



UNIVERSIDADE
ESTADUAL DE LONDRINA

JÚLIO KAZUHIRO TINO

**DESEMPENHO DE MODELOS DE PREVISÃO DE DEMANDA
DIÁRIA E HORÁRIA DE ABASTECIMENTO URBANO DE
ÁGUA:
ESTUDO DE CASO**

JÚLIO KAZUHIRO TINO

**DESEMPENHO DE MODELOS DE PREVISÃO DE DEMANDA
DIÁRIA E HORÁRIA DE ABASTECIMENTO URBANO DE
ÁGUA:
ESTUDO DE CASO**

Dissertação apresentada à Universidade Estadual de Londrina para obtenção do título de Mestre em Engenharia de Edificações e Saneamento.

Orientador: Prof.^a Deize Dias Lopes

Londrina
2011

**Catálogo elaborado pela Divisão de Processos Técnicos da Biblioteca Central da
Universidade Estadual de Londrina**

Dados Internacionais de Catalogação-na-Publicação (CIP)

T591d Tino, Júlio Kazuhiro.
Desempenho de modelos de previsão de demanda diária e horária de abastecimento urbano de água : estudo de caso / Júlio Kazuhiro Tino. – Londrina, 2011.
130 f. : il.

Orientador: Deize Dias Lopes.

Dissertação (Mestrado em Engenharia de Edificações e Saneamento) – Universidade Estadual de Londrina, Centro de Tecnologia e Urbanismo, Programa de Pós-Graduação em Engenharia de Edificações e Saneamento, 2011.

Inclui bibliografia.

1. Abastecimento de água nas cidades – Previsão – Teses. 2. Redes neurais artificiais – Teses. 3. Água – Consumo – Teses. 4. Abastecimento de água nas cidades – Estudo de casos – Teses. 5. Análise de séries temporais – Teses. I. Lopes, Deize Dias. II. Universidade Estadual de Londrina. Centro de Tecnologia e Urbanismo. Programa de Pós-Graduação em Engenharia de Edificações e Saneamento. III. Título.

CDU 628.16

JÚLIO KAZUHIRO TINO

**DESEMPENHO DE MODELOS DE PREVISÃO DE DEMANDA DIÁRIA
E HORÁRIA DE ABASTECIMENTO URBANO DE ÁGUA: ESTUDO DE
CASO**

Dissertação apresentada à Universidade Estadual de Londrina para obtenção do título de Mestre em Engenharia de Edificações e Saneamento.

BANCA EXAMINADORA

Orientadora: Prof^a. Deize Dias Lopes
Universidade Estadual de Londrina – UEL

Prof^a. Vanderli Marino Melem
Universidade Estadual de Londrina – UEL

Prof^a. Luisa Fernanda Ribeiro Reis
Universidade de São Paulo – USP

Londrina, 14 de abril de 2011.

DEDICO

A Deus, minha esposa Cynthia e meus filhos Lucas e Rafael.

AGRADECIMENTOS

Agradeço primeiramente a Deus, criador dos céus, da terra, da luz, das águas e dos seres vivos. Sem Ele, nada existiria.

Agradeço aos meus pais Sumiko e Saburo, pelo amor, dedicação e educação dos filhos. *"Eles perfuraram o poço e encontraram água"*.

Agradeço a minha orientadora, Professora Deize Dias Lopes, pela sua amizade, apoio e compreensão nos momentos difíceis, sendo uma grande motivadora para que pudesse concluir este trabalho. *"Ela montou as instalações hidráulicas"*.

Agradeço todos os colegas da Companhia de Saneamento do Paraná, que diretamente ou indiretamente, contribuíram para a realização do estudo. *"Eles assentaram as tubulações"*.

Agradeço os docentes e amigos da Universidade Estadual de Londrina que me proferiram com sua sabedoria, críticas e discussões que contribuíram para o desenvolvimento deste mestrado. *"Eles trataram a água"*.

Agradeço os meus familiares, meus filhos e minha esposa Cynthia pelo apoio em todos os momentos e incentivo para continuar estudando e trabalhando. *"Eles ajudaram a reservar a água"...*

"Que possamos abrir a torneira e utilizar a água com sabedoria!"

A todos, muito obrigado!

“Mede o que é mensurável e torna mensurável o que não o é”.

Galileu Galilei

TINO, Júlio Kazuhiro. **Desempenho de modelos de previsão de demanda diária e horária de abastecimento urbano de água**: estudo de caso. 2011. 130 f. Dissertação (Mestrado em Engenharia de Edificações e Saneamento) – Universidade Estadual de Londrina. Londrina.

RESUMO

O panorama do abastecimento de água mundial é movido pela constante busca à eficiência operacional dos sistemas de abastecimento de água, originada pelo aumento populacional, escassez de recursos hídricos, elevação de perdas de água e aumento do consumo de energia elétrica nos sistemas de bombeamento. Este trabalho teve por objetivo pesquisar três grupos de modelos quantitativos de previsão de demanda de abastecimento de água: modelos de séries temporais, modelos causais e de inteligência artificial por redes neurais artificiais. Sob este desígnio, as demandas diárias e horárias foram estudadas em dois períodos: fase de ajuste (estudo do passado histórico) e fase de previsão (predição do futuro). A partir do diagnóstico realizado pela comparação dos modelos de ajuste e previsão, conclui-se que, entre os modelos estudados, inexistem modelos ótimos de ajuste e previsão, embora alguns modelos tenham-se evidenciado em relação a outros. As decisões conduzidas pelo conhecimento da demanda proporcionam maior capacidade de decisão aos gestores responsáveis pelo abastecimento público de água, habilitando-os com maior capacidade de planejamento da distribuição, exame crítico do potencial de economia de energia elétrica e detecção de perdas no sistema distribuidor, os quais são essenciais ao equilíbrio e à sustentabilidade ambiental urbana. Todos os modelos possuem proficuidades e a sua aplicação depende da disponibilidade de dados confiáveis, do nível de precisão e detalhamento requerido e possuem o objetivo de automatizar os resultados. Todavia, não supre a competência de um analista de assumir deliberações, pois procedimentos automáticos não substituem o conhecimento especial de um analista sobre os dados estudados.

Palavras-chave: Demanda de abastecimento de água. Modelos de previsão. Séries temporais. Modelos causais. Redes neurais artificiais.

TINO, Júlio Kazuhiro. **Performance of daily and hourly demand forecasting models of urban water supply: a case study.** 2011. 130 p. Dissertation (Master's Degree in Construction and Sanitation Engineering) – State University of Londrina. Londrina.

ABSTRACT

The worldwide water supply panorama is shaped by the constant search for operational efficiency of water supply systems, driven by the demand of population growth, water shortages, increased water loss, and increased energy consumption of pumping systems. This research studies three sets of quantitative methods for forecasting demand in water supply: time series models, causal models, and artificial intelligence by artificial neural networks. Under this plan, the daily and hourly demands were studied in two periods: the adjustment phase (study of the historical past), and the prediction phase (predicting the future). Based on the diagnosis made by comparing the model predictions, it is concluded that among the models studied, there is no optimal fit and prediction model, although some models were shown to perform better than others. Knowledge of the demand provides a better basis for decision-making among the managers responsible for the public water supply, giving them greater capacity in the distribution planning, critical examination of the potential for energy saving, and detection of losses in the distribution system, all of which are essential for the balance and sustainability of the urban environment. All three models have their usefulness, but their application depends on the availability of reliable data and the level of precision and detail required, with the goal of automating the results. However, they do not do away with the expertise of an analyst in decision-making, as automatic procedures cannot replace the analyst's specialist knowledge of the data studied.

Keywords: Demand for water supply. Forecasting models. Time series. Causal models. Artificial neural networks.

LISTA DE ILUSTRAÇÕES

Figura 4 1 –	Métodos e Modelos de Previsão de Demanda.....	34
Figura 4 2 –	Características de séries temporais	37
Figura 4 3 –	Procedimento de previsão dos modelos de Box e Jenkins	45
Figura 4 4 –	Estrutura dos neurônios biológicos	51
Figura 4 5 –	Disposição física dos neurônios biológicos.....	51
Figura 4 6 –	Comparação entre o Neurônio Biológico e o Neurônio Artificial.....	53
Figura 4 7 –	Topologia das RNAs	53
Figura 4 8 –	Modelo de um neurônio artificial	54
Figura 4 9 –	Principais funções de ativação: (a) degrau; (b) linear por partes; (c) sigmoide e (d) exponencial	55
Figura 4 10 –	Representação de RNA do tipo MLP	56
Figura 4 11 –	Fase de propagação – backpropagation	57
Figura 4 12 –	Fase de retropropagação – backpropagation.....	57
Figura 4 13 –	Rede neural RBF com múltiplas saídas	58
Figura 4 14 –	Representação gráfica de uma função qualquer através da combinação de funções gaussianas	59
Figura 5 1 –	Mapa de localização do Município de Londrina	61
Figura 5 2 –	Área de abastecimento do REL Maria Lúcia	62
Figura 5 3 –	Perspectiva do centro de reservação Maria Lúcia	63
Figura 5 4 –	Classificação climática de Köppen (Fonte: Instituto Agrônômico do Paraná)	64
Figura 5 5 –	Temperatura média mínima anual de Londrina - PR de 1961 a 2008	66
Figura 5 6 –	Temperatura média máxima anual de Londrina - PR de 1961 a 2008	66
Figura 5 7 –	Precipitação total anual de Londrina - PR de 1961 a 2008	66
Figura 7 1 –	Gráfico de Ajuste de Médias Móveis com Parcela de Aproximação	75
Figura 7 2 –	Gráfico de Ajuste de Médias Móveis sem Parcela de Aproximação	75
Figura 7 3 –	Gráfico para o período de previsão de Médias Móveis Ponderadas.....	76

Figura 7 4 – Gráfico de Ajuste de Suavização Exponencial Simples para Demanda Diária	77
Figura 7 5 – Gráfico para o Período de Previsão de Suavização Exponencial Simples	78
Figura 7 6 – Gráfico de Ajuste de Suavização Exponencial Dupla para Demanda Diária	79
Figura 7 7 – Gráfico para o Período de Previsão de Suavização Exponencial Dupla.....	80
Figura 7 8 – Gráfico de Ajuste do Modelo de Holt-Winters Aditivo para Demanda Diária	81
Figura 7 9 – Gráfico para o Período de Previsão do Modelo de Holt-Winters Aditivo	81
Figura 7 10 – Gráfico de Ajuste do Modelo de Holt-Winters Multiplicativo para Demanda Diária	82
Figura 7 11 – Gráfico para o Período de Previsão do Modelo de Holt-Winters Multiplicativo.....	83
Figura 7 12 – Função de Autocorrelação (FAC) para dados diários de demanda com limite de significância de 95%.....	84
Figura 7 13 – Função de Autocorrelação Parcial (FACP) para dados diários de demanda com limite de significância de 95%.....	84
Figura 7 14 – Evolução da Série Temporal com relação à Média e Tendência Linear	85
Figura 7 15 – Gráfico de Ajuste do Modelo de Box-Jenkins - ARIMA Sazonal para Demanda Diária – SARIMA (0,0,0)(1,1,1) ₇	86
Figura 7 16 – Gráfico para o Período de Previsão do Modelo de Box e Jenkins – SARIMA (0,0,0)x(1,1,1) ₇	86
Figura 7 17 – Gráfico de Ajuste do Modelo de Regressão Múltipla para Demanda Diária.	87
Figura 7 18 – Gráfico para o Período de Previsão do Modelo de Regressão Linear Múltipla.	88
Figura 7 19 – Gráfico de Ajuste do Modelo de Regressão Múltipla com Médias Móveis para Demanda Diária.....	89
Figura 7 20 – Gráfico para o Período de Previsão do Modelo de Regressão Linear Múltipla e Médias Móveis.	90

Figura 7 21 – Topologia da Rede Neural Artificial MLP-BP 3-15-11-1	91
Figura 7 22 – Gráfico de Ajuste do Modelo de Rede Neural Artificial MLP Backpropagation 3-15-11-1 para Demanda Diária.....	91
Figura 7 23 – Gráfico para o Período de Previsão do Modelo RNA MLP-BP.....	92
Figura 7 24 – Gráfico para o Período de Previsão do Modelo RNA RBF.....	94
Figura 7 25 – Gráfico de Ajuste da Demanda Horária pelo Modelo de Médias Móveis com Parcela de Aproximação.	96
Figura 7 26 – Gráfico de Ajuste da demanda horária pelo Modelo de Médias Móveis sem Parcela de Aproximação.	96
Figura 7 27 – Gráfico para o período de previsão de Médias Móveis Ponderadas para demanda horária.....	97
Figura 7 28 – Gráfico de Ajuste do Modelo de Holt-Winters Aditivo para Demanda Horária.....	98
Figura 7 29 – Gráfico para o Período de Previsão do Modelo de Holt-Winters Aditivo para demanda horária.	99
Figura 7 30 – Gráfico de ajuste do Modelo de Holt-Winters Multiplicativo para demanda horária	100
Figura 7 31 – Gráfico para o Período de Previsão do Modelo de Holt-Winters Multiplicativo horário.....	101
Figura 7 32 – Função de Autocorrelação para dados horários de demanda com limite de significância de 95%	102
Figura 7 33 – Função de Autocorrelação Parcial para dados horários de demanda com limite de significância de 95%.....	102
Figura 7 34 – Evolução da Série Temporal de demanda horária com relação à Média e Tendência Linear.....	103
Figura 7 35 – Gráfico de Ajuste do Modelo de Box-Jenkins - ARIMA Sazonal para Demanda Horária.....	104
Figura 7 36 – Gráfico para o Período de Previsão do Modelo de Box e Jenkins (SARIMA (1,0,1)x(1,1,2) ₂₄).....	104
Figura 7 37 – Gráfico de Ajuste do Modelo de Regressão Linear para Demanda Horária.....	105
Figura 7 38 – Gráfico de importância das variáveis preditoras	106
Figura 7 39 – Gráfico de Ajuste do Modelo Híbrido de Regressão Múltipla para Demanda Horária.....	107

Figura 7 40 – Gráfico para o Período de Previsão Horária do Modelo Híbrido de Médias Móveis e Regressão Linear Múltipla.....	108
Figura 7 41 – Topologia da Rede Neural Artificial MLP-BP 4-10-6-1.....	109
Figura 7 42 – Gráfico de Ajuste do Modelo de Rede Neural Artificial MLP Backpropagation para Demanda Diária.	109
Figura 7 43 – Gráfico para o Período de Previsão Horária do Modelo RNA MLP-BP.....	110
Figura 7 44 – Topologia da Rede Neural Artificial RBF 2-7-1.. ..	110
Figura 7 45 – Gráfico para o Período de Previsão horária do Modelo RNA RBF.....	112

LISTA DE TABELAS

Tabela 4 1 –	Comportamento das FAC e FACP de um processo ARIMA (p,d,q).....	46
Tabela 4 2 –	Principais diferenças entre as redes MLP e RBF.....	60
Tabela 5 1 –	Ligações totais abastecidas e Economias totais abastecidas	63
Tabela 7 1 –	Valores de β e Análise de Erros de Média Móvel Ponderada para o período de ajuste	75
Tabela 7 2 –	Análise de Erros de Média Móvel Ponderada para o período de previsão.....	76
Tabela 7 3 –	Análise de Erros do Modelo de Suavização Exponencial Simples para o período de ajuste	77
Tabela 7 4 –	Análise de Erros do Modelo de Suavização Exponencial Simples para o período de Previsão.	78
Tabela 7 5 –	Análise de Erros do Modelo de Suavização Exponencial Dupla para o período de ajuste.	79
Tabela 7 6 –	Análise de Erros do Modelo de Suavização Exponencial Dupla para o período de previsão.	80
Tabela 7 7 –	Análise de Erros do Modelo de Holt-Winters Aditivo para o período de ajuste.	81
Tabela 7 8 –	Análise de Erros do Modelo de Holt-Winters Aditivo para o período de previsão.....	82
Tabela 7 9 –	Análise de Erros do Modelo de Holt-Winters Multiplicativo para o período de ajuste.	82
Tabela 7 10 –	Análise de Erros do Modelo de Holt-Winters Multiplicativo para o período de previsão.....	83
Tabela 7 11 –	Resultados das ordens SARIMA (p,d,q)(P,D,Q)s.....	85
Tabela 7 12 –	Análise de Erros do Modelo de Box e Jenkins para o período de previsão.....	86
Tabela 7 13 –	Análise de Erros do Modelo de Regressão Linear Múltipla para o período de ajuste	87
Tabela 7 14 –	Análise de Erros do Modelo de Regressão Linear Múltipla para o período de previsão.....	88

Tabela 7 15 – Análise de Erros do Modelo de Híbrido de Regressão Linear Múltipla com Médias Móveis para o período de ajuste.....	89
Tabela 7 16 – Análise de Erros do Modelo de Regressão Linear Múltipla com Médias Móveis para o período de previsão.....	90
Tabela 7 17 – Resultado de Erros para aplicação do Modelo de Rede Neural Artificial MLP Backpropagation 3-15-11-1 para o período de ajuste da demanda diária.	92
Tabela 7 18 – Resultado de Erros para aplicação do Modelo de Rede Neural Artificial MLP Backpropagation 3-15-11-1 para o período de previsão da demanda diária.	92
Tabela 7 19 – Resultado de Erros da Aplicação do Modelo de Rede Neural Artificial RBF 3-7-1 para o período de ajuste.	94
Tabela 7 20 – Resultados de Erros do Modelo de Rede Neural Artificial RBF para o período de previsão.	94
Tabela 7 21 – Análise de Erros de Média Móvel Ponderada para o período de ajuste horário.	96
Tabela 7 22 – Análise de Erros de Média Móvel Ponderada para o período de previsão para demanda horária.	97
Tabela 7 23 – Análise de Erros do Modelo de Holt-Winters Aditivo para o período de ajuste.	98
Tabela 7 24 – Resultado de Erros do Modelo de Holt-Winters Aditivo para o período de previsão.....	99
Tabela 7 25 – Análise de Erros do Modelo de Holt-Winters Multiplicativo para o período de ajuste horário.	100
Tabela 7 26 – Análise de Erros do Modelo de Holt-Winters Multiplicativo para o período de previsão.....	101
Tabela 7 27 – Resultados das ordens SARIMA (p,d,q)x(P,D,Q)S para dados horários.	104
Tabela 7 28 – Análise de Erros do Modelo de Box e Jenkins para o período de previsão horária	105
Tabela 7 29 – Análise de Erros do Modelo Híbrido de Médias Móveis e Regressão Linear Múltipla para o período de ajuste.	107
Tabela 7 30 – Análise de Erros do Modelo de Regressão Linear Múltipla para o período de previsão.....	108

