAPE (%)	Erro Máximo (%)
0,9669	RLM - Stepwise	4,82	11,33	4,52	12,51
	Modelo Híbrido	1,31	3,66	1,29	5,49


Fonte: Elaboração da própria autora.

A Tabela 10 mostra a análise comparativa entre os erros: erro percentual médio (MAPE) e erro máximo, obtidos através do uso dos métodos, RLM e modelo híbrido, nos horizontes de previsão de 24 e 48 horas para o conjunto de variáveis composto pela hora (h) e carga (h) para o 2º período.

5.5 PREVISÃO DE CARGA ELÉTRICA - HORA, CARGA (H) E CARGA (H-1) REFERENTES AO 2º PERÍODO


A previsão de carga elétrica foi realizada para o mesmo período (2º período), porém com um conjunto de dados composto com os valores da hora (h), carga elétrica correspondente à hora (h) e carga elétrica correspondente a hora (h-1) (Aplicação 2).

Figura 29 - Resultado da previsão de carga obtida pela RLM para o dia 01/08/1990 - Aplicação 2 no 2º Período.



Fonte: Elaboração da própria autora.


Figura 30 - Resultado da previsão de carga obtida pela RLM para os dias 01 e 02/08/1990 - Aplicação 2 no 2º Período.



Fonte: Elaboração da própria autora.


Nas Figuras 29 e 30 é possível observar os valores da carga elétrica real e carga prevista pelo método de regressão linear múltipla (RLM) com variáveis selecionadas pelo método *stepwise* realizadas, respectivamente, no dia 01 de agosto de 1990 e para os dias 01 e 02 de agosto de 1990.

Figura 31 - Resultado da previsão de carga obtida pelo modelo híbrido para o dia 01/08/1990 - Aplicação 2 no 2º Período.



Fonte: Elaboração da própria autora.

Figura 32 - Resultado da previsão de carga obtida pelo modelo híbrido para os dias 01 e 02/08/1990 - Aplicação 2 no 2º Período.



Fonte: Elaboração da própria autora.

Para o conjunto de dados composto por variáveis: hora (h), carga (h) e carga (h-1) descritas no período de 01/06/1990 a 31/07/1990, nas Figuras 31 e 32 têm-se os valores da carga elétrica real e as previsões de demanda carga elétrica obtidos pelo modelo híbrido para o horizonte de 24 horas (01/08/1990) e 48 horas (01 e 02/08/1990), respectivamente.

Na Tabela 11 é mostrada a análise comparativa entre MAPE e erro máximo, obtidos através do uso dos métodos, RLM e modelo híbrido, nos horizontes de previsão de 24 e 48 horas para o conjunto de variáveis composto pela hora (h), carga (h) e carga (h-1).

Tabela 11 - Análise comparativa - Aplicação 2 no 2º Período.


Coeficiente Correlação	Métodos	Períodos			
		24 horas		48 horas	
		MAPE (%)	Erro Máximo (%)	MAPE (%)	Erro Máximo (%)
0,9813	RLM - Stepwise	2,97	9,86	2,84	9,87
	Modelo Híbrido	1,44	5,49	1,18	5,49

Fonte: Elaboração da própria autora.

5.6 PREVISÃO DE CARGA ELÉTRICA - HORA, CARGA (H), CARGA (H-1) E CARGA (H-2) REFERENTES AO 2º PERÍODO


Foi realizada a previsão de carga elétrica utilizando um conjunto de dados composto pela hora (h), carga elétrica na hora (h), carga elétrica na hora (h-1) e carga elétrica na hora (h-2) (Aplicação 3) considerando o período de 01 de junho de 1990 a 31 de julho de 1990.

Figura 33 - Resultado da previsão de carga obtida pela RLM para o dia 01/08/1990 - Aplicação 3 no 2º Período.



Fonte: Elaboração da própria autora.


Figura 34 - Resultado da previsão de carga obtida pela RLM para os dias 01 e 02/08/1990 - Aplicação 3 no 2º Período.



Fonte: Elaboração da própria autora.


Os valores da carga elétrica real e carga prevista pelo método de regressão linear múltipla (RLM) com variáveis selecionadas pelo método *stepwise* realizadas, respectivamente, no dia 01 de agosto de 1990 e nos dias 01 e 02 de agosto de 1990, podem ser visualizadas nas Figuras 33 e 34.

Figura 35 - Resultado da previsão de carga obtida pelo modelo híbrido para o dia 01/08/1990 - Aplicação 3 no 2º Período.