Tabela 7 31 – Resultado de Erros do Modelo de Rede Neural Artificial MLP Backpropagation para o período de ajuste horário.	110
Tabela 7 32 – Resultado de Erros do Modelo de Rede Neural Artificial MLP Backpropagation para o período de previsão horária.	110
Tabela 7 33 – Análise de Erros do Modelo de Rede Neural Artificial RBF para o período de ajuste horário.	112
Tabela 7 34 – Análise de Erros do Modelo de Rede Neural Artificial RBF para o período de previsão horária.	112
Tabela 7 35 – Classificação da eficiência dos modelos no período de ajuste diário.	113
Tabela 7 36 – Classificação da eficiência dos modelos no período de previsão diária.	114
Tabela 7 37 – Classificação da eficiência dos modelos no período de ajuste horário.	115
Tabela 7 38 – Classificação da eficiência dos modelos no período de previsão horária.	116

LISTA DE ABREVIATURAS E SIGLAS

ABNT	Associação Brasileira de Normas Técnicas;
ANFIS	Adaptive Neuro-Fuzzy Inference System;
ANN	Artificial Neural Network;
ARIMA	Auto Regressivo Integrado de Médias Móveis;
AWWA	American Water Works Association;
CCO	Centro de Controle Operacional;
CDD	Coefficiente de Demanda Diária;
Cfa	Clima temperado úmido com verão quente;
Cfb	Clima temperado úmido com verão temperado;
DAN	Rede Neural Dinâmica;
FAC	Função de Autocorrelação;
FACP	Função de Autocorrelação Parcial;
IAPAR	Instituto Agrônomo do Paraná;
IBGE	Instituto Brasileiro de Geografia e Estatística;
MAE	Mean Absolute Error, Erro Absoluto Médio;
MAPE	Mean Absolute Percent Error, Erro Percentual Médio Absoluto;
MARS	Multivariate Adaptive Regression Splines;
MFIS	Mamdani Type Fuzzy Inference System;
MLP	Multilayer Perceptron;
MSE	Meas Squared Error, Erro Quadrático Médio;
NBR	Norma Brasileira;
ONU	Organização das Nações Unidas;
PA	Parcela de Aproximação;
PNCDA	Programa Nacional de Combate ao Desperdício de Água;
PPR	Projection Pursuit Regression;
RBF	Radial Basis Function;
RNA	Redes Neurais Artificiais;
RNA MLP-BP	Redes Neurais Perceptron de Múltiplas Camadas Backpropagation;
RNN	Redes Neurais Naturais;
SANEPAR	Companhia de Saneamento do Paraná;
SARIMA	Sazonal Auto Regressivo Integrado de Médias Móveis;
SVR	Support Vector Regression.

LISTA DE SÍMBOLOS

α	Constante de suavização de nível;
β	Constante de suavização da tendência;
γ	Constante de suavização da sazonalidade;
b_t	Tendência no tempo t ;
k_1	Coefficiente do dia de maior consumo de água;
k_2	Coefficiente da hora de maior consumo de água;
x_t	Média móvel; último valor observado;
N	Número de observações;
x_{pt}	Média móvel ponderada;
F_{t+1}	Previsão no tempo $t+1$;
F_t	Previsão no tempo t ;
F_{t+m}	Previsão para o período m ;
t	Tempo;
L_t	Nível no tempo t ;
T_t	Tendência no tempo t ;
k	Número de períodos à frente a ser previsto;
z_t	Valor do dado no tempo t ;
\hat{z}_{t+k}	Previsão no tempo t , k passos à frente (valor estimado);
S	Comprimento da Sazonalidade;
b_t	Tendência no tempo t ;
Y_t	Valor observado no tempo t ;
X	Valor da demanda;
Y	Previsão;
Φ_{kk}	Função de Autocorrelação Parcial;
ε	Termo de erro do modelo;
x_i	Entradas da rede;
w_{ki}	Pesos sinápticos;
b_k	Bias (viés, erro sistemático ou tendenciosidade);
y_k	Saída da rede;
$\Psi(\cdot)$	Função de ativação de RNA.

SUMÁRIO

1	INTRODUÇÃO.....	20
2	OBJETIVOS	23
2.1	OBJETIVO GERAL.....	23
2.2	OBJETIVOS ESPECÍFICOS.....	23
3	REVISÃO BIBLIOGRÁFICA	24
3.1	COMPOSIÇÃO DA DEMANDA DE CONSUMO DE ÁGUA.....	24
3.2	FATORES QUE INFLUENCIAM A DEMANDA DE ÁGUA	24
3.3	VARIAÇÕES QUANTITATIVAS DE DEMANDA DE ÁGUA	26
3.4	PREVISÃO DE DEMANDA DE ÁGUA.....	27
3.5	ESTUDOS SOBRE PREVISÃO DE DEMANDA	28
4.	MÉTODOS E MODELOS DE PREVISÃO DE DEMANDA.....	36
4.1	MODELOS DE SÉRIES TEMPORAIS	37
4.1.1	Modelo de médias móveis.....	38
4.1.2	Modelos de suavização exponencial.....	39
	<i>Suavização exponencial simples.....</i>	39
	<i>Modelo de Holt ou suavização exponencial dupla.....</i>	40
	<i>Modelo de Holt-Winters aditivo.....</i>	40
	<i>Modelo de Holt-Winters multiplicativo</i>	41
4.1.3	Modelos de Box e Jenkins ou ARIMA	42
	<i>Modelos autorregressivos AR(p).....</i>	43
	<i>Modelos de médias móveis MA(q).....</i>	44
	<i>Modelos autorregressivos e de médias móveis ARMA(p,q)</i>	44
	<i>Modelos autorregressivos integrados de médias móveis</i>	
	<i>ARIMA(p,d,q)</i>	44
	<i>Procedimentos de previsão utilizando os modelos de Box e</i>	
	<i>Jenkins.....</i>	45
4.2	MODELOS CAUSAIS OU DE DECOMPOSIÇÃO	46
	<i>Regressão linear múltipla.....</i>	47
	<i>Regressão Linear Múltipla por Etapas (Stepwise).....</i>	48

4.3	MODELO HÍBRIDO DE DEMANDAS MÉDIAS COM REGRESSÃO LINEAR MÚLTIPLA	48
4.3.1	Modelo híbrido de médias móveis com regressão linear múltipla	49
4.4	MODELOS DE REDES NEURAIS ARTIFICIAIS	50
4.4.1	Redes de neurônios biológicos	50
4.4.2	Redes de neurônios artificiais	52
	<i>Breve histórico das redes neurais artificiais</i>	52
	<i>Neurônios artificiais e sua topologia</i>	52
	<i>Funções de ativação das redes neurais artificiais</i>	54
	<i>Processos de aprendizagem</i>	55
4.4.3	Modelos de redes neurais MLP e algoritmo backpropagation	56
4.4.4	Modelos de redes neurais RBF	58
4.4.5	Principais diferenças entre os modelos de Redes Neurais MLP e RBF	59
5.	CARACTERIZAÇÃO DA ÁREA DO ESTUDO DE CASO	61
6.	PROCEDIMENTO	67
6.1	ANÁLISE DO PROBLEMA DE PESQUISA	67
6.2	IDENTIFICAÇÃO DA SOLUÇÃO E LIMITAÇÕES DO ESTUDO	68
6.3	COLETA DE DADOS	68
6.4	ANÁLISE DE ERROS	69
6.5	TRATAMENTO DOS DADOS	72
7.	RESULTADOS E DISCUSSÃO	73
7.1	RESULTADOS DE PREVISÕES DIÁRIAS	73
7.1.1	Modelo de Médias Móveis	73
7.1.2	Modelo de Suavização Exponencial Simples	77
7.1.3	Modelo de Holt ou Suavização Exponencial Dupla	78
7.1.4	Modelo de Holt-Winters Aditivo	80
7.1.5	Modelo de Holt-Winters Multiplicativo	82
7.1.6	Modelo de Box e Jenkins e Análise de FAC e FACP	83
7.1.7	Modelo de Regressão Linear Múltipla por Método Stepwise	87

7.1.8	Modelo Híbrido de Médias Móveis e Regressão Linear Múltipla.....	88
7.1.9	Redes Neurais Artificiais MLP-BP	90
7.1.10	Redes Neurais Artificiais RBF.....	92
7.2	RESULTADOS DE PREVISÕES HORÁRIAS	95
7.2.1	Modelo de Médias Móveis	95
7.2.2	Modelos de Suavização Exponencial	97
7.2.3	Modelo de Holt-Winters Aditivo	98
7.2.4.	Modelo de Holt-Winters Multiplicativo	99
7.2.5.	Modelo de Box e Jenkins e Análise de FAC e FACP.....	101
7.2.6.	Modelo Híbrido de Médias Móveis e Regressão Linear Múltipla Stepwise	105
7.2.7.	Redes Neurais Artificiais MLP-BP	108
7.2.8.	Redes Neurais Artificiais RBF.....	111
7.3	COMPARAÇÃO DOS RESULTADOS.....	113
7.3.1	Resultados de Demandas Diárias.....	113
7.3.2	Resultados de Demandas Horárias	115
8.	CONCLUSÃO.....	117
9.	REFERÊNCIAS BIBLIOGRÁFICAS	119
	ANEXO A	124
	ANEXO B	127

1 INTRODUÇÃO

O cenário do abastecimento público de água no Brasil e no mundo é marcado pela constante busca da eficiência operacional dos sistemas de abastecimento de água. Isso vem ocorrendo, principalmente devido ao aumento populacional, escassez de recursos hídricos em quantidade e qualidade, elevação de perdas de água nos sistemas de abastecimento e consequente aumento do consumo de energia elétrica.

O aumento da população mundial, associada a sua concentração em áreas urbanas e consequente aumento do consumo de água e energia, tem provocado severos desequilíbrios no meio ambiente do planeta como a perda de biodiversidade e carência de recursos naturais, especialmente quanto aos recursos hídricos. Segundo dados da ONU (2007), o índice de crescimento populacional anual no Brasil é de 1,26%, acima da média de crescimento populacional verificado mundialmente (1,17%).

A relação entre a população urbana e rural inverteu-se no Brasil durante a década de 1960, quando foi observado um rápido aumento populacional nas cidades. De acordo com o IBGE (2007), o censo realizado no ano 2000 constatou que 81,23% da população brasileira vivem em áreas urbanas. A migração da população da área rural para a urbana é um fato constatado pelo histórico mundial, onde a preocupação com o abastecimento de água urbano deverá tornar-se maior a cada ano.

A quantidade de água potável demandada pelas populações urbanas revela o problema de sua escassez. Através dos progressivos volumes de água requeridos, devido à necessidade de seus habitantes, os recursos hídricos esgotam-se gradativamente. Detoni e Dondoni (2008) afirmam que a necessidade por água no mundo deve dobrar nos próximos 25 anos, sendo que quatro bilhões de pessoas poderão enfrentar a insuficiência de água até o ano 2025.

Com o passar dos tempos, os sistemas de abastecimento de água sofrem com o desgaste natural das unidades operacionais, causado pela diminuição da vida útil dos componentes constituintes do sistema. Este fato propicia a elevação

dos índices de perdas de água, caso não haja a devida manutenção e investimentos orientados pela dinâmica de cada sistema de abastecimento.

De acordo com Perroni (2005), a produção de água potável para fornecimento aos centros urbanos exige elevado consumo de energia elétrica, sobretudo nos sistemas de bombeamento utilizados para a extração de água dos mananciais, superficiais ou subterrâneos, no processo de tratamento, na elevação aos reservatórios de distribuição ou para alcançar a pressão necessária à distribuição direta na rede de abastecimento.

Os custos com energia elétrica das empresas concessionárias de saneamento representam o segundo item de suas despesas, ficando atrás apenas dos gastos com serviços de mão de obra (Gomes, 2009). O consumo de energia em sistemas de bombeamento representa apreciável dispêndio, por isso, em muitas localidades, as concessionárias de saneamento constituem-se como as principais clientes das empresas de energia elétrica.

O gasto de energia para o bombeamento de água potável é diretamente proporcional à demanda requerida do sistema de abastecimento de água. Portanto, o gerenciamento da demanda e sua previsão torna-se uma atividade essencial na manutenção da integridade e sustentabilidade ambiental.

Scare e Zylbersztajn (2007) explicam a percepção da insuficiência de água para o consumo humano no mundo, pelo aumento da demanda devido à explosão demográfica e ao crescimento econômico ou pela crescente degradação da qualidade desse recurso esgotável, causada pela poluição indiscriminada.

Borges (2003) refere-se ao conhecimento de demanda como de fundamental importância para o intuito de se alcançar a excelência na operação do serviço. Porém, de acordo com Silva (2003), “as empresas de saneamento não parecem ainda ter reconhecido o papel fundamental da previsão e administração da demanda como fonte de aprimoramento operacional”.

A previsão de demanda tem por finalidade subsidiar o planejamento da reservação, a redução de perdas de água e do consumo de energia requerida, garantia do abastecimento público, preservação dos recursos hídricos, conservação dos recursos energéticos e em especial, sobretudo, a preservação do meio ambiente e a sustentabilidade ambiental urbana.

O estudo apresentado neste trabalho visa examinar a previsão de demandas diárias e horárias de abastecimento de água por meio de um estudo de caso na cidade de Londrina, Estado do Paraná, através da avaliação de diferentes métodos, com objetivo de prever a demanda de consumo e observar a influência de fatores climáticos e sazonais no consumo demandado no sistema de abastecimento de água.

Fundamentalmente, existem dois grupos de métodos de previsão: os métodos qualitativos e os métodos quantitativos, os quais são subdivididos em diversos modelos. O enfoque deste trabalho é estudar os métodos quantitativos para a previsão de demanda de abastecimento de água e examinar os modelos de séries temporais, modelos causais e modelos de redes neurais.

Os modelos de séries temporais realizam a previsão através dos padrões ordenados no tempo, que geraram a demanda passada e são projetados para o futuro, ou seja, o futuro reproduz o passado. Os modelos de suavização exponencial e modelos de Box-Jenkins serão abordados neste trabalho como exemplares de modelos de séries temporais.

Os modelos causais ou de decomposição buscam correlacionar a demanda (variável dependente) com outros fatores tais como temperatura, pluviosidade, umidade do ar e vento (variáveis independentes). A Regressão Linear Múltipla é um dos modelos causais mais conhecidos e também será alvo de estudo deste trabalho.

Por fim, os modelos de Redes Neurais Artificiais (RNA), constituem-se de técnicas computacionais, que estudam o padrão matemático inspirado pela estrutura neural de organismos biológicos inteligentes, os quais adquirem conhecimento por meio da experiência. Neste estudo, a RNA de múltiplas camadas (MLP) e RNA de base radial (RBF) serão igualmente estudados e seus resultados comparados aos demais modelos.

2 OBJETIVOS

2.1 OBJETIVO GERAL

O objetivo geral deste trabalho é pesquisar modelos quantitativos de previsão de demanda de abastecimento de água: modelos de séries temporais, modelos causais e de inteligência artificial por redes neurais artificiais e aplicá-los em um estudo de caso para subsidiar a previsão de demanda de água, cuja finalidade é reduzir custos e contribuir para melhorar a eficiência operacional das empresas de saneamento.

2.2 OBJETIVOS ESPECÍFICOS

Este trabalho possui os seguintes objetivos específicos:

- levantar na literatura os métodos aplicados à previsão de demanda de abastecimento de água;
- estudar modelos quantitativos de previsão: modelos de séries temporais, modelos causais e inteligência artificial através de redes neurais artificiais;
- aplicar os modelos estudados em um estudo de caso localizado na zona de abastecimento do reservatório elevado do centro de reservação Maria Lúcia do sistema de abastecimento de água de Londrina, Estado do Paraná;
- avaliar o modelo mais apropriado às séries diárias e horárias, por meio da verificação e análise de erros.

3 REVISÃO BIBLIOGRÁFICA

3.1 COMPOSIÇÃO DA DEMANDA DE CONSUMO DE ÁGUA

Para a determinação da demanda de água, devem ser considerados os consumos das ligações medidas e não medidas e o volume de perdas no sistema (ABNT - NBR 12211, 1992).

O abastecimento público deve fornecer água em quantidade e qualidade suficiente, com pressões adequadas e de forma ininterrupta, para atender as demandas residenciais, comerciais e industriais, onde o mesmo está inserido. Comumente, admite-se o uso da água em função da população e dimensiona-se o sistema para a população prevista considerando o horizonte de projeto.

Contudo, alguns autores e estudos desde a década de 60 têm apresentado críticas ao modelo que considera o consumo per capita, uma vez que este desconsidera outras parcelas que compõem o consumo de água dos sistemas de abastecimento, tais como o consumo de indústrias, comércio, hospitais e escolas, e por isso geram dados de consumo errôneos quanto à natureza da demanda.

Yassuda e Nogami (1976) classificam a demanda de água nas seguintes classes de destinação que compõem o consumo: uso residencial, uso industrial ou comercial, uso público e perdas, os quais constituem todos os destinos possíveis da água abastecida.

3.2 FATORES QUE INFLUENCIAM A DEMANDA DE ÁGUA

Conforme Yassuda e Nogami (1976), Protopapas et al. (2000), Zhou et al. (2000), Borges (2003), Tsutiya (2004), Trautwein (2004) e Falkenberg (2005), os seguintes fatores alteram a demanda de água:

a) Condições climáticas: o consumo de água é maior no verão e diretamente proporcional ao aumento da temperatura ambiente. As condições de

umidade do ar e pluviosidade são inversamente proporcionais ao consumo de água. Fatores climáticos tais como o aquecimento global causado por gases de efeito estufa, podem agravar a situação de escassez por aumento do consumo de água, devido a elevação da temperatura do ar. Outros efeitos climáticos anômalos, popularmente conhecidos por El Niño e La Niña, afetam diretamente o clima e em consequência, podem comprometer o consumo de água no mundo.

b) Hábitos e nível de vida da população: quanto mais alto o nível de vida da população, maior é o consumo em decorrência da utilização da água em atividades que visam o conforto das pessoas.

c) Natureza da cidade: cidades com natureza industrial apresentam o consumo per capita maior que cidades de caráter tipicamente residenciais, tais como cidades dormitórios, cidades satélites, conjuntos habitacionais, entre outros, os quais apresentam menor consumo per capita.

d) Medição de água: a falta de medição com hidrômetros (micromedição) faz com que haja aumento no desperdício do consumo de água.

e) Pressão na rede de distribuição: a pressão na rede é diretamente proporcional à demanda de água, seja por aumento de vazamentos ou por aumento de consumo de aparelhos ligados diretamente à rede.

f) Presença de rede coletora de esgoto: trata-se de um item que merece discussão, pois dependendo do nível de vida da população, há aumento ou diminuição do consumo de água. Em classes de poder econômico mais elevado e onde havia restrição anterior à disposição de esgoto, há aumento do consumo de água pela despreocupação com o destino final do esgoto. Já em classes menos abastadas, a presença de rede coletora de esgoto diminui o consumo de água, devido ao aumento da tarifa com o esgoto agregado.

g) Preço da água: a demanda de água é afetada pelo preço. O aumento da tarifa faz com que a população procure meios de emprego do uso racional da água.

h) Turismo: a sazonalidade e a alteração do perfil populacional de cidades turísticas conferem mudanças no padrão de consumo da água.

i) Dia da semana e feriados: comumente, os dias de maior consumo concentram-se às segundas-feiras, sextas-feiras e sábados, onde os afazeres domésticos, tais como lavagens de roupas e pisos, concentram-se nesses dias. Aos domingos e feriados, verificam-se menores consumos diários.

Segundo Trautwein (2004), alguns fatores influenciam o consumo conforme o horizonte de previsão considerado na Tabela 3-1:

Tabela 3-1 - Fatores que influenciam o consumo

horizonte considerado de previsão	fatores que influenciam o consumo
horária	período do dia
horária e diária	temperatura umidade ou chuva dia da semana
semanal e mensal	época do ano
mensal e semestral	variação no número de ligações

Fonte: Trautwein, 2004

3.3 VARIAÇÕES QUANTITATIVAS DE DEMANDA DE ÁGUA

A Norma NBR 12211 (1992) considera que a demanda é composta pelo consumo de ligações medidas e não medidas além do volume de perdas no sistema. A citada Norma apresenta os conceitos de coeficiente do dia de maior consumo (k_1), Eq. 3.1, e coeficiente da hora de maior consumo (k_2), Eq. 3.2:

$$k_1 = \frac{\text{maior consumo diário do ano}}{\text{consumo médio diário do ano}} \quad (\text{Eq. 3.1})$$

$$k_2 = \frac{\text{maior vazão horária do dia}}{\text{vazão média horária do dia}} \quad (\text{Eq. 3.2})$$

Tsutiya (2004) apresentou recomendações para a determinação de k_1 e k_2 para projetos, baseado em dados obtidos por diversos autores e entidades. Em sua pesquisa, o coeficiente k_1 variou entre 1,08 a 4,00 e o coeficiente k_2 variou entre 1,30 a 6,00. Usualmente, utiliza-se $k_1 = 1,20$ e $k_2 = 1,50$; na falta de maiores informações ou dados da área de estudo do projeto.

O estudo da variação quantitativa de água é importante no planejamento da reservação e produção. Conforme Falkenberg (2005), os reservatórios de distribuição armazenam água nos períodos de menor consumo para suprir as necessidades dos períodos de maior consumo e demandas de emergência.

3.4 PREVISÃO DE DEMANDA DE ÁGUA

Billings e Jones (2008) relatam que, segundo a AWWA – American Water Works Association, 65% dos serviços públicos de água americanos são operados por previsão de demanda de água per capita.

Babbitt et al. (1973) expõem: “a estatística mostra que a demanda per capita e a população total não apresentam boa correlação”. Pois o consumo per capita é aumentado pelas indústrias, as quais tendem a crescer mais rapidamente que a população total.

Desde os anos 60, economistas e cientistas sociais têm criticado previsões de demanda de consumo de água através de métodos per capita, pelo fato do método ignorar fatores socioeconômicos das áreas de estudo (Billings e Jones, 2008).

Atualmente, uma ampla gama de métodos é utilizada para a realização de previsões. O método a ser empregado depende da sofisticação técnica do analista, dos recursos destinados ao processo de previsão e dos dados disponíveis.

Para a predição dos consumos de água, deve-se entender a variabilidade da demanda explicada através da relação com os fatores descritos no item 3.2. Alguns fatores apresentam maior correlação com a demanda de água que

outros. A escolha dos fatores através da disponibilidade dos dados é orientada por meio da finalidade e horizonte de previsão desejada.

Os horizontes de previsão podem ser anuais, mensais, semanais, diários e horários. Conforme Silva (2003), pode-se classificar a previsão como de longo prazo ou de curto prazo. A previsão de longo prazo está associada à definição de parâmetros para planejamento ou projetos. A previsão de curto prazo está associada aos estudos de efeitos de medidas de racionamento ou operação.

3.5 ESTUDOS SOBRE PREVISÃO DE DEMANDA

Segundo Silva e Rocha (1999), a previsão de demanda é um instrumento que deve ser utilizado no dimensionamento da oferta de água e para o direcionamento de medidas relacionadas à gestão dos sistemas de abastecimento de água.

Os primeiros estudos de previsão de demanda foram aplicados no sistema de eletricidade, onde os impactos das condições meteorológicas foram correlacionados com o consumo de energia elétrica (Dryar, 1944; Williams e Leslie, 1953; Davies, 1959; Quayle e Diaz, 1980 apud Bolzern et al., 1982).

Conforme Amaral e Shirota (2003), os primeiros trabalhos de previsão de demanda de abastecimento de água avaliaram a hipótese da inelasticidade do preço da demanda de água residencial, entre os quais figuram trabalhos publicados até a década de 1970.

A partir de então estudos de previsão de consumo de água começaram a ser aplicados em diversos sistemas de abastecimento de água.

An et al. (1996) propuseram um método de inteligência artificial para a geração de regras de previsão por meio de um conjunto de 18 fatores condicionais, tais como: dia da semana, temperatura máxima, temperatura mínima, umidade média, precipitação pluviométrica, ocorrência de neve, velocidade do vento e tempo de exposição do sol; baseados em dados do dia atual e de 2 dias anteriores.

Lertpalangsunti et al. (1999) apresentaram um conjunto de modelos aplicados à predição de consumo de água usando algoritmos computacionais de inteligência artificial como: técnicas de lógica fuzzy, redes neurais artificiais, “knowledge-based” e “case-based reasoning”. O sistema de abastecimento de água de Regina, no Canadá, foi utilizado como estudo de caso. Os autores compararam as técnicas propostas aos processos de regressão linear e demonstraram que os métodos sugeridos apresentaram melhor desempenho.

Silva e Rocha (1999) publicaram através do programa do Governo Federal do Brasil - PNCDa – Programa Nacional de Combate ao Desperdício de Água, um documento técnico de apoio específico para caracterização da demanda urbana de água para abastecimento público. Apresentaram elementos teóricos, princípios fundamentais e um roteiro básico para estimativa da demanda. Classificaram os métodos de estimativa de demanda em 6 grupos: 1) Contabilização per capita; 2) Contabilização por ligação; 3) Coeficientes de uso unitário; 4) Modelos de múltiplas variáveis explicativas; 5) Modelos econométricos e 6) Modelos de contingência (Jones et al. 1986 apud Silva e Rocha, 1999).

Zhou et al. (2000) formularam um conjunto de equações que representam o efeito de quatro fatores relacionados ao consumo de água: tendência (fração polinomial de tempo), sazonalidade climática (verão e inverno), correlação e autocorrelação climática. Foram desenvolvidos sete modelos de previsão, aplicados na cidade de Melbourne, Austrália. O modelo escolhido (separado por verão e inverno, com chuvas no verão) obteve resultados com $R^2=0,89$ e desvio padrão $\pm 8\%$, o que foi considerado satisfatório pelos pesquisadores.

Protopapas et al. (2000) pesquisaram a relação entre o consumo de água da cidade de Nova Iorque, EUA, e as condições climáticas (pluviosidade e a ocorrência de precipitação), durante os anos de 1982 a 1991. Verificaram-se que, durante os meses de inverno, a pluviosidade tem pouco efeito no consumo de água, enquanto nos períodos de verão, a chuva causa diminuição no uso de água diário e que acima de 78°F (25,56°C), a demanda de água aumenta linearmente com a temperatura média diária.

Mukhopadhyay et al. (2001) coletaram dados de 48 famílias do Kuwait pelo período de um ano. Os autores aplicaram técnicas de regressão linear e modelos de redes neurais para ajuste dos dados observados. Os resultados

sugerem a existência de dependência entre o consumo de água e a quantidade de banheiros e cômodos das residências, o tamanho de jardins anexos, o nível de renda familiar, a temperatura atmosférica, a umidade relativa do ar e o número de pessoas em cada residência.

Zhou et al. (2002) voltaram a realizar um novo trabalho na zona urbana de Melbourne, Austrália, com um modelo de previsão de séries temporais do consumo de água horário com 24 horas de antecedência. O modelo compreende módulos diários e horários. O módulo diário foi formulado usando fatores de sazonalidade, correlações e autocorrelação com fatores climáticos. Utilizaram um período de 6 anos, validando o método para um período independente de 7 meses.

Amaral e Shirota (2003) analisaram os efeitos de variáveis socioeconômicas e climáticas na quantidade de água consumida na cidade de Piracicaba, Estado de São Paulo. A estimativa de demanda foi explicada por modelos de séries temporais e de decomposição (método X-11). Os autores concluíram que o consumo apresenta forte componente sazonal, no caso diretamente proporcional à temperatura.

Dube e Zaag (2003) utilizaram-se da técnica de regressão linear múltipla para previsões anuais, analisaram padrões de setores de consumo de famílias ricas e pobres. Empregaram como dados de entrada a população do ano, o crescimento populacional, a precipitação pluviométrica e a possível ocorrência de demandas reprimidas por racionamento. A cidade de Masvingo, no Zimbábue foi empregada neste estudo de caso. Completaram o estudo afirmando que há possibilidade de instituir a gestão de demanda na cidade de Masvingo, sem ter que recorrer a investimentos muito caros ou incorrer em enormes despesas.

Borges (2003) propôs melhoria metodológica na operação do sistema adutor metropolitano de São Paulo, por meio da incorporação de um modelo matemático, usando dados em tempo real, para previsão de consumo de água horário. Foi utilizado um modelo baseado na série de Fourier conectado a um modelo simulador para a resolução de regras operacionais. Os resultados obtidos confirmam a obtenção de ganhos operacionais pela maior confiabilidade no processamento de dados e rapidez nas tomadas de decisão.

Silva (2003) estudou a utilização de redes neurais artificiais e modelos baseados em séries temporais (médias móveis e auto-regressão) para a previsão de demanda. A área de estudo localizou-se na região metropolitana de São Paulo, denominada Alça Leste. O autor afirma que a previsão multivariada é possível de ser realizada, apresentando resultados bastante satisfatórios. Na primeira etapa do trabalho, foi verificada a correlação entre consumo e temperatura, porém foi constatado que outras variáveis independentes, tais como dia da semana, eventos, época do ano, frentes quentes, frentes frias entre outros, afetam a variável dependente. O trabalho traz como recomendação que sejam estudadas outras variáveis que influenciam o consumo.

Sachet (2004) aplicou a metodologia de regressão linear múltipla para predição mensal do volume de água a ser produzido no sistema de abastecimento de água de Paranavaí, Estado do Paraná. Utilizou o método Stepwise, o qual avalia a combinação de todas as regressões possíveis, neste caso específico, foram utilizadas as seguintes variáveis independentes para a categoria residencial: número de economias, temperatura, densidade pluviométrica e preço de venda da água. O tratamento estatístico determinou que o melhor modelo utilizou-se do número de economias e da temperatura para o prognóstico da demanda de água de Paranavaí. Entretanto, considerou que se outras variáveis significativas fossem acrescentadas, tais como rendimento do parque de hidrômetros ou renda familiar, o modelo poderia passar por mudanças significativas.

Trautwein Jr. (2004) analisou dois modelos para previsão de consumo de curtíssimo prazo, o modelo de ajuste exponencial e o modelo de redes neurais RBF (Radial Basis Function ou Função de Base Radial) e MLP (Multilayer Perceptron ou Perceptron Multicamadas), para horizonte de quinze minutos, utilizando dados de consumo da cidade de Pinhais, região metropolitana de Curitiba, Estado do Paraná, como estudo de caso. O autor constatou a eficiência da previsão de consumo dos dois métodos utilizados. Foi verificado que a previsão multivariada é possível de ser realizada, apresentando resultados bastante satisfatórios.

Pereira Filho et al. (2004) analisaram, entre os anos de 1999 e 2002, as séries temporais de consumo de água e a relação com as variáveis meteorológicas (temperatura, umidade específica, pressão e precipitação) da região metropolitana de São Paulo. Avaliaram a evolução temporal horária, diária e mensal

das variáveis analisadas. Seus resultados indicaram correlações com as variáveis meteorológicas, mais especificamente temperatura e umidade relativa.

Falkenberg (2005) analisou a utilização de redes neurais artificiais, regressão linear múltipla e modelos ARIMA para a previsão do consumo de água da cidade de Ponta Grossa, Paraná. Foram utilizadas as variáveis: dia da semana, a hora e os consumos anteriores. O autor concluiu que cada caso específico apresentou um modelo mais adequado dentre os modelos utilizados.

Barbassa e Silva (2005) pesquisaram o sistema de abastecimento de água da cidade de Pirassununga, Estado de São Paulo, para aplicação como estudo de caso para a modelagem da demanda de água do referido sistema. O método linear de coeficientes múltiplos de demanda de água foi empregado no estudo, cujas variáveis explanatórias utilizadas foram o número de habitantes por ligação, a temperatura média mensal, a precipitação mensal, a umidade, o preço marginal e a renda per capita.

Gato et al. (2007) utilizaram dados de temperatura e precipitação pluviométrica do sistema de East Doncaster, subúrbio de Melbourne, Austrália. Os dados de produção de água foram correlacionados com o dia da semana e fatores climáticos, como: temperatura e precipitação. Os resultados revelaram independência dos fatores climáticos, mas são afetados por dias de finais de semana e dias úteis. Os dados de temperatura e de precipitação pluviométrica foram incorporados ao modelo e apresentaram coeficiente de determinação R^2 de 0,71. Com dados de 2000 a 2001 foi obtido um coeficiente de determinação R^2 de 0,83.

Ghizellaoui e Djebbar (2007) apresentaram um trabalho de previsão de consumo de longo prazo para o ano de 2020 a partir de dados básicos de demografia, dados de consumos domésticos, industriais e comerciais, para a cidade de Constantine, Argélia. O estudo revelou um déficit de 3910 L/s de produção perante a demanda estimada.

Ruijs et al. (2008) procuraram descrever os efeitos da política tarifária sobre a demanda de água da Região Metropolitana de São Paulo. Concluíram que devido à evolução com relação às políticas de preços da água e os problemas crescentes de escassez de água em áreas urbanas no Brasil, bem como em muitas outras partes do mundo, os resultados indicam os efeitos distributivos das

políticas de tarifação na demanda de água. Segundo os autores, os habitantes de menor poder aquisitivo gastam de 4,2% a 4,7% de seus rendimentos com a água consumida. Já os mais favorecidos economicamente gastam apenas 0,4% para 0,5% do seu rendimento, considerando que consomem mais que o dobro comparado aos primeiros.

Silva (2008) objetivou a determinação da magnitude de interviência das variáveis climáticas sobre a quota per capita de água. Utilizou como estudo de caso a coleta de dados junto a instituições públicas e privadas sediadas no município de Cuiabá, Estado do Mato Grosso. Os resultados obtidos indicaram a inexistência de associação entre as variáveis climáticas e o consumo per capita de água. Os modelos não foram adequados para representar a demanda da população de baixa renda e no caso das demais classes socioeconômicas, a capacidade de previsão foi baixa.

Depexe et al. (2009) propuseram um controle gráfico com limites flutuantes para aplicação no controle e programação da produção horária de uma estação de tratamento de água. O método proposto foi aplicado na estação de tratamento de água da cidade de Maringá, Estado do Paraná, responsável pelo abastecimento de uma população aproximada de 330 mil habitantes. O trabalho possibilitou reduzir o volume produzido, que estava acima da demanda, resultando em diminuição do volume de perdas de água, do consumo de energia elétrica e de produtos químicos utilizados no tratamento da água.

Firat et al. (2009) empregaram dois tipos de inferência fuzzy para prever o consumo de água mensal do sistema de abastecimento da região metropolitana de Izmir, terceira maior cidade da Turquia em termos populacionais e industriais. Utilizaram-se dos modelos ANFIS (Adaptive neuro-fuzzy inference system) e MFIS (Mamdani type fuzzy inference system). Os resultados demonstraram que o modelo ANFIS é superior ao modelo MFIS e pode ser aplicado com sucesso para a previsão de consumo de água mensal.