Fonte: Elaboração da própria autora.

Figura 36 – Resultado da previsão de carga obtida pelo modelo híbrido para os dias 01 e 02/08/1990 - Aplicação 3 no 2º Período.



Fonte: Elaboração da própria autora.

Para o conjunto de dados composto por variáveis: hora (h), carga (h), carga (h-1) e carga (h-2) no período de 01 de junho a 31 de julho de 1990, observam-se através das Figuras, 35 e 36, os valores da carga elétrica real e as previsões de demanda carga elétrica obtidas pelo

modelo híbrido para o horizonte de 24 horas (01/08/1990) e 48 horas (01 e 02/08/1990), respectivamente.

Tabela 12 - Análise comparativa - Aplicação 3 no 2º Período.

Coeficiente Correlação	Métodos	Períodos			
		24 horas		48 horas	
		MAPE (%)	Erro Máximo (%)	MAPE (%)	Erro Máximo (%)
0,9816	RLM - <i>Stepwise</i>	2,98	10,41	2,81	10,41
	Modelo Híbrido	1,71	4,47	1,54	4,47

Fonte: Elaboração da própria autora.


A Tabela 12 mostra a análise comparativa entre os erros: erro percentual médio (MAPE) e erro máximo expressos em porcentagem (%), obtidos através do uso dos métodos, RLM e modelo híbrido, nos horizontes de previsão de 24 e 48 horas para o conjunto de variáveis composto pela hora (h), carga (h), carga (h-1) e carga (h-2) para o 2o período.

5.7 PREVISÃO DE CARGA ELÉTRICA - HORA E CARGA (H) REFERENTES AO 3º PERÍODO

A previsão de carga elétrica foi efetuada considerando-se um conjunto de dados com valores da hora (h) e carga elétrica na hora (h) (Aplicação 1) de um período compreendido entre os dias 01 de maio de 1990 a 31 de julho de 1990 (3º período).


As Figuras 37 e 38 mostram os valores da carga elétrica real e da carga prevista pelo método de regressão linear múltipla (RLM) com variáveis selecionadas pelo método *stepwise* para os horizontes de previsão correspondentes, respectivamente, ao dia 01 de agosto de 1990 e aos dias 01 e 02 de agosto de 1990.

Figura 37 - Resultado da previsão de carga obtida pela RLM para o dia 01/08/1990 - Aplicação 1 no 3º Período.



Fonte: Elaboração da própria autora.

Figura 38 - Resultado da previsão de carga obtida pela RLM para os dias 01 e 02/08/1990 - Aplicação 1 no 3º Período.




Fonte: Elaboração da própria autora.

Considerando o conjunto de dados composto por variáveis: hora (h) e carga (h) descritas em um período de 01/05/1990 a 31/07/1990, têm-se nas Figuras 39 e 40 as cargas


elétricas reais e a previsão obtida pelo modelo híbrido para o horizonte de 24 horas (01/08/1990) e 48 horas (01 e 02/08/1990), respectivamente.

Figura 39 - Resultado da previsão de carga obtida pelo modelo híbrido para os dias 01 e 02/08/1990 - Aplicação 1 no 3º Período.



Fonte: Elaboração da própria autora.

Figura 40 - Resultado da previsão de carga obtida pelo modelo híbrido para os dias 01 e 02/08/1990 - Aplicação 1 no 3º Período.



Fonte: Elaboração da própria autora.

Na Tabela 13 é possível verificar o erro percentual médio (MAPE) e erro máximo expressos em porcentagem (%), obtidos através do uso dos métodos, RLM e modelo híbrido, nos horizontes de previsão de 24 e 48 horas para o conjunto de variáveis composto pela hora (h) e carga (h) para o 3º período.

Tabela 13 - Análise comparativa - Aplicação 1 no 3º Período.

Coeficiente Correlação	Métodos	Períodos			
		24 horas		48 horas	
		MAPE (%)	Erro Máximo (%)	MAPE (%)	Erro Máximo (%)
0,9648	RLM - <i>Stepwise</i>	4,82	11,32	4,52	12,50
	Modelo Híbrido	1,58	3,65	1,46	3,70


Fonte: Elaboração da própria autora.

5.8 PREVISÃO DE CARGA ELÉTRICA - HORA, CARGA (H) E CARGA (H-1) REFERENTES AO 3º PERÍODO

A previsão de carga elétrica foi realizada para o mesmo período (3º período), porém com um conjunto de dados composto com os valores da hora (h), carga elétrica na hora (h) e carga elétrica na hora (h-1) (Aplicação 2).