Silva et al. (2009) obtiveram através da técnica de Regressões Múltiplas, equações que permitem antever volumes micromedidos (hidrometrados). Selecionaram através de técnicas estatísticas objetivas a melhor equação para fins de previsão. Aplicaram o método em uma determinada cidade do Centro-Oeste brasileiro. O melhor modelo de previsão do volume micromedido foi explicado pelas

variáveis de número de economias faturadas, volume disponibilizado, número de cortes de água e a temperatura média.

Vasílio e Jorge (2009) produziram um modelo de previsão de demanda horária, utilizando o sistema de Apucarana, Estado do Paraná, como estudo de caso. Os autores estabeleceram curvas de demandas horárias, a partir de dados históricos de vazão, utilizando médias baseadas em padrões cíclicos diários e sazonais de consumo. Os padrões de sazonalidade foram divididos em 4 faixas de temperatura classificadas pelos autores. Ainda, definiram curvas médias, máximas e mínimas para cada dia da semana, os quais se correlacionam com as temperaturas médias ocorridas historicamente.

Herrera et al. (2010) apresentaram um trabalho de previsão de demanda horária, empregando o sistema de abastecimento de uma cidade do sudeste da Espanha, que possui uma população de 5.000 consumidores distribuída em uma área de 8 km², cuja demanda média é de 19 m³/h e o desvio-padrão de aproximadamente 8 m³/h. Além dos valores do consumo de água, coletaram informações sobre os valores diários das variáveis climáticas temperatura, velocidade do vento, pluviosidade e pressão atmosférica. Os resultados revelaram que os melhores modelos foram estimados pelo método SVR – Support vector regression, seguido pelo método MARS - Multivariate adaptive regression splines, PPR - Projection pursuit regression e Random Forests. Os modelos de redes neurais artificiais ANN – Artificial Neural Network utilizados no trabalho, segundo eles, apresentaram um desempenho abaixo do esperado.

Odan (2010) pesquisou a demanda de sistemas de abastecimento de água visando à operação em tempo real. O autor utilizou as cidades de Araraquara e São Carlos como estudo de caso para previsões de 1 e 24 horas por meio de Redes Neurais Perceptron de Múltiplas Camadas com algoritmo de treinamento Backpropagation (RNA MLP-BP), Rede Neural Dinâmica (DAN2) e associação híbrida de Série de Fourier com RNA MLP e DAN2, denominados respectivamente, por RNA-H e DAN2-H. Concluiu que os melhores modelos de previsão não utilizavam variáveis meteorológicas e observou que as Redes Neurais Dinâmicas (DAN2) sobressaíram-se sobre as Redes Neurais Perceptron de Múltiplas Camadas com algoritmo de treinamento Backpropagation (MLP-BP).

A revisão bibliográfica dos métodos de previsão expõe diversos modelos utilizados historicamente, desde os menos complexos até os mais intrincados, auxiliando a compreensão dos agentes envolvidos na demanda de abastecimento de água. Todos os modelos possuem proficiências e a sua aplicação depende da disponibilidade de dados confiáveis e do nível de detalhamento requerido. Esses modelos têm como objetivo automatizar os resultados, porém não suprem a competência de um analista de assumir deliberações, pois procedimentos automáticos não substituem o conhecimento de um especialista sobre os dados estudados.

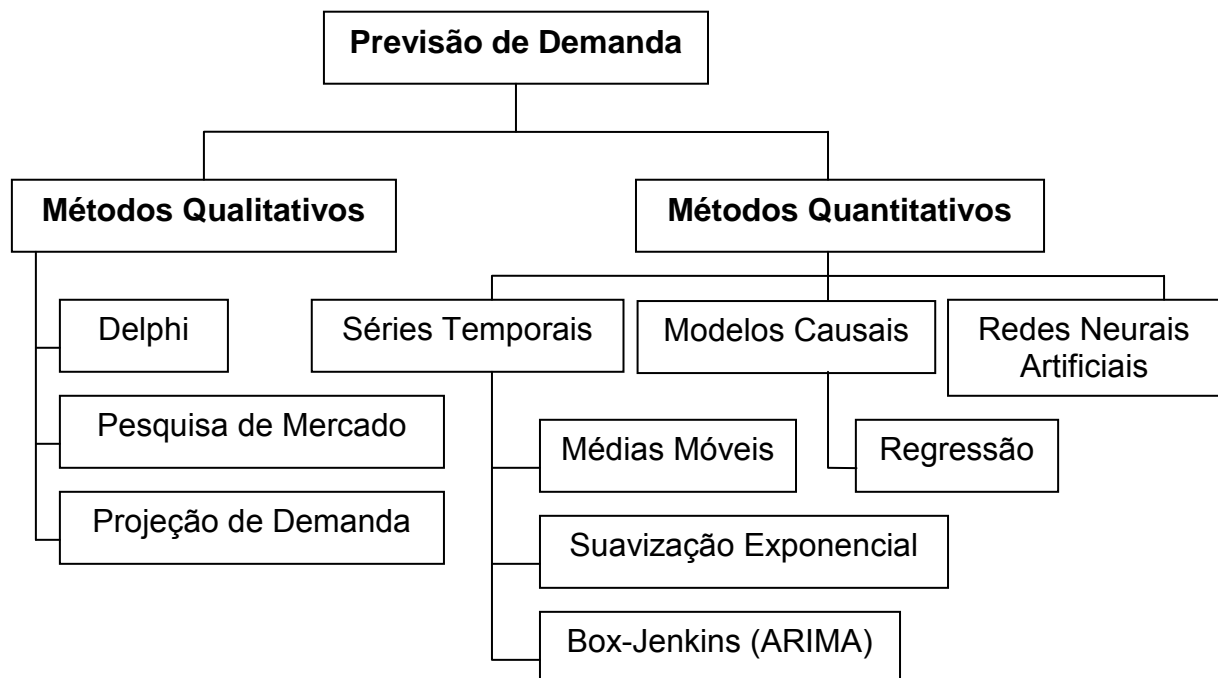
Entretanto, sem a orientação determinada pelos modelos de previsão de demanda de abastecimento de água, as decisões dos analistas das companhias de saneamento tornam-se mais arriscadas. Estas decisões refletem a habilidade de planejamento da produção e da distribuição, o exame crítico da capacidade de economia de energia elétrica e a detecção de perdas no sistema distribuidor, os quais são essenciais ao equilíbrio e à sustentabilidade ambiental urbana.

4. MÉTODOS E MODELOS DE PREVISÃO DE DEMANDA

Segundo Silva (2003), existem dois métodos de estimativa futura, os métodos quantitativos e os métodos qualitativos. Os métodos qualitativos são fundamentados em julgamento, intuição, entrevista, e usados para criar cenários futuros. Os métodos quantitativos baseiam-se em modelos matemáticos.

A Figura 4-1 apresenta resumidamente os métodos e modelos.


Figura 4-1 - Métodos e Modelos de Previsão de Demanda



Fonte: adaptado de Silva (2003)

O emprego de cada modelo depende do comportamento da série temporal em análise, que pode exibir até quatro características diferentes em seu comportamento: média, sazonalidade, ciclo e tendência, conforme Figura 4.2 (Makridakis et al., 1998).

Figura 4-2 - Características de séries temporais



fonte: Makridakis et al. (1998)

4.1 MODELOS DE SÉRIES TEMPORAIS

Os modelos de séries temporais partem do princípio de que os acontecimentos passados contêm informações sobre o padrão de eventos futuros. Sua vantagem em relação aos modelos causais, é que nos modelos de séries temporais, as extrapolações não acumulam os erros das variáveis explicativas.

Segundo Morettin e Toloí (2006), os objetivos de análise de séries temporais são:

- a) **Investigação:** procurar saber o mecanismo gerador da série temporal;
- b) **Previsão:** prever valores futuros com base em valores passados da série no período observado.
- c) **Descrição e controle:** por exemplo, construção de gráficos e controle estatístico de qualidade.
- d) **Explicação:** a construção de modelos que permitam explicar a periodicidade dos dados.

4.1.1 Modelo de médias móveis

Os modelos de médias móveis apresentam grande simplicidade e consistem em calcular a média de períodos passados, chamados de período de recorrência (Pr), que se torna a previsão para o período seguinte. A visualização de tendência é facilitada através da suavização das curvas obtidas usando a Equação 4.1.

$$x_t = \frac{x_{t-1} + x_{t-2} + \dots + x_{t-n}}{n} \quad (\text{Eq. 4.1})$$

Em que:

x_t = média móvel;

n = número de observações.

Quanto maior o Pr considerado, maior o efeito de alisamento ou suavização na previsão. Segundo Faria et al. (2008), caso a série apresente muita aleatoriedade ou pequenas mudanças em seus padrões, o Pr deverá ser maior. Já para o caso de séries que apresentam pouca flutuação aleatória, poucas mudanças significativas, o número Pr poderá ser menor, tal que a série prevista reaja de maneira mais rápida.

Outro modelo de média móvel é a média móvel ponderada representada pela Equação 4.2.

$$xp_t = a_1 xp_{t-1} + a_2 xp_{t-2} + \dots + a_n xp_{t-n} \quad (\text{Eq. 4.2})$$

Em que:

xp_t = média móvel ponderada;

n = número de observações;

$a_1 + a_2 + \dots + a_n = 1$.

A média móvel ponderada apresenta a vantagem de valorizar os dados mais recentes. Entretanto, uma desvantagem das médias móveis é o atraso da previsão da demanda, assim, quanto maior o n , maior será o atraso. Sua aplicação em previsões de curto prazo é bastante limitada, no entanto, seu uso em previsões de longo prazo torna-se mais adequado.

4.1.2 Modelos de suavização exponencial

Os modelos de suavização exponencial trabalham com componentes de nível, de tendência e de sazonalidade da série temporal (Billings e Jones, 2008).

Segundo Pellegrini (2000), os modelos de suavização exponencial são largamente empregados para previsão de demanda devido a sua simplicidade, facilidade de ajustes e a boa precisão. A distinção do padrão de comportamento da série temporal de qualquer ruído é o princípio dos modelos de suavização, em que os valores extremos da série representam a aleatoriedade e pela sua suavização, identifica-se o padrão básico do desempenho da série.

Billings e Jones (2008) relatam que os modelos de suavização exponencial foram desenvolvidos no final dos anos 1950, para serem utilizados em previsão de vendas e controle de estoque.

Suavização exponencial simples

A suavização exponencial simples é descrita matematicamente pela Equação 4.3:

$$F_{t+1} = \alpha \cdot x_t + (1 - \alpha) \cdot F_t \quad (\text{Eq. 4.3})$$

Em que:

F_{t+1} = previsão no tempo t+1;

α = peso atribuído ($0 < \alpha < 1$) ou constante de suavização;

x_t = último valor observado;

F_t = valor da previsão anterior.

Quanto menor o valor de α , mais estáveis são as previsões finais, pois pesos maiores serão dados às observações passadas. Em geral, quanto mais aleatória for a série, menores serão os valores da constante de suavização. Uma das vantagens desse modelo é a facilidade de seu entendimento.

Porém, um fato desvantajoso do modelo é a dificuldade na determinação de α que minimize a soma dos quadrados. A determinação de α pode ser feita por tentativa e erro ou usando métodos como o procedimento de Marquardt.

Modelo de Holt ou suavização exponencial dupla

Em dados com tendência linear, o modelo Holt pode ser utilizado de maneira satisfatória. De acordo com Makridakis et al. (1998), o modelo utiliza duas constantes de suavização α e β , cujos valores devem variar de 0 a 1. Este modelo é concebido pelas Equações 4.4, 4.5 e 4.6:

$$L_t = \alpha.z_t + (1 - \alpha).(L_{t-1} + T_{t-1}) \quad (\text{Eq. 4.4})$$

$$T_t = \beta.(L_t - L_{t-1}) + (1 - \beta).T_{t-1} \quad (\text{Eq. 4.5})$$

$$\hat{z}_{t+k} = L_t + k.T_t \quad (\text{Eq. 4.6})$$

Em que:

L_t = nível no tempo t;

T_t = tendência no tempo t;

α = constante de suavização do nível;

β = constante de suavização da tendência;

k = número de períodos à frente a ser previsto;

z_t = valor do dado no tempo t;

\hat{z}_{t+k} = Previsão no tempo t, k passos à frente (valor estimado).

Modelo de Holt-Winters aditivo

Quando a magnitude do padrão sazonal não muda com o aumento ou diminuição da série, pode ser utilizado o modelo de Holt-Winters aditivo. As três equações fundamentais com constantes de suavização indicativos de cada componente do padrão da série temporal, ou seja, nível, tendência e sazonalidade são apresentadas, respectivamente, pelas Equações 4.7, 4.8 e 4.9, que são utilizadas na Equação da previsão (Eq. 4.10):

Para o nível:

$$L_t = \alpha.(Y_t - S_{t-s}) + (1-\alpha).(L_{t-1} + b_{t-1}) \quad (\text{Eq. 4.7})$$

Para a tendência:

$$b_t = \beta.(L_t - L_{t-1}) + (1-\beta).b_{t-1} \quad (\text{Eq. 4.8})$$

Para a sazonalidade:

$$S_t = \gamma.(Y_t - L_t) + (1-\gamma).S_{t-s} \quad (\text{Eq. 4.9})$$

Para a previsão:

$$F_{t+m} = (L_t + b_{t-m}).S_{t-s+m} \quad (\text{Eq. 4.10})$$

Em que:

S = Extensão da Sazonalidade;

α = constante de suavização do nível;

β = constante de suavização da tendência;

γ = constante de suavização da sazonalidade;

b_t = Tendência no tempo t;

L_t = Nível da Série no tempo t;

S_t = Componente Sazonal;

F_{t+m} = Previsão para o período m;

Y_t = Valor Observado;

Modelo de Holt-Winters multiplicativo

O Modelo de Holt-Winters Multiplicativo é empregado quando a amplitude da variação sazonal se amplia com o tempo, ou seja, quando o nível e as componentes sazonais são conjuntamente multiplicadas. Assim como no modelo aditivo, três equações básicas com constantes de suavização diferentes são associadas a cada componente do padrão da série temporal, ou seja, constante de suavização de nível (Eq. 4.11), de tendência (Eq. 4.12) e de sazonalidade (Eq. 4.13), que são utilizadas na equação de previsão (Eq. 4.14).

Para o nível:

$$L_t = \alpha \cdot \frac{Y_t}{S_{t-s}} + (1 - \alpha) \cdot (L_{t-1} + b_{t-1}) \quad (\text{Eq. 4.11})$$

Para a tendência:

$$b_t = \beta \cdot (L_t - L_{t-1}) + (1 - \beta) \cdot b_{t-1} \quad (\text{Eq. 4.12})$$

Para a sazonalidade:

$$S_t = \gamma \cdot \left(\frac{Y_t}{L_t} \right) + (1 - \gamma) \cdot S_{t-s} \quad (\text{Eq. 4.13})$$

Para a previsão:

$$F_{t+m} = (L_t + b_{t-m}) \cdot S_{t-s+m} \quad (\text{Eq. 4.14})$$

Em que:

- S = Comprimento da Sazonalidade;
- α = constante de suavização do nível;
- β = constante de suavização da tendência;
- γ = constante de suavização da sazonalidade;
- b_t = Tendência no tempo t;
- L_t = Nível da Série no tempo t;
- S_t = Componente Sazonal;
- F_{t+m} = Previsão para o período m;
- Y_t = Valor Observado;

4.1.3 Modelos de Box e Jenkins ou ARIMA

Segundo Billings e Jones (2008), durante as décadas de 1960 e 1970, os estatísticos Edward George Pelham Box e Gwilym Meirion Jenkins desenvolveram uma abordagem que combina os modelos de séries temporais autorregressivos e de médias móveis.

A maior contribuição de Box & Jenkins foi o desenvolvimento de uma metodologia sistemática para identificar e estimar modelos que pudessem usar ambas as abordagens, modelos autorregressivos e médias móveis.

Os modelos de Box e Jenkins baseiam-se no ajuste de modelos denominados ARIMA (Autorregressivos Integrados e de Médias Móveis), de forma que a diferença entre os valores gerados pelos modelos e os valores observados resulte em resíduos de comportamento em torno de zero.

Moccellin (2003) define os modelos de Box e Jenkins como apropriados para séries temporais em que $\{X_t, t=1, 2, \dots\}$ não podem ser consideradas variáveis aleatórias independentes, ou seja, partem do princípio de que os valores de uma série temporal são altamente dependentes uns dos outros e que cada valor futuro pode ser explicado por valores prévios da série.

Segundo Pellegrini (2000), os modelos ARIMA representam a classe mais geral de modelos para a análise de séries temporais, os quais descrevem tanto o comportamento estacionário como o não estacionário.

Os modelos de Box e Jenkins são divididos em:

- Modelo autorregressivo de ordem p ou AR (p);
- Modelo de média móvel de ordem q ou MA (q);
- Modelo autorregressivo de média móvel ou ARMA (p,q);
- Modelo Autorregressivo integrado de média móvel ou ARIMA (p,d,q).

Modelos autorregressivos AR(p)

Os modelos autorregressivos AR(p) também podem ser expressos como ARIMA(p,0,0). O valor presente X_t (Eq. 4.15 e 4.16) é uma função linear dos valores passados X_{t-n} e de uma função aleatória a_t , a qual é uma variável aleatória independente descrita por uma função densidade de probabilidade normal. A ordem da auto-regressão depende do valor mais antigo “p”, os coeficientes de regressão ϕ_n , são constantes e reais. Para encontrar estes valores pode ser usada a técnica dos mínimos quadrados.

$$X_t = \delta + \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + a_t \quad (\text{Eq. 4.15})$$

$$\delta + a_t = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) X_t \quad (\text{Eq. 4.16})$$

Modelos de médias móveis MA(q)

São modelos de média móvel MA(q) ou ARIMA (0,0,q), cujo valor presente X_t (Eq. 4.17 e 4.18) é uma função linear dos valores passados erros a_{t-n} . A ordem da autorregressão depende do valor mais antigo do erro q. θ_m são os coeficientes de regressão, constantes e reais.

$$X_t = m + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (\text{Eq. 4.17})$$

$$X_t = m + (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) a_t \quad (\text{Eq. 4.18})$$

Modelos autorregressivos e de médias móveis ARMA(p,q)

São modelos mistos ARMA(p,q) ou ARIMA(p,0,q), cujo valor presente X_t (Eq. 4.19 e 4.20) é uma função linear dos valores passados da série X_{t-n} e dos valores do ruído dos erros passados a_{t-n} . A ordem da autorregressão depende do valor mais antigo dos elementos da série p e do erro q. ϕ_n e θ_m são os coeficientes de regressão, constantes e reais.

$$X_t = \delta + \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (\text{Eq. 4.19})$$

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) X_t = \delta + (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) a_t \quad (\text{Eq. 4.20})$$

Modelos autorregressivos integrados de médias móveis ARIMA(p,d,q)

Nos modelos mistos ARIMA ou ARIMA(p,d,q), mostrados na Equação 4.21, a série não é estacionária, por isso recorre-se à diferenciação de ordem d. A ordem da auto-regressão depende do valor mais antigo dos elementos da série p e do erro q e da ordem de diferenciação d.

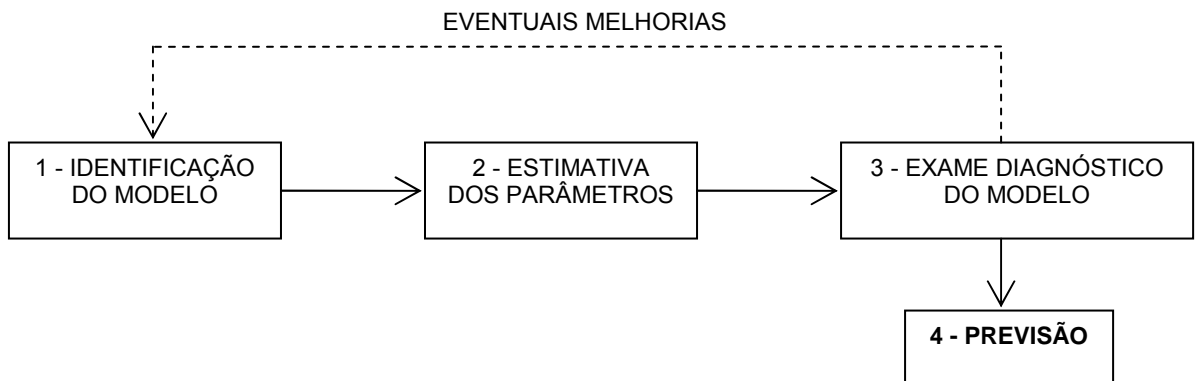
$$\underbrace{(1-B)^d}_{I(d)} \underbrace{(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)}_{\text{autoregressiva AR}(p)} \underbrace{(1 - \Theta_1 B^s)}_{\text{sazonalAR}} X_t = \delta + \underbrace{(1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)}_{\text{médiamóveMA}(q)} \underbrace{(1 - \Theta_1 B^{s0})}_{\text{sazonaMA}} a_t$$

(Eq. 4.21)

Procedimentos de previsão utilizando os modelos de Box e Jenkins

O procedimento para uso dos modelos de Box e Jenkins foi apresentado na forma de diagrama (Figura 4-3) por Moccellini (2003).

Figura 4-3 – Procedimento de previsão dos modelos de Box e Jenkins



Fonte: Moccellini (2003)

Segundo Moccellini (2003), a previsão utilizando modelos de Box e Jenkins é precedido de 3 etapas: 1 – identificação do modelo, 2 – estimativa dos parâmetros e 3 – exame diagnóstico do modelo.

A identificação do modelo é realizada por meio da análise estatística dos dados históricos, utilizando a Função de Autocorrelação (FAC) e a Função de Autocorrelação Parcial (FACP), porém, para obtenção de resultados satisfatórios são necessárias, ao menos 50 observações da variável X.

A Função de Autocorrelação (ρ_k) é dada pela Equação 4.22.

$$\hat{\rho}_k = \frac{\sum_{t=k+1}^T (y_t - \bar{y})(y_{t-k} - \bar{y})}{\sum_{t=1}^T (y_t - \bar{y})^2} \quad (\text{Eq. 4.22})$$

Em que \bar{y} é a média do processo e k é o número de defasagem das autocorrelações.

Genericamente, a Função de Autocorrelação Parcial (Φ_{kk}) é dada pela Equação 4.23.

$$\phi_{kk} = \left(\rho_k - \sum_{j=1}^{k-1} \phi_{k-1,j} \rho_{k-j} \right) \cdot \left(1 - \sum_{j=1}^{k-1} \phi_{k-1,j} \rho_k \right)^{-1} \quad (\text{Eq. 4.23})$$

Para facilitar a identificação do modelo, na Tabela 4-1 é apresentado um resumo do comportamento das FAC e FACP de um processo ARIMA (p,d,q)

Tabela 4-1 - Comportamento das FAC e FACP de um processo ARIMA (p,d,q).

Ordem	(1,d,0)	(0,d,1)
comportamento de FAC	decai exponencialmente	somente $\rho_1 \neq 0$
comportamento de FACP	somente $\Phi_{11} \neq 0$	decaimento exponencial dominante
Ordem	(2,d,0)	(0,d,2)
comportamento de FAC	mistura exponenciais ou ondas senóides amortecidas	somente $\rho_1 \neq 0$ e $\rho_2 \neq 0$
comportamento de FACP	somente $\Phi_{11} \neq 0$ e $\Phi_{22} \neq 0$	dominada por mistura de exponenciais e senóides amortecidas
Ordem	(1,d,1)	
comportamento de FAC	decai exponencialmente após o lag 1	
comportamento de FACP	dominada exponencialmente após o lag 1	

Fonte: adaptado de Morettin e Toloí (2006)

Para a estimativa dos parâmetros do modelo, o procedimento usual consiste na utilização do Método dos Mínimos Quadrados. Segundo Morettin e Toloí (2006), atualmente, os programas computacionais incorporam estes valores iniciais, não havendo necessidade de estimativas preliminares.

O diagnóstico dos modelos ARIMA é efetuado através da análise estatística de desvios $e_t = x_t - \hat{x}_t$ sobre os dados históricos. E também possível verificar se o modelo representa adequadamente ou não os dados.

4.2 MODELOS CAUSAIS OU DE DECOMPOSIÇÃO

Os modelos causais procuram conhecer os fatores que originam os fenômenos, possibilitando identificar suas causas e entender o relacionamento entre duas ou mais variáveis pertencentes ao processo em estudo. Partem do princípio de

que as leis de dependência entre as variáveis independentes (explicativas) e a variável dependente (demanda) permanecem no futuro.

Um dos modelos causais mais conhecidos é o da Regressão Linear Múltipla, cuja previsão de demanda consiste em realizar a previsão através de métodos de decomposição estatística das variáveis pesquisadas. São modelos que apresentam resultados aceitáveis quando as variáveis independentes são previstas de maneira satisfatória.

Entretanto, se a previsão de uma ou mais variáveis independentes é estimada com erros, ou seja, de forma a não refletir a realidade prevista, o cálculo da variável dependente torna-se prejudicada.

Regressão linear múltipla

De acordo com Montgomery e Runger (2003), a análise de regressão é uma técnica estatística para modelar e investigar a relação entre duas ou mais variáveis. Quando a equação de regressão é formada por funções lineares e contém mais de um regressor, o modelo é chamado de regressão linear múltipla.

A estimativa dos coeficientes de regressão é realizada pelo Método dos Mínimos Quadrados, que é uma técnica de otimização matemática que procura encontrar o melhor ajuste para um conjunto de dados tentando minimizar a soma dos quadrados das diferenças entre os valores estimados e os dados observados.

O modelo de regressão linear múltipla com k regressores é dado pela Equação 4.24.

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \varepsilon \quad (\text{Eq. 4.24})$$

Em que:

- Y = variável dependente (demanda);
- x_1, x_2, \dots, x_k = variáveis preditoras conhecidas;
- $\beta_0, \beta_1, \dots, \beta_k$ = parâmetros do modelo;
- ε = termo de erro do modelo;

A verdadeira relação funcional entre Y e x_1, x_2, \dots, x_k são desconhecidas e os modelos de regressão linear múltipla são utilizados como aproximação de funções.

Quanto mais o termo de erro do modelo " ε " tender a um valor próximo de zero, mais adequado torna-se o modelo de regressão linear múltipla. Para tanto, a escolha adequada das variáveis preditoras é primordial para o sucesso do modelo, ou seja, de forma a minimizar ε .

Regressão Linear Múltipla por Etapas (Stepwise)

Segundo Montgomery e Runger (2003), o método de regressão Stepwise ou regressão por etapas, é provavelmente a técnica mais utilizada para seleção das variáveis para o modelo. O algoritmo computacional estabelece iterativamente uma sequência de modelos de regressão pela adição (forward) ou pela remoção (backward) de variáveis em cada etapa.

A seleção de adição (forward) começa sem preditores no modelo. As variáveis são adicionadas a cada etapa pela variável mais significativa em cada passo. O algoritmo pára quando todas as variáveis que não estão no modelo têm valores- p maiores que o valor especificado, por exemplo, o coeficiente de entrada alfa utilizado for maior que 0,05.

Já a seleção por remoção (backwards) começa com todos os preditores no modelo e o algoritmo remove a variável menos significativa em cada passo. A finalização ocorre quando todas as variáveis no modelo têm valores- p menores que o valor especificado ($\text{alfa} < 0,05$).

4.3 MODELO HÍBRIDO DE DEMANDAS MÉDIAS COM REGRESSÃO LINEAR MÚLTIPLA

O modelo híbrido de demandas médias com regressão linear múltipla permite a consideração de sazonalidade. Tal análise seria de muito difícil obtenção apenas por regressão linear múltipla, pela não linearidade dos dados de saída com relação às variáveis preditoras.

O modelo é semelhante à regressão linear múltipla com k regressores, com a ressalva de que este modelo considera o padrão histórico médio como uma das variáveis preditoras. O padrão histórico médio tem a função de linearizar as outras variáveis preditoras em torno do comportamento sazonal da demanda.

Um exemplo é a consideração de demandas horárias, cujo padrão de desempenho é determinado, em sua maior parte, pelo comportamento do uso da água pelos usuários, clientes do sistema de abastecimento público, em horários concentrados em dois picos diários máximos de consumo, normalmente, um às 11h (almoço) e outro às 20h (banho), e um pico mínimo que ocorre em média às 5h (consumo mínimo). Em menor porção, mas de igual importância, as outras variáveis preditoras como temperatura do ar, vento, precipitação ou umidade determinam o aumento ou declínio da demanda verificada.

4.3.1 Modelo híbrido de médias móveis com regressão linear múltipla

O modelo híbrido de médias móveis com regressão linear múltipla é uma variação do modelo híbrido de demandas médias com regressão linear múltipla comentado anteriormente. A demanda média é substituída pela média móvel da demanda. A partir de testes realizados para o caso de demandas diárias, obteve-se a Equação 4.25, que considera a sazonalidade devido aos dias de semana.

$$CDD = \frac{D_n}{\frac{1}{7} \sum_{i=n-7}^n D_i} \quad (\text{Eq. 4.25})$$

Em que:

- CDD = Coeficiente de Demanda Diária e
- D = Demanda do Dia n

4.4 MODELOS DE REDES NEURAIS ARTIFICIAIS

Os modelos de Redes Neurais Artificiais constituem-se de técnicas computacionais que estudam o padrão matemático inspirado pela estrutura neural de organismos biológicos inteligentes, os quais adquirem conhecimento por meio da experiência.

Comparativamente, uma rede neural artificial pode possuir centenas ou milhares de unidades de processamento e o cérebro de um mamífero possui bilhões de neurônios. Recentemente, de acordo com Azevedo et al. (2009), descobriu-se que o sistema nervoso humano possui cerca de 86 bilhões de neurônios.

De uma forma geral, as RNAs são vistas como “black boxes” ou “caixas pretas”, pois não se sabe como a rede chega a um determinado resultado, uma vez que não proporcionam justificativas para seus resultados. Porém, através do uso de algoritmos para a introdução de regras, proposições para justificativas podem ser realizadas.

4.4.1 Redes de neurônios biológicos


O sistema nervoso biológico é composto por um conjunto extremamente complexo de células, os neurônios, conforme as Figuras 4-4 e 4-5. Os quais possuem um papel fundamental no funcionamento do corpo humano e do raciocínio. Os neurônios são constituídos por dendritos (conjunto de terminais de entrada), corpo central e axônios, que são longos terminais de saída.

As redes neurais biológicas são unidas funcionalmente pelas sinapses (Figura 4-5), onde o terminal do axônio de um neurônio comunica-se com o dendrito do neurônio vizinho. Segundo Braga et al. (2000), as sinapses funcionam como válvulas e são capazes de controlar a transmissão de impulsos nervosos.

Segundo Kovács (1996), as manifestações elétricas dos neurônios biológicos foram observadas pela primeira vez com o auxílio de galvanômetros por um médico fisiologista alemão, Emil du Bois Reymond, no século 19, que descobriu


o potencial elétrico dos neurônios e realizou diversos experimentos de eletrofisiologia.

Figura 4-4 - Estrutura dos neurônios biológicos



Fonte: <http://www.mecatronicaatual.com.br>

Figura 4-5 - Disposição física dos neurônios biológicos



Fonte: <http://www.sobiologia.com.br>

Na região entre os neurônios, as sinapses, os estímulos nervosos são transferidos através de substâncias conhecidas por neurotransmissores. Dependendo do tipo de neurotransmissor, a conexão sináptica é excitatória ou inibitória. Dentre os neurotransmissores, os mais conhecidos são: as colinas, as aminas biogênicas, os aminoácidos, os neuropeptídeos e alguns hormônios.

4.4.2 Redes de neurônios artificiais

Breve histórico das redes neurais artificiais

A construção de Redes Neurais Artificiais (RNA) tem inspiração nas redes neuronais biológicas. Porém, atualmente, as RNAs estão muito distantes das Redes Neurais Naturais (RNN) e frequentemente as semelhanças são mínimas (Azevedo et al., 2000).

De acordo com Kovács (1996), Braga et al. (2000), Azevedo et al. Oliveira (2000) e Haykin (2002), o trabalho pioneiro em RNA foi realizado por Warren McCulloch, um neuroanatomista e psiquiatra americano, e por Walter Pitts, um matemático americano, em 1943. Em passos lentos, durante cerca de 40 anos após McCulloch e Pitts terem realizado seu primeiro trabalho, diversos estudiosos contribuíram para o desenvolvimento das RNAs modernas.

Esse retardamento no avanço dos estudos, entre as décadas de 1940 e 1980, deveu-se principalmente à indisponibilidade de tecnologia apropriada para a realização dos experimentos. Já a partir da década de 1980, os estudos sobre as RNA tornaram-se relevantes pelo avanço proporcionado pela disseminação tecnológica e de computadores pessoais.

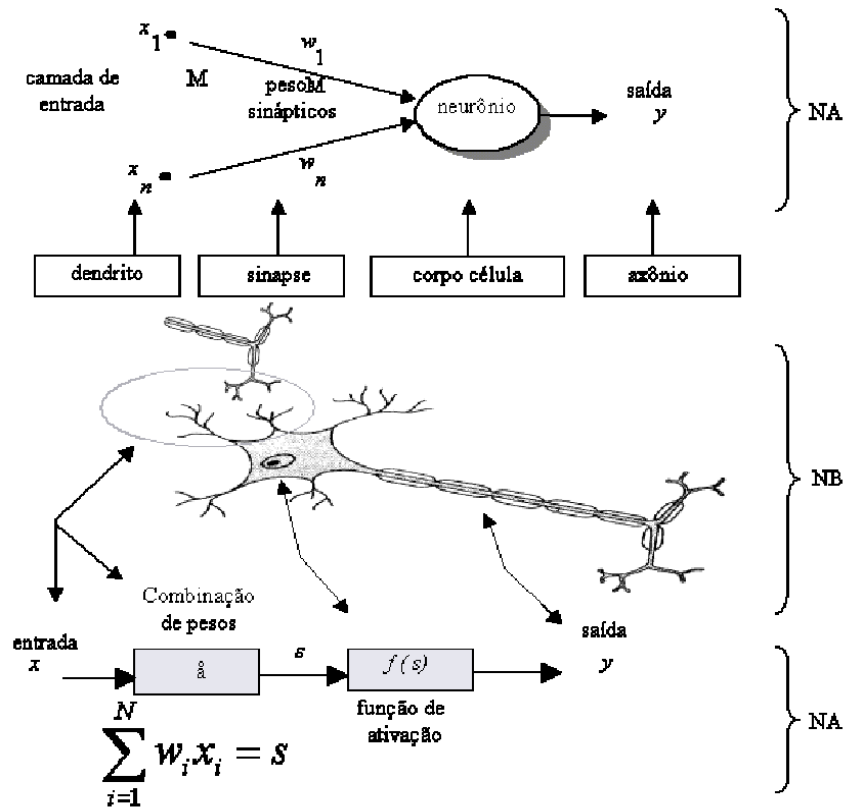
Segundo Braga et al. (2000), espera-se que a biologia e as ciências cognitivas possam se beneficiar do desenvolvimento da neurocomputação.

Neurônios artificiais e sua topologia

De acordo com Haykin (2002), as redes neurais são compostas de elementos simples que atuam em paralelo e que registram conhecimentos através de experiências, inspirados no sistema nervoso biológico.

O neurônio artificial e o neurônio biológico são comparados na Figura 4-6.