Nas figuras 41 e 42 podem ser visualizados os valores da carga elétrica real e carga prevista pelo método de regressão linear múltipla (RLM) com variáveis selecionadas pelo método *stepwise* realizadas, respectivamente, para o dia 01 de agosto de 1990 e para os dias 01 e 02 de agosto de 1990.

Figura 41 - Resultado da previsão de carga obtida pela RLM para o dia 01/08/1990 - Aplicação 2 no 3º Período.



Fonte: Elaboração da própria autora.


Figura 42 - Resultado da previsão de carga obtida pela RLM para os dias 01 e 02/08/1990 - Aplicação 2 no 3º Período.



Fonte: Elaboração da própria autora.


Para o conjunto de dados composto por variáveis: hora (h), carga (h) e carga (h-1) descritas no período de 01 de maio a 31 de julho de 1990, nas Figuras 43 e 44 têm-se os valores da carga elétrica real e as previsões de demanda carga elétrica obtidos pelo modelo híbrido para o horizonte de 24 horas (01/08/1990) e 48 horas (01 e 02/08/1990), respectivamente.

Figura 43 - Resultado da previsão de carga obtida pelo modelo híbrido para os dias 01 e 02/08/1990 - Aplicação 2 no 3º Período.



Fonte: Elaboração da própria autora.

Figura 44 - Resultado da previsão de carga obtida pelo modelo híbrido para os dias 01 e 02/08/1990 - Aplicação 2 no 3º Período.



Fonte: Elaboração da própria autora.

Tabela 14 - Análise comparativa - Aplicação 2 no 3º Período.

Coeficiente Correlação	Métodos	Períodos			
		24 horas		48 horas	
		MAPE (%)	Erro Máximo (%)	MAPE (%)	Erro Máximo (%)
0,9791	RLM – Stepwise	3,01	9,79	2,86	9,79
	Modelo Híbrido	1,38	6,94	1,25	6,94


Fonte: Elaboração da própria autora.

A Tabela 14 apresenta a análise comparativa entre MAPE e erro máximo, obtidos através do uso dos métodos, RLM e modelo híbrido, nos horizontes de previsão de 24 e 48 horas para o conjunto de variáveis composto pela hora (h), carga (h) e carga (h-1).

5.9 PREVISÃO DE CARGA ELÉTRICA - HORA, CARGA (H), CARGA (H-1) E CARGA (H-2) REFERENTES AO 3º PERÍODO


A previsão de carga elétrica é realizada utilizando um conjunto de dados composto pela hora (h), carga elétrica referente à hora (h), carga elétrica referente à hora (h-1) e carga elétrica referente à hora (h-2) (Aplicação 3) considerando o período de 01 de maio de 1990 a 31 de julho de 1990. Os valores da carga elétrica real e carga prevista pelo método de regressão linear múltipla (RLM) com variáveis selecionadas pelo método *stepwise* realizadas, respectivamente, no dia 01 de agosto de 1990 e nos dias 01 e 02 de agosto de 1990, podem ser visualizadas nas Figuras 45 e 46.

Figura 45 - Resultado da previsão de carga obtida pela RLM para o dia 01/08/1990 - Aplicação 3 no 3º Período.



Fonte: Elaboração da própria autora.


Figura 46 - Resultado da previsão de carga obtida pela RLM para os dias 01 e 02/08/1990 - Aplicação 3 no 3º Período.



Fonte: Elaboração da própria autora.


Para o conjunto de dados composto por variáveis: hora (h), carga (h), carga (h-1) e carga (h-2) no período de 01 de maio a 31 de julho de 1990, observam-se através das Figuras 47 e 48 os valores da carga elétrica real e as previsões de demanda carga elétrica obtidas pelo modelo híbrido para o dia 01/08/1990 e para os dias 01 e 02/08/1990, respectivamente.

Figura 47 - Resultado da previsão de carga obtida pelo modelo híbrido para os dias 01 e 02/08/1990 - Aplicação 3 no 3º Período.



Fonte: Elaboração da própria autora.

Figura 48 - Resultado da previsão de carga obtida pelo modelo híbrido para os dias 01 e 02/08/1990 - Aplicação 3 no 3º Período.



Fonte: Elaboração da própria autora.