Figura 4-6 - Comparação entre o Neurônio Biológico e o Neurônio Artificial



Fonte: Trautwein (2004)

Os elementos de conexão do sistema nervoso são demonstrados na Figura 4-7. Observa-se que os receptores recebem estímulo do ambiente externo que transmitem a informação para a rede neural. Os emissores convertem impulsos gerados pela rede neural em resposta para a saída do sistema.

Figura 4-7 - Topologia das RNAs

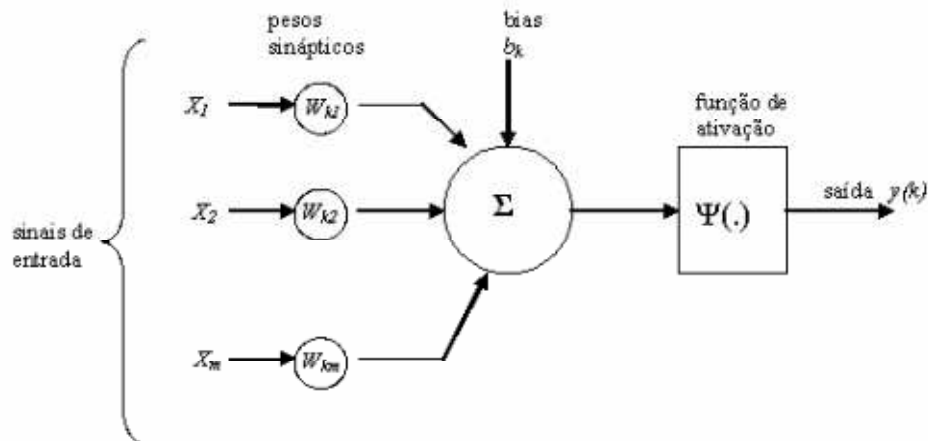


Fonte: Silva (2003)

A Figura 4-8 apresenta o modelo de um neurônio artificial, em que:

- x_i : entradas da rede;
- w_{ki} : pesos sinápticos;
- b_k : bias (viés, erro sistemático ou tendenciosidade);
- $\Psi(\cdot)$: função de ativação;
- y_k : saída da rede.

Figura 4-8 - Modelo de um neurônio artificial



Fonte: Haykin (2002)

Para Haykin (2002), os três elementos básicos do modelo de um neurônio são: os pesos sinápticos – atribuem o grau de importância dos sinais de entrada, o somador – realiza a soma dos sinais de entrada considerados pelos pesos sinápticos, e uma função de ativação – regula o sinal de saída do neurônio.

Matematicamente, a saída da rede y_k é representada pela Equação 4.26.


$$y_k = \varphi \left(\sum_{j=1}^m w_{kj} \cdot x_j + b_k \right) \quad (\text{Eq. 4.26})$$

Funções de ativação das redes neurais artificiais

Conforme Haykin (2002), a função de ativação objetiva restringir a amplitude de saída do neurônio.

Segundo Odan (2010), dentre as funções de ativação existentes, as mais empregadas são: degrau(a), rampa(b), sigmóide(c) e gaussiana(d), as quais são apresentadas na Figura 4-9:

Figura 4-9 - Principais funções de ativação:
(a) degrau; (b) linear por partes; (c) sigmoide e (d) exponencial



Fonte: Odan (2010)

Processos de aprendizagem

Braga et al. (2000) explicam que as RNAs possuem a capacidade de aprender por exemplos e fazer interpolações e extrapolações do que aprenderam. As RNAs inicialmente passam por uma fase de aprendizagem, quando a rede extrai padrões relevantes de informações, criando uma representação do problema. Os pesos das conexões das unidades de processamento, guardam o conhecimento adquirido do ambiente de operação.

Os principais processos de aprendizagem ou treinamento são: o aprendizado supervisionado e o aprendizado não supervisionado.

O aprendizado supervisionado é o método mais utilizado de treinamento de RNAs. É chamado de supervisionado porque as entradas e saídas são providas por um supervisor (professor) externo, o qual direciona o processo de treinamento. Segundo Braga et al. (2000), os exemplos de redes neurais mais

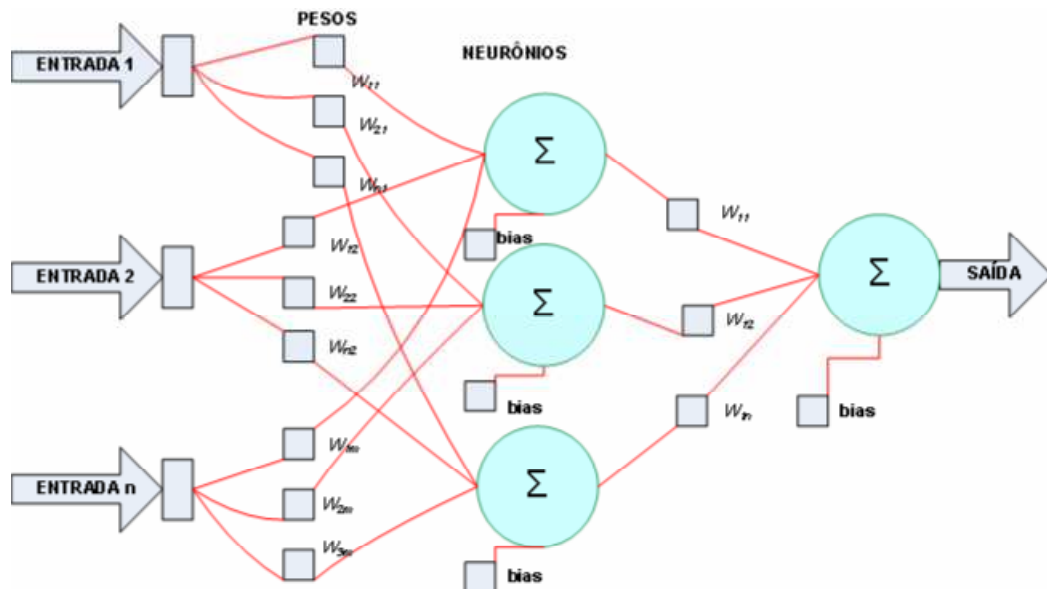
conhecidos são os perceptrons de múltiplas camadas (MLP) com algoritmo backpropagation (regra delta generalizada), que serão vistos mais adiante.

Já no aprendizado não supervisionado, não existe o supervisor externo, onde apenas os parâmetros de entrada estão disponíveis para a rede. Também é chamada de aprendizagem auto-organizada (Haykin, 2002). Este tipo de aprendizado pode ser comparado biologicamente aos estágios iniciais da visão e da audição (Braga et al. 2000).

4.4.3 Modelos de redes neurais MLP e algoritmo backpropagation

A Figura 4.10 apresenta uma RNA tipo MLP (Multi Layer Perceptron) com uma camada de entrada com n entradas, uma camada oculta com m neurônios e uma única camada de saída com um neurônio.

Figura 4-10 - Representação de RNA do tipo MLP



Fonte: Falkenberg (2005)


As RNAs de múltiplas camadas MLP resolvem problemas linearmente inseparáveis, como as séries temporais por exemplo. Segundo Silva (1998), pelo teorema da aproximação universal, um perceptron de múltiplas

camadas com uma camada intermediária é capaz de realizar uma aproximação uniforme, dado um conjunto de treinamento suficientemente significativo para representar a função.

O algoritmo Backpropagation, também conhecido como retropropagação, é o método para treinamento de redes multicamadas mais difundido e popular atualmente. Foi criado em 1969 por Bryson e Ho, mas ignorado até a década de 1980. Foi responsável pelo ressurgimento do interesse em RNAs em 1986 (Braga et al. 2000).


O Backpropagation ocorre em duas fases: fase feed-forward (propagação) e fase feed-backward (retropropagação). As Figuras 4-11 e 4-12 ilustram estas duas fases.

Figura 4-11 - Fase de propagação – backpropagation



Fonte: www.Incc.br

Figura 4-12 - Fase de retropropagação – backpropagation



Fonte: www.Incc.br

Na fase de propagação, após a apresentação do sinal de entrada, a resposta de uma unidade é conduzida como entrada para as unidades na camada

seguinte, até a camada de saída, onde a resposta da rede é obtida e o erro é calculado e na fase de retropropagação, os pesos sinápticos são alterados da camada de saída até a entrada.

4.4.4 Modelos de redes neurais RBF

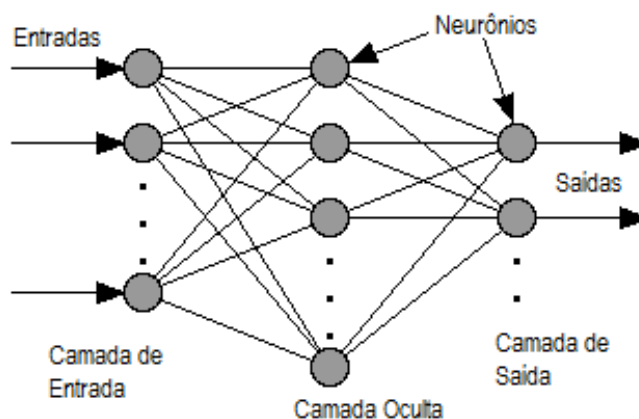
Os modelos de redes neurais artificiais RBF (Radial Basis Functions ou Funções de Base Radial), assim como as redes MLP, são redes neurais multicamadas com neurônios ocultos não lineares. Deste modo, as redes RBF podem determinar soluções de problemas não separáveis linearmente.

De acordo com Haykin (2002), as redes RBF em sua forma mais básica envolvem três camadas de papéis totalmente diferentes. A camada de entrada é constituída por nós que conectam a rede ao ambiente, a segunda camada (oculta) aplica uma transformação não linear do espaço de entrada para o espaço oculto e a camada de saída é linear, fornecendo resposta da rede ao sinal de entrada.

A diferença principal em relação às redes MLP, é que as redes RBF apresentam apenas uma única camada oculta e seus neurônios possuem função de ativação gaussiana em vez de sigmoideal.

Geralmente, apenas uma camada intermediária é utilizada nas redes RBF, embora redes com mais de uma camada intermediária tenham sido propostas (Braga et al., 2000). Na Figura 4.13 é apresentado um exemplo de arquitetura de rede RBF com saídas múltiplas.


Figura 4-13 - Rede neural RBF com múltiplas saídas



fonte: adaptado de www.geocomputation.org

As redes RBF aproximam qualquer função por meio da combinação linear de funções gaussianas com centros em diversas posições do espaço, conforme ilustra a Figura 4-14.

Figura 4-14 - Representação gráfica de uma função qualquer através da combinação de funções gaussianas



fonte: www.deti.ufc.br

Segundo Azevedo et al. (2000), a função mais utilizada com redes RBF é a função de Gauss, dada pela Equação 4.27.

$$h_m = \exp\left(-\frac{1}{2\sigma^2} \|t - c\|^2\right) \quad (\text{Eq. 4.27})$$

Onde c e σ da Equação 4.27 são parâmetros relacionados com o valor médio e o espalhamento da função de Gauss.

4.4.5 Principais diferenças entre os modelos de Redes Neurais MLP e RBF

Tanto as redes RBF como as redes MLP são aproximadores universais de funções, portanto são redes teoricamente equivalentes (Braga et al. 2000). Por serem aproximadores universais, uma rede RBF é capaz de imitar precisamente uma rede MLP ou vice-versa (Haykin, 2000).

As principais diferenças entre as redes MLP e RBF são apresentadas na Tabela 4-2.

Tabela 4-2 - Principais diferenças entre as redes MLP e RBF.

Rede MLP	Rede RBF
<ul style="list-style-type: none"> • Pode possuir uma ou mais camadas intermediárias 	<ul style="list-style-type: none"> • Geralmente possui apenas uma camada intermediária
<ul style="list-style-type: none"> • Os nós das camadas intermediárias e de saída têm funções semelhantes 	<ul style="list-style-type: none"> • Os nós das camadas intermediárias e de saída têm funções distintas
<ul style="list-style-type: none"> • A entrada da função de ativação é o produto interno dos vetores de entrada e de pesos 	<ul style="list-style-type: none"> • A entrada da função de ativação é a distância euclidiana entre os vetores de entrada e de pesos
<ul style="list-style-type: none"> • Separa padrões de entrada com hiperplanos 	<ul style="list-style-type: none"> • Separa padrões de entrada com hiperelipsoides
<ul style="list-style-type: none"> • Melhor em problemas complexos 	<ul style="list-style-type: none"> • Melhor em problemas bem definidos
<ul style="list-style-type: none"> • Constrói aproximadores globais para mapeamento entrada-saída. 	<ul style="list-style-type: none"> • Constrói aproximadores locais para mapeamento entrada-saída.

(Fonte: Braga et al. 2000)

A área escolhida para o estudo de caso localiza-se no perímetro de abastecimento abrangido pelo reservatório elevado do Jardim Maria Lúcia, zona norte da cidade de Londrina/PR. O abastecimento público é realizado pela Companhia de Saneamento do Paraná – Sanepar. A região é predominantemente residencial, possui economias de abastecimento de água residenciais (92,42%), além das economias comerciais (5,99%), industriais (1,19%) e públicas (0,40%).

As economias de abastecimento de água são definidas como a menor unidade individual (indústria, comércio, apartamento ou residência) da ligação de água. Por exemplo, um edifício de 20 apartamentos possui uma ligação e 20 economias.

O reservatório elevado do Jardim Maria Lúcia abastece a área inserida entre as latitudes 23°16'26" e 23°17'48" sul e longitude 51°11'19" e 51°14'29" oeste. A base do reservatório situa-se a 632 metros de altitude em relação ao nível do mar, estrategicamente localizado no ponto mais alto desta área. A Figura 5-2 mostra a área de abastecimento delimitada pela linha amarela e uma vista em perspectiva dos reservatórios está disposta na Figura 5-3.

Figura 5-2 - Área de abastecimento do REL Maria Lúcia



Fonte: Sanepar/GoogleMaps

Figura 5-3 - Perspectiva do centro de reservação Maria Lúcia



Fonte: GoogleMaps

A Tabela 5-1 demonstra a distribuição do número de ligações e de economias totais abastecidas. A quantidade de economias totaliza 5.222 unidades, 11,6% superior ao número de ligações. A baixa verticalização é denotada pela pequena diferença entre o número de economias residenciais e o número de ligações, ou seja, o número de economias é apenas 3,2% superior ao de ligações, por este motivo, o local não possui quantidade significativa de edifícios residenciais ou comerciais multipavimentados. A região consome em média 68.262 m³ por mês, o que perfaz a média de 14,59 m³/mês/ligação ou 486 L/dia/ligação.

Tabela 5-1 - Ligações totais abastecidas e Economias totais abastecidas

Ligações Totais (unidades)	Economias Totais (unidades)				Total de Economias (unidades)
	Residenciais	Comerciais	Industriais	Públicas	
4.678	4.826	313	62	21	5.222

(Fonte: Sanepar - outubro/2010)

O clima de Londrina é classificado, segundo Köppen, como “Cfa”, conforme ilustra a Figura 5-4 em amarelo, enquanto no sul do Estado é classificado como Cfb, em que:

- C – Climas mesotérmicos; temperatura média do ar dos três meses mais frios compreendidas entre -3°C e 18°C ; temperatura média do mês mais quente $> 10^{\circ}\text{C}$; estações de Verão e Inverno bem definidas.
- f – Clima úmido; ocorrência de precipitação em todos os meses do ano; inexistência de estação seca definida;
- a – Temperatura média do ar no mês mais quente $> 22^{\circ}\text{C}$



Figura 5-4 - Classificação climática de Köppen (Fonte: Instituto Agrônomo do Paraná)

As médias históricas do clima de Londrina, para o período de 33 anos, de 1976 a 2009, demonstradas na Tabela 5-2, foram compiladas pelo Instituto Agrônomo do Paraná – Iapar.

Dentre os dados observados na Quadro 5-2, pode-se notar que os meses de inverno concentram as menores precipitações atmosféricas e das temperaturas mais baixas.

Quadro 5-1 - Médias históricas do clima de Londrina (Período 1976 a 2009)


EST.: Londrina / CÓD.: 02351003 / LAT.: 23°22'S / LONG.: 51°10'W / ALT.: 585m														PERÍODO: 1976 - 2009		
Mês	TEMPERATURA DO AR (°C)							U.REL	VENTO		PRECIPITAÇÃO (mm)				EVAPORAÇÃO	INSOLAÇÃO
	média	média máxima	média mínima	máxima absol.	ano	mínima absol.	ano	média (%)	direção pred.	veloc. (m/s)	total	máxima 24h	ano	dias de chuva	total (mm)	total (horas)
JAN	23,9	29,5	19,6	36,4	1993	11,0	1980	76	E	2,4	212,1	113,5	1993	15	105,6	203,2
FEV	23,8	29,7	19,5	36,0	2005	12,2	1987	76	E	2,2	188,8	93,6	1993	14	91,1	192,8
MAR	23,5	29,7	18,7	37,0	2005	7,0	1987	73	E	2,2	136,2	124,6	1992	11	113,5	223,6
ABR	21,6	28,0	16,6	34,3	2002	3,8	1999	71	E	2,2	109,5	151,2	1984	8	108,6	227,8
MAI	18,3	24,5	13,5	32,0	2001	0,0	1979	74	E	2,1	115,8	84,0	1994	8	91,8	216,1
JUN	16,9	23,1	11,9	30,3	2002	-1,0	1994	75	NE/E	2,0	89,1	161,0	1997	8	80,8	206,4
JUL	16,9	23,5	11,6	31,2	1977	-1,3	2000	69	E	2,3	69,0	77,8	1990	6	105,1	229,2
AGO	18,8	25,8	12,8	34,8	1994	0,6	1984	62	E	2,4	53,8	62,5	1986	6	143,3	237,1
SET	19,9	26,4	14,5	37,5	1988	1,9	2002	64	E	2,8	122,7	82,8	1998	9	145,2	198,3
OUT	22,2	28,7	16,7	37,0	2007	8,0	1981	66	E	2,8	138,4	106,4	1994	10	155,6	219,7
NOV	23,2	29,4	17,9	39,2	1985	9,8	1976	67	E	2,8	164,6	142,7	1992	11	148,6	228,0
DEZ	23,7	29,4	19,0	36,4	1985	12,0	2001	72	E	2,6	205,9	117,1	1989	14	125,5	218,0
ANO	21,1	27,3	16,0					70,6			1606			121	1415	2600

Fonte: Instituto Agrônômico do Paraná

Ricce et al. (2009) analisaram as tendências de mudanças nos padrões de temperatura e precipitação usando dados de estações meteorológicas localizados em Londrina. Os autores concluíram que as temperaturas anuais vêm apresentando elevação em Londrina (Figuras 5-5 e 5-6), Também verificaram que nos últimos 48 anos, ocorreram aumentos de: 1,33°C na temperatura mínima anual; 0,83°C na temperatura média e 0,33°C na temperatura máxima. No mesmo período, as precipitações não mostraram tendência significativa de alteração (Figura 5-7).


Com base nos resultados do estudo de Ricce et al. (2009), concluiu-se que as mudanças climáticas mundiais afetaram as temperaturas na região de Londrina.

Figura 5-5 - Temperatura média mínima anual de Londrina - PR de 1961 a 2008




Fonte: Ricce et al. (2009)

Figura 5-6 - Temperatura média máxima anual de Londrina - PR de 1961 a 2008



Fonte: Ricce et al. (2009)

Figura 5-7 - Precipitação total anual de Londrina - PR de 1961 a 2008



Fonte: Ricce et al. (2009)

6. PROCEDIMENTO

6.1 ANÁLISE DO PROBLEMA DE PESQUISA

Uma das dificuldades crescentes dentro do setor de saneamento é a limitação de recursos hídricos disponíveis enquanto o consumo torna-se maior a cada época (Trautwein, 2004). Além disso, o problema abordado neste trabalho concerne às incertezas de demanda por parte dos gestores responsáveis pelos sistemas de abastecimento de água potável.

Muitas vezes, a produção de água é superestimada por desconhecimento da demanda, e em decorrência, os sistemas de abastecimento de água são obrigados a consumir mais energia e retirar maiores quantidades de matéria prima da natureza, dos mananciais superficiais ou subterrâneos, sem a devida necessidade.

A operação de sistemas de abastecimento sem qualquer parametrização para a estimativa da demanda acarreta dificuldades no planejamento de operação dos reservatórios de distribuição, no aumento de perdas de água e em maior consumo de energia elétrica.

O conhecimento da demanda permite antecipação quanto a eventuais desabastecimentos por aumento de consumo. Por outro lado, o desconhecimento da demanda origina desperdício de energia elétrica, comprometendo a disponibilidade de recursos energéticos.

Os problemas gerados pela incerteza da demanda trazem principalmente como consequência, o comprometimento à sustentabilidade ambiental. O gerenciamento sem delineamento objetivo dos recursos hídricos tais como a permissão de elevação de perdas por parte das companhias de saneamento e gasto sem parcimônia pelos usuários, eleva o risco de escassez de água.

Detoni e Dondoni (2008) afirmam que a necessidade por água no mundo deve dobrar nos próximos 25 anos, sendo que quatro bilhões de pessoas poderão enfrentar a insuficiência de água até o ano 2025.

Fonseca e Guimarães (2004) descrevem que variações entre a demanda real e sua previsão são inevitáveis e que praticamente sempre haverá um erro de previsão. As técnicas para aprimoramento da previsão de demanda têm importância na diminuição das variações entre a demanda e sua estimativa.

6.2 IDENTIFICAÇÃO DA SOLUÇÃO E LIMITAÇÕES DO ESTUDO

A proposta para o problema da incerteza sobre a demanda, apresentado neste trabalho, considera a estimativa de demanda com auxílio de técnicas estatísticas e computacionais associadas a análise de séries históricas de dados de consumo. Para tanto, utilizou-se como estudo de caso um setor do sistema de abastecimento de água do município de Londrina, Estado do Paraná.

As técnicas de previsão utilizadas para a estimativa da demanda foram escolhidas por apresentarem bons resultados em diversos trabalhos já estudados. O estudo limitou-se às técnicas de análise de séries temporais, modelos causais e de inteligência artificial pelo meio de redes neurais artificiais.

O estudo realizado inclui também a verificação da demanda de água através da correlação de medições de temperatura média, pluviosidade, umidade relativa do ar e velocidade do vento, em observações ocorridas de 01/01/2008 a 30/09/2010.

Procurou-se estudar as observações em períodos menores que 7 dias para dados horários e menores que 3 meses para dados diários, para que fatores sazonais passados não influenciassem nas medidas históricas mais recentes. Os erros resultantes de cada modelo empírico podem ter origem em outros fatores não inclusos nesta pesquisa.

6.3 COLETA DE DADOS

Os dados de vazões e volumes produzidos ou de demanda coletados no período de 01/01/2008 a 30/09/2010 foram obtidos a partir do banco de

dados do CCO – Centro de Controle Operacional da Companhia de Saneamento do Paraná – Sanepar, de Londrina – PR.

Os dados meteorológicos foram adquiridos através do Instituto Tecnológico Simepar para os dados horários e do Instituto Agrônômico do Paraná para os dados diários.

A vazão de um período de tempo pode ser contabilizada de duas formas: por uma média de vários valores durante um determinado tempo ou por um valor instantâneo. A vazão horária deste estudo foi medida pela vazão instantânea. O Anexo A e Anexo B apresentam, para maiores detalhes, os dados originais de demanda diária e horária, respectivamente.

6.4 ANÁLISE DE ERROS

Segundo Gonçalves (2007), toda demanda possui um componente aleatório, o qual se manifesta na forma de erro de previsão. A análise de erros de previsão auxilia a escolha do modelo a ser adotado e se o mesmo prevê detalhadamente o componente sistemático da demanda.

Os seguintes critérios são utilizados para avaliação dos modelos de previsão de demanda:

- a) **Desvio Absoluto Médio – Mean Absolute Error (MAE):** é uma medida alternativa utilizada quando o analista quer aferir um grande erro ao mesmo tempo em que vários pequenos erros somam o mesmo total. O MAE considera erros positivos e negativos, sendo igualmente somados por seus valores absolutos (Billings e Jones, 2008). O MAE é uma medida do tamanho típico ou médio do erro ou diferença entre os dados observados e as previsões. O MAE é determinado usando a Equação 6.1.

$$MAE = \frac{1}{N} \sum_{t=1}^N |y_t - \hat{y}_t| \quad (\text{Eq. 6.1})$$

- b) **Erro Quadrático Médio – Mean Squared Error (MSE):** A soma dos erros elevados ao quadrado harmoniza os pesos para erros de previsão positivas ou negativas, mas determina um erro muito mais intensamente do que vários pequenos erros somando o mesmo total. A soma dos quadrados é normalmente dividido por N, portanto o número de observações que gera o Erro Quadrático Médio pode ser comparado entre as amostras de diferentes tamanhos. A raiz quadrada do MSE é o erro padrão da estimativa, que é uma medida da dimensão típica do erro de previsão (Billings e Jones, 2008). O MSE é explicada pela Equação 6.2.

$$MSE = \frac{1}{N} \sum_{t=1}^N (y_t - \hat{y}_t)^2 \quad (\text{Eq. 6.2})$$

Em que y_t é igual ao valor atual, \hat{y}_t é igual ao valor estimado, e N é igual ao número de observações.

A diferença mais importante entre o MSE e o MAE é que o MSE eleva ao quadrado os erros individuais, colocando um peso maior nas “outliers” (observações que são numericamente distantes do resto do dados) e a MAE não possibilita tal análise.

- c) **Erro Percentual Médio Absoluto – Mean Absolute Percent Error (MAPE):** O erro de previsão pode muitas vezes ser apresentado em termos percentuais, dividindo cada erro medido pelo valor real da observação correspondente. Isso produz uma medida de erro que é uma unidade livre, para que o analista possa comparar a precisão das previsões de diferentes tamanhos ou segmentos (Billings e Jones, 2008). O erro percentual médio absoluto (MAPE) é demonstrado na Equação 6.3.

$$MAPE = \frac{1}{N} \sum_{t=1}^N \left| \frac{(y_t - \hat{y}_t)}{y_t} \right| \times 100 \quad y_t \neq 0 \quad (\text{Eq. 6.3})$$

Em que y_t é igual ao valor atual, \hat{y}_t é igual ao valor estimado, e N é igual ao número de observações.

- d) **Coeficiente de Pearson (r):** também chamado de coeficiente de correlação, é uma avaliação do nível de afinidade linear entre duas variáveis quantitativas. Este coeficiente é variável entre os valores -1 e 1. O valor 0 (zero) significa que não há relação linear, o valor 1 indica uma afinidade linear perfeita e o valor -1 também indica uma relação linear perfeita mas inversa, ou seja, quando uma das variáveis cresce a outra diminui. Quanto mais próximo estiver de 1 ou -1, mais intensa é a associação linear entre ambas as variáveis. A Equação 6.4 ilustra o Coeficiente de Pearson.

$$r = \frac{\sum (x - \bar{x})(y - \bar{y})}{\sqrt{\sum (x - \bar{x})^2 (y - \bar{y})^2}} \quad (\text{Eq. 6.4})$$

Em que x e y são os valores individuais das amostras e, \bar{x} e \bar{y} são as médias das amostras.

- e) **Coeficiente de determinação (R²):** é interpretado como a proporção da variância total da variável dependente Y que é explicada pelo modelo de regressão, ou seja, é a quantidade de variabilidade dos dados explicada ou considerada pelo modelo de regressão. No caso de duas variáveis (X e Y) aleatórias e distribuídas conjuntamente, R^2 será o quadrado do coeficiente de correlação r . O coeficiente de determinação estará situado entre 0 e 1. Quanto mais próximo do valor unitário, mais adequado será o modelo, entretanto, segundo Montgomery e Runger (2003), não implica necessariamente que o modelo seja adequado. Em caso de regressões múltiplas, a adição de uma nova variável ao modelo sempre aumentará R^2 , independente da variável adicional ser ou não estatisticamente significativa.

Billings e Jones (2008) consideram que valores de R^2 situados entre 0,70 e 0,90 são avaliados como resultados muito bons.

$$R^2 = \frac{\text{variação explicada}}{\text{variação total}} = \frac{SQ_{\text{Reg.}}}{SQT}$$

Em que:

- $SQ_{\text{Reg.}}$ = soma dos quadrados explicada pela regressão;
- SQT = soma dos quadrados totais

6.5 TRATAMENTO DOS DADOS

Para a previsão da demanda de abastecimento de água, analisados no estudo de caso, foram considerados os dados de quatro períodos, divididos em duas séries diárias (ajuste e previsão) e duas séries horárias (ajuste e previsão).

O primeiro período, de 01/12/2008 a 14/03/2009, totaliza 104 observações diárias de demanda que foram usados para o período de ajuste e o segundo período, de 15/03/2009 a 28/03/2009, composto por 14 dados que foram utilizados para a previsão de demanda diária.

No terceiro e quarto período analisados, foram avaliadas respectivamente, as demandas horárias de 144 horas de operação entre os dias 01/04/2010 a 06/04/2010 para o período de ajuste e 24 horas para o período de previsão horária para o dia 07/04/2010.

Para cada série (diária de ajuste, diária de previsão, horária de ajuste e horária de previsão), foram aplicados os modelos de séries temporais, modelos de regressão múltipla e modelos de redes neurais artificiais.

A eficiência de cada modelo estudado foi medida através da análise dos erros MAE (erro absoluto médio), MSE (erro quadrático médio), MAPE (erro percentual absoluto médio) e R^2 (coeficiente de determinação).

7. RESULTADOS E DISCUSSÃO

Neste capítulo são apresentados os resultados obtidos nos três tipos de modelos estudados: modelos de séries temporais, modelos de séries causais e modelos de redes neurais artificiais para a previsão de demanda do estudo de caso. Os trabalhos foram separados em séries diárias e séries horárias, cada série dividida em períodos de ajuste e outra de previsão. Este estudo foi realizado com o auxílio do software Statsoft Statistica[®].

7.1 RESULTADOS DE PREVISÕES DIÁRIAS

As previsões diárias do estudo de caso foram realizados com base em 104 observações realizadas entre os dias 01/12/2008 a 14/03/2009, que constitui o período de ajuste do estudo. A previsão foi realizada para os 14 dias seguintes (de 15/03/2009 a 28/03/2009).

Os melhores parâmetros obtidos no período de ajuste foram utilizados no período de previsão. Não há garantia de que os parâmetros mais bem sucedidos do período de ajuste produzirão os melhores resultados no período de previsão, no entanto devem apresentar maior garantia de sucesso na antevisão dos valores futuros, onde os padrões ótimos do período de previsão permanecerão, conjecturalmente, muito próximos aos do período de ajuste.

Nos próximos itens são apresentados os resultados de ajuste e previsão para os tipos de modelos estudados.

7.1.1 Modelo de Médias Móveis

O modelo de médias móveis apresenta-se como um modelo simples para aplicação. Grandes períodos de recorrência (Pr) conduzem a maiores efeitos de suavização da previsão, em contrapartida, apresentam maiores erros de previsão de curto prazo. Por este motivo, o período de recorrência escolhido foi de 2 dias, o menor período de recorrência possível.

Para a compensação do atraso de previsão e para utilização em previsões de curto prazo, um fator de aproximação multiplicado pela diferença das médias anteriores, que constitui uma parcela de aproximação, pode ser acrescentado à Equação 4.2. A maior eficácia, para os dados estudados, foi determinada por duas médias anteriores. Essa parcela de aproximação é representada pela Equação 7.1.

$$PA = \beta(xp_{t-1} - xp_{t-2}) \quad (\text{Eq. 7.1})$$

Em que:

- PA = parcela de aproximação;
- xp_t = média móvel ponderada;
- β = fator de aproximação.

A adição da parcela de aproximação transforma a Equação 4.2 na Equação 7.2.

$$xp_t = a_1 xp_{t-1} + a_2 xp_{t-2} + PA \quad (\text{Eq. 7.2})$$

O sinal de PA é resolvido pela diferença $xp_{t-1} - xp_{t-2}$. PA será positivo se $xp_{t-1} > xp_{t-2}$ e negativo se $xp_{t-1} < xp_{t-2}$. O acréscimo de PA à Equação 4.2 resolve em parte o atraso das previsões com as médias móveis, contudo produz previsões de maior amplitude que a série original.

A média móvel utilizada foi a média móvel ponderada com a adição da parcela de aproximação, conforme as Equações 7.1, 7.2 e 7.3.

A partir de testes realizados, o melhor valor de β utilizado na Equação 7.1 foi de 0,7 e os coeficientes de ponderação a_1 e a_2 , respectivamente, iguais a 0,9 e 0,1 (Eq. 7.2); ficando assim, a Equação 7.3 para o período de ajuste:

$$xp_t = 0,9xp_{t-1} + 0,1xp_{t-2} + 0,7(xp_{t-1} - xp_{t-2}) \quad (\text{Eq. 7.3})$$

O modelo de média móvel ponderada com a adição da parcela de aproximação (Figura 7-1) produziu resultados melhores que o modelo de média móvel ponderada simples, em que $\beta=0$ (Figura 7-2).

Na Tabela 7-1 é apresentada uma análise dos erros dos modelos de previsão de médias móveis ponderadas, a partir de valores de β (de 0 a 1).

Figura 7-1 - Gráfico de Ajuste de Médias Móveis com Parcela de Aproximação




Figura 7-2 - Gráfico de Ajuste de Médias Móveis sem Parcela de Aproximação




Tabela 7-1 - Valores de β e Análise de Erros de Média Móvel Ponderada para o período de ajuste

Valor de β	Pearson	R ²	MAE	MSE	MAPE
0,0	0,16	0,02	273,37	111.290,86	6,54%
0,1	0,19	0,03	258,32	101.761,08	6,19%
0,2	0,22	0,05	245,81	94.145,26	5,90%
0,3	0,25	0,06	235,44	88.443,42	5,65%
0,4	0,28	0,08	227,02	84.655,55	5,46%
0,5	0,30	0,09	222,20	82.781,64	5,35%
0,6	0,31	0,10	219,89	82.821,70	5,30%
0,7	0,32	0,10	218,84	84.775,73	5,28%
0,8	0,32	0,11	221,62	88.643,73	5,35%
0,9	0,32	0,10	228,04	94.425,69	5,51%
1,0	0,32	0,10	235,93	102.121,63	5,70%

Com base nos resultados da Tabela 7-1, para utilização no período de previsão, elegeu-se $\beta=0,7$ por apresentar menores MAE e MAPE. O gráfico da Figura 7-3 apresenta a previsão diária para o período em que a média móvel ponderada com a parcela de aproximação foi testada para o período de ajuste.

Na Tabela 7-1 são apresentados os resultados da análise dos erros para o período de previsão pela aplicação do modelo de médias móveis ponderadas com a parcela de aproximação, utilizando-se diversos valores de β (de 0 a 1).

Figura 7-3 - Gráfico para o período de previsão de Médias Móveis Ponderadas




Tabela 7-2 - Análise de erros da aplicação do modelo de Média Móvel Ponderada com a parcela de aproximação para o período de previsão.

Valor de β	Pearson	R ²	MAE	MSE	MAPE
0,7	0,05	0,003	161,71	54.663,79	3,96%

Os erros MAE, MSE e MAPE do período de previsão de médias móveis ponderadas apresentaram resultados melhores que os resultados do período de ajuste. Porém, os coeficientes de Pearson e R² demonstraram resultados inferiores ao período de ajuste.

Valores de β crescentes, maiores que 1 (um), apresentam amplitudes também crescentes nos resultados, devido à maximização do coeficiente de aproximação. Por isso foi necessário inserir uma parcela ou fator que pudesse adequar as amplitudes e melhorar os ajustes e previsões.