A Tabela 15 exibe o MAPE e o erro máximo, em porcentagem (%), obtidos através do uso dos métodos, RLM e modelo híbrido, nos horizontes de previsão de 24 e 48 horas para o conjunto de variáveis composto pela hora (h), carga (h), carga (h-1) e carga (h-2) para o 3o período.

Tabela 15 - Análise comparativa - Aplicação 3 no 3º Período.

Coeficiente Correlação	Métodos	Períodos			
		24 horas		48 horas	
		MAPE (%)	Erro Máximo (%)	MAPE (%)	Erro Máximo (%)
0,9796	RLM – <i>Stepwise</i>	3,01	10,37	3,71	10,37
	Modelo Híbrido	1,40	4,78	1,54	5,16

Fonte: Elaboração da própria autora.

Também foram realizados testes com as variáveis que apresentaram baixa correlação, como as variáveis de temperatura, porém os resultados obtidos não foram satisfatórios. Em nenhum dos casos, na realização do treinamento da rede neural *perceptron*, houve convergência para a tolerância de erro estabelecida, estacionando em mínimos locais.

6 CONSIDERAÇÕES FINAIS E SUGESTÃO DE TRABALHOS FUTUROS

Neste trabalho foi desenvolvida uma estrutura híbrida a qual é composta por duas metodologias distintas que são: regressão linear múltipla com o critério de seleção *stepwise* e redes neurais artificiais com o algoritmo *backpropagation*.

A regressão linear múltipla através do passo *stepwise* auxilia na determinação das variáveis mais significativas e que devem, então, ser utilizadas como entrada de dados para a rede neural artificial. A vantagem do uso do método *stepwise* é a facilidade de programação computacional e o tempo de processamento rápido. A desvantagem é que não é possível estabelecer uma tolerância mínima de erro, pois o método dos mínimos quadrados é utilizado para se obter uma equação de regressão que mais se aproxime dos dados observados e nem sempre tal aproximação é satisfatória.

A rede neural artificial é responsável em realizar a previsão de carga elétrica, portanto, a vantagem de utilizá-la é que a sua fase de aprendizado é feita em modo *off-line*, desta forma, a fase de previsão, em termos computacionais, é efetuada de forma rápida, e é possível estabelecer uma tolerância mínima de erro.

Uma das desvantagens da rede neural artificial é a dificuldade na determinação dos parâmetros de entrada como, por exemplo, número de neurônios das camadas intermediárias, parâmetro de inclinação da função *sigmóide* e taxa de aprendizagem. A redução no número de variáveis de entrada diminui o espaço de busca de uma arquitetura adequada para a fase de aprendizado.

No caso dos conjuntos de dados testados, o número de variáveis antes da fase *stepwise* foi num total de nove variáveis. Depois desta fase o número de variáveis foi bastante reduzido, respeitando também a exigência de conteúdo diverso da rede neural *perceptron*. Com isso, o número de variáveis selecionadas como dados de entrada para a rede neural artificial foi de duas, três e quatro variáveis como mostra a Tabela 2.

As Tabelas 16 e 17 apresentam uma síntese dos resultados obtidos em termos de erro percentual médio (MAPE) e erro máximo obtidos, respectivamente, com o uso do método de regressão linear múltipla com variáveis selecionadas através do método *stepwise* e modelo híbrido (rede neural *perceptron* via algoritmo *backpropagation* e seleção de variáveis de entrada de dados através do método *stepwise*).

Tabela 16 - Síntese dos resultados obtidos - regressão linear múltipla com seleção *stepwise*.

Regressão Linear Múltipla com Seleção <i>Stepwise</i>	
24 horas	48 horas
Correlação Linear	Correlação Linear
Entre 0,9648 e 0,9837	Entre 0,9648 e 0,9837
MAPE	MAPE
Entre 2,94% e 4,82%	Entre 2,79% e 4,52%
Erro máximo	Erro máximo
Entre 9,79% e 11,33%	Entre 6,14% e 12,60%

Fonte: Elaboração da própria autora.

De acordo com a Tabela 17, para os conjuntos de dados utilizados, a rede neural híbrida proposta apresentou bons resultados de previsão em curto prazo. Comparando-se com a previsão na fase *stepwise* com a fase *perceptron* houve uma melhora significativa na previsão.

Tabela 17 - Síntese dos resultados obtidos - modelo híbrido.

Modelo Híbrido	
24 horas	48 horas
MAPE	MAPE
Entre 1,31% e 1,70%	Entre 1,18% e 1,54%
Erro máximo	Erro máximo
Entre 3,65% e 6,94%	Entre 3,70% e 6,94%

Fonte: Elaboração da própria autora.

Assim, para os conjuntos de dados analisados, a rede neural híbrida atingiu o seu objetivo reduzindo o número de variáveis e obtendo uma previsão de qualidade.

Observa-se, também, que para os testes com variáveis pouco correlacionadas, não houve resultados satisfatórios, e em todos os casos, não houve convergência para a tolerância de erro estabelecida.

Como sugestão para trabalhos futuros propõe-se a utilização de outros conjuntos de dados com variáveis que não foram abordadas neste trabalho, como por exemplo, velocidade

do vento, umidade do ar, etc. e também utilizar o modelo proposto com outros tipos de redes neurais com treinamento supervisionado.

REFERÊNCIAS

BOX, G. E. P.; JENKINS, G. M. **Times series analysis: forecasting and control**. San Francisco: J. Willey, 1976.

FUNG, Y. H. ;TUMMALA, R. V. M. **Forecasting of eletricity consumption: a comparative analysis of regression and artificial neural network models**. In: IEE INTERNATIONAL CONFERENCE ON ADVANCES IN POWER SYSTEM CONTROL, OPERATION AND MANAGEMENT, 2., 1993, Hong Kong. **Proceedings...** Hong kong: IEE, 1993. p. 782-787. Disponível em: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=00292624>>. Acesso em: 20 jun. 2013.

GROSS, G.; GALIANA F. D. Short term load forecasting. **Proceedings of the IEEE**, New York, v. 75, n. 12, p. 1558-1573, 1987. Disponível em: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=01458194>>. Acesso em: 20 jun. 2012.

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

HOCKING, R. R. **The analysis and selection of variables in linear regression biometrics**. Washington, v. 32, n. 1, p. 1-49, 1976.

HOFFMANN, R. e VIEIRA, S. **Análise de regressão: uma Introdução à econometria**. São Paulo: HUCITEC, 1977.

LARSON, R. FABER, B. **Estatística aplicada**. 4. ed. São Paulo: Pearson Hall, 2010.

MOHGRAM, I.; RAHMAN, S. Analysis and evaluation of five short term load forecasting techniques. **IEEE Transactions on Power Systems**, New York, v. 4, n. 4, p. 1484-1491, 1989. Disponível em: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=00041700>>. Acesso em: 15 dez. 2012.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de séries temporais**. 2. ed. São Paulo: Egard Blucher, 2006.

O'DONOVAN, T. M. **Short term forecasting: an introduction to the Box-Jenkins approach**. New York : John Wiley and Sons, 1983.

OLIVEIRA, C. M. **Previsão de cargas elétricas através de uma rede neural híbrida back-ART Fuzzy**. 2012. 76 f. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2012.

RUGGIERO, M. A. G. LOPES, V. L. R. **Cálculo numérico: aspectos teóricos e computacionais**. 2. ed. São Paulo: Pearson Makron Books, 1996.

SARANI, N. et al. Comparison of artificial neural network and multivariate linear regression model to predict sodium adsorption ratio. **International Journal of Biological, Ecological and Environmental Sciences**, Roorkee, v. 1, n. 2, p. 29-34, 2012. Disponível em: <<http://psrcentre.org/images/extraimages/IJBEE%20102007.pdf>>. Acesso em: 25 jun. 2013.

SILVA, A.; MOITA, G. F.; ALMEIDA, P. E. M. Técnica de regressão linear múltipla e métodos estatísticos de seleção de características na redução de dimensionalidade na classificação de E-mails. **Mecânica Computacional**, Buenos Aires, v. 29, p. 9521-9540, 2010.

SILVA, T. A. A. **Previsão de Cargas Elétricas através de um Modelo Híbrido de Regressão com Redes Neurais**. 2012. 64 f. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2012.

SIMPSON, P. K. **Artificial neural systems: foundations, paradigms, applications, and implementations**. New York: Pergamon Press, 1989.

TABACHNICK, B.G, FIDELL, L. S. **Using Multivariate Statistics**. 5. ed. Boston: Pearson 2007.

WIDROW, B.; LEHR, M. A. 30 years of adaptive neural networks: perceptron, madaline, and backpropagation. **Proceedings of the IEEE**, New York, v. 78, n. 9, p. 1415-1442, 1990. Disponível em: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=58323>>. Acesso em: 12 jun. 2013.