7.1.2 Modelo de Suavização Exponencial Simples

Assim como o modelo de médias móveis, o modelo de suavização exponencial simples proporciona ampla simplicidade de uso. Pela utilização da Equação 4.3, o melhor valor da constante de suavização encontrada foi $\alpha = 0,426$. O critério utilizado para a determinação de alfa (α) é a minimização da soma dos quadrados dos erros de ajuste, determinados computacionalmente através do software Statsoft Statistica®.

No gráfico da Figura 7-4 é apresentado o resultado do período de ajuste, e na Tabela 7-3 são apresentados os erros do Modelo de Suavização Exponencial Simples para o período de ajuste.

Figura 7-4 - Gráfico de Ajuste de Suavização Exponencial Simples para Demanda Diária




Tabela 7-3 - Análise de Erros do Modelo de Suavização Exponencial Simples para o período de ajuste

α	Pearson	R ²	MAE	MSE	MAPE
0,426	0,26	0,07	217,00	74.228,68	5,21%

Para $\alpha = 0,426$; os resultados obtidos no período de previsão são demonstrados no gráfico da Figura 7-5. Por limitação do modelo, a previsão resulta em um valor constante.

Na Tabela 7-4 são apresentados os valores dos erros de aplicação do modelo exponencial simples, para o período de previsão, que foram menores que

os obtidos para o mesmo modelo no período de ajuste. Igualmente ao modelo de médias móveis ponderadas, os coeficientes de correlação e determinação do período de previsão também obtiveram desempenho inferior ao período de ajuste neste modelo.

Figura 7-5 - Gráfico para o Período de Previsão de Suavização Exponencial Simples




Tabela 7-4 - Análise de Erros do Modelo de Suavização Exponencial Simples para o período de Previsão.

α	Pearson	R^2	MAE	MSE	MAPE
0,426	0,20	0,04	147,59	36.974,51	3,59%

7.1.3 Modelo de Holt ou Suavização Exponencial Dupla

A suavização exponencial dupla, adicionalmente a constante de suavização (α), do modelo de suavização simples, apresenta uma constante de suavização de tendência (β).

Na aplicação deste modelo, para o período de ajuste, resultaram valores da constante de suavização de nível $\alpha=0,425$ e da suavização de tendência $\beta=0,001$. Para β com valor positivo e pequeno, o ajuste apresentou um valor muito próximo da Suavização Exponencial Simples.

O gráfico da Figura 7-6 apresenta os resultados para o período de ajuste do modelo de Suavização Exponencial Dupla.

Os resultados do modelo de Suavização Exponencial Dupla, no período de ajuste, ficaram muito próximos dos erros gerados pela Suavização Exponencial Simples. A Tabela 7-5 apresenta os resultados do período de ajuste:

Figura 7-6 - Gráfico de Ajuste de Suavização Exponencial Dupla para Demanda Diária




Tabela 7-5 - Análise de Erros do Modelo de Suavização Exponencial Dupla para o período de ajuste.

α	β	Pearson	R^2	MAE	MSE	MAPE
0,42	0,00	0,26	0,0	216,9	74.282,9	5,21
5	1		7	7	9	%

Com valor de $\beta=0,001$, do período de ajuste, obteve-se os resultados para o período de previsão, Figura 7-7. A configuração desses resultados é praticamente idêntica a obtida para o do modelo de Suavização Exponencial Simples. Os resultados da análise de erros da aplicação do modelo são mostrados na Tabela 7-6.

Diferentemente dos modelos anteriores, o período de previsão do modelo de Suavização Exponencial Dupla apresentou todos os parâmetros de estimativa de erro melhores que os apresentados no período de ajuste.

Figura 7-7 - Gráfico para o Período de Previsão de Suavização Exponencial Dupla




Tabela 7-6 - Análise de Erros do Modelo de Suavização Exponencial Dupla para o período de previsão.

α	β	Pearson	R^2	MAE	MSE	MAPE
0,425	0,0001	0,75	0,56	148,58	37.030,31	3,61%

7.1.4 Modelo de Holt-Winters Aditivo

Para o modelo de Holt-Winters Aditivo, aplicando-se as Equações 4.7, 4.8 e 4.9, para o nível, tendência e sazonalidade, respectivamente, obtiveram-se os valores das constantes de suavização de nível $\alpha=0,218$; de tendência $\beta=0,001$ e de sazonalidade $\gamma=0,529$, cujas aplicações resultaram no ajuste apresentado no gráfico da Figura 7.8.

A Tabela 7-7 apresenta a análise de erros do modelo de Holt-Winters Aditivo para o período de ajuste.

Figura 7-8 - Gráfico de Ajuste do Modelo de Holt-Winters Aditivo para Demanda Diária

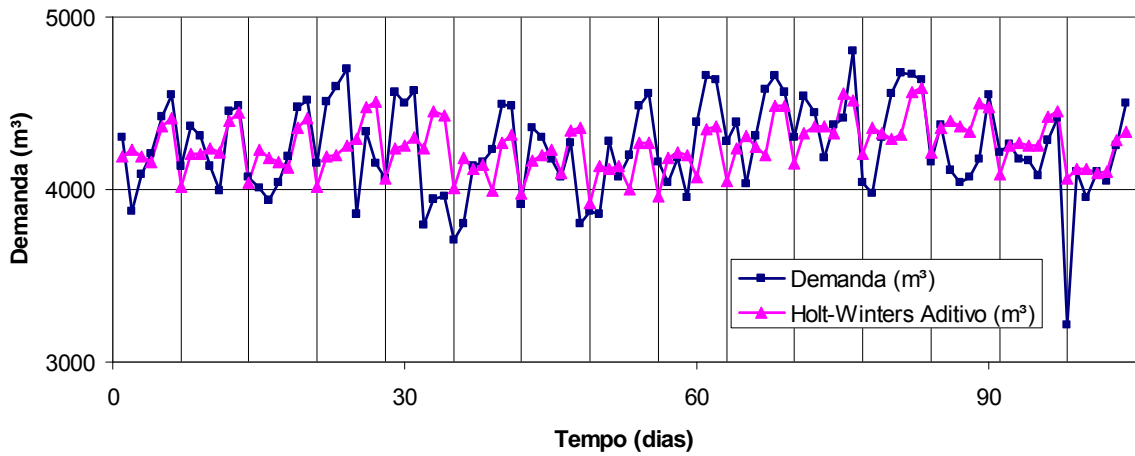


Tabela 7-7 - Análise de Erros do Modelo de Holt-Winters Aditivo para o período de ajuste.

α	β	γ	Pearson	R ²	MAE	MSE	MAPE
0,218	0,001	0,529	-0,39	0,22	184,99	55.089,74	4,45%

Utilizando-se as mesmas constantes de suavização, do período de ajuste, foram alcançados os resultados para o período de previsão, conforme mostrados no gráfico da Figura 7-9.

Os indicadores de erros MAE, MSE e MAPE do período de previsão, como os modelos anteriores, também apresentaram bons resultados, melhores que do período de ajuste, conforme Tabela 7-8:

Figura 7-9 - Gráfico para o Período de Previsão do Modelo de Holt-Winters Aditivo




Tabela 7-8 - Análise de Erros do Modelo de Holt-Winters Aditivo para o período de previsão.

α	β	γ	Pearson	R^2	MAE	MSE	MAPE
0,218	0,001	0,529	0,67	0,45	117,03	22.338,97	2,84%

7.1.5 Modelo de Holt-Winters Multiplicativo

Assim como no modelo aditivo, o modelo de Holt-Winters Multiplicativo lança mão das constantes de suavização de nível, de tendência e de sazonalidade. Porém neste modelo, os valores das constantes calculadas foram: nível $\alpha=0,165$; tendência $\beta=0,001$ e sazonalidade $\gamma=0,534$.

Aparentemente, o gráfico do modelo em estudo não apresenta aumento de amplitude ao longo do tempo. O gráfico de ajuste, Figura 7-10, apresenta-se comparável ao do modelo de Holt-Winters Aditivo.

A análise dos erros do Modelo de Holt-Winters Multiplicativo para a demanda diária está apresentada na Tabela 7-9.

Figura 7-10 - Gráfico de Ajuste do Modelo de Holt-Winters Multiplicativo para Demanda Diária




Tabela 7-9 - Análise de Erros do Modelo de Holt-Winters Multiplicativo para o período de ajuste.

α	β	γ	Pearson	R^2	MAE	MSE	MAPE
0,165	0,001	0,534	0,47	0,22	184,61	55.262,77	4,44%

Por ser um modelo análogo ao modelo aditivo e não apresentar aumento de amplitude na série de ajuste, os erros obtidos apresentaram valores muito semelhantes ao do Modelo de Holt-Winters Aditivo. Graficamente, o modelo multiplicativo, Figura 7-11, assemelhou-se ao modelo aditivo, por tratarem-se de modelos comparáveis.

Do mesmo modo, o resultados dos erros da aplicação do modelo multiplicativo, no período de previsão, assemelharam-se aos do modelo aditivo, com ligeira melhora dos erros, conforme Tabela 7-10.

Figura 7-11 - Gráfico para o Período de Previsão do Modelo de Holt-Winters Multiplicativo




Tabela 7-10 - Análise de Erros do Modelo de Holt-Winters Multiplicativo para o período de previsão.

α	β	γ	Pearson	R ²	MAE	MSE	MAPE
0,165	0,001	0,534	0,67	0,46	115,09	21.804,63	2,79%

7.1.6 Modelo de Box e Jenkins e Análise de FAC e FACP

Para a preparação dos modelos de Box e Jenkins, primeiramente foi feita a análise da função de autocorrelação (FAC – Função de Autocorrelação) e da função de autocorrelação parcial (FACP – Função de Autocorrelação Parcial), os quais determinam o modelo mais provável e as ordens p, d e q dos modelos ARIMA.

As Figuras 7-12 e 7-13 apresentam, respectivamente, o gráfico das funções de autocorrelação FAC e de autocorrelação parcial FACP para os dados de demanda diária do estudo de caso.

Figura 7-12 – Função de Autocorrelação (FAC) para dados diários de demanda com limite de significância de 95%.


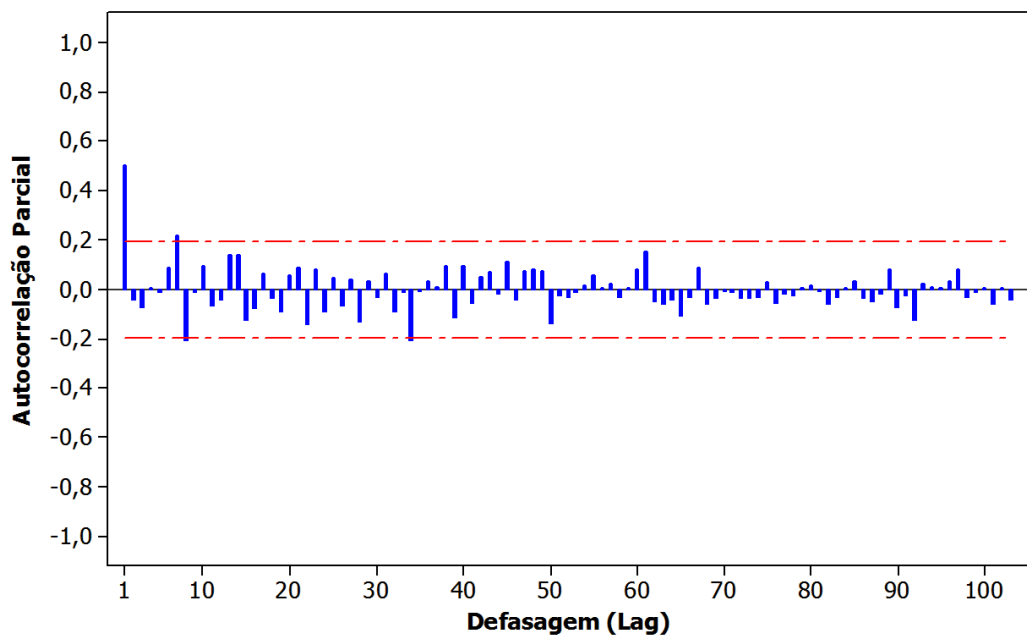



Figura 7-13 – Função de Autocorrelação Parcial (FACP) para dados diários de demanda com limite de significância de 95%.



A partir da verificação do gráfico da Figura 7-14, nota-se que a evolução da série com relação à média dos dados indica que a série é estacionária, portanto a ordem $d=0$. A sazonalidade do modelo diário é semanal, portanto, com ordem $D=1$ e sazonalidade S igual a 7 (uma semana), através da análise do período da FAC.

Figura 7-14 – Evolução da Série Temporal com relação à Média e Tendência Linear



A análise da FAC e FACP, indica que ambas apresentam um valor fora do intervalo de confiança. Portanto, o modelo ARIMA sazonal provável com ordem $(p,d,q)(P,D,Q)_s$ é dado por SARIMA $(1,0,1)(1,1,1)_7$.

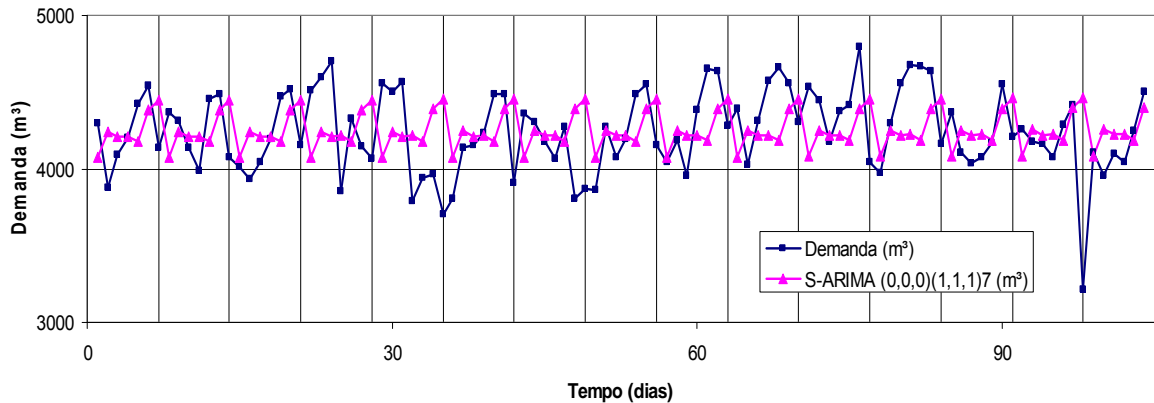
A Tabela 7-11 apresenta os resultados do SARIMA para algumas ordens de $(p,d,q)(P,D,Q)_s$.

O melhor resultado do modelo de Box e Jenkins, SARIMA $(1,0,1)(1,1,1)_7$, para dados de demanda diária é mostrado no gráfico da Figura 7-15.

Tabela 7-11 - Resultados das ordens SARIMA $(p,d,q)(P,D,Q)_s$

Ordem	Pearson	R ²	MAE	MSE	MAPE
$(0,0,0)(1,1,1)_7$	-0,09	0,01	237,28	89.538,04	5,69%
$(0,0,0)(0,1,1)_7$	-0,09	0,01	237,26	89.551,87	5,69%
$(1,0,1)(0,1,1)_7$	-0,09	0,01	239,34	92.593,67	5,76%
$(1,0,1)(1,1,1)_7$	-0,10	0,01	239,74	92.855,34	5,77%
$(1,0,1)(1,0,1)_7$	-0,09	0,01	241,91	95.329,97	5,78%
$(1,1,1)(1,0,1)_7$	-0,07	0,00	245,82	96.139,77	5,80%
$(0,0,0)(1,1,0)_7$	-0,11	0,01	376,30	211.424,09	8,80%
$(1,1,1)(1,1,1)_7$	-0,06	0,00	573,57	450.983,86	13,27%

Figura 7-15 - Gráfico de Ajuste do Modelo de Box-Jenkins - ARIMA Sazonal para Demanda Diária – SARIMA (0,0,0)(1,1,1)₇



O modelo SARIMA (0,0,0)x(1,1,1)₇ superou o modelo provável na fase de ajuste e será utilizado no período de previsão. O gráfico da Figura 7-16 delinea a previsão realizada.

A Tabela 7-12 apresenta os resultados da análise de erros do Modelo de Box e Jenkins para o período de previsão. Os erros MAE, MSE e MAPE da fase de previsão apresentaram-se com valores menores que os do período de ajuste, igualmente aos modelos anteriores. Porém, os valores de correlação e determinação não apresentaram valores significativos.

Figura 7-16 - Gráfico para o Período de Previsão do Modelo de Box e Jenkins – SARIMA (0,0,0)x(1,1,1)₇




Tabela 7-12 - Análise de Erros do Modelo de Box e Jenkins para o período de previsão

Ordem	Pearson	R ²	MAE	MSE	MAPE
(0,0,0)x(1,1,1) ₇	0,0003	0,02	155,10	43.030,37	3,74%

7.1.7 Modelo de Regressão Linear Múltipla por Método Stepwise

Para a previsão de demanda de séries diárias, foram colhidos dados diários de temperatura máxima, média e mínima (°C), umidade (%), insolação (h), radiação global (cal), vento acumulado (somatória do deslocamento do vento no ponto medido em 1 dia) a 10 metros de altura (km) e nebulosidade às 9h, 15h e 21h (0 a 10). A relevância de cada variável preditora é determinada pelo método Stepwise.

O critério utilizado para a inclusão das variáveis foi possuir p-valor menor que 0,05. Sob este pré-requisito, as variáveis de temperatura mínima e vento acumulado mostraram-se significantes para a predição do modelo. Obtendo-se a Equação 7.4.

O ajuste dos dados com base na Equação 7.4 é mostrado na Figura 7.17 e as análises de erros, correlação e determinação do modelo de regressão linear múltipla é descrita na Tabela 7-13.

$$Demanda = 1930 + 88,2 \times Temp.Mín. + 0,99 \times Vento \quad (7.4)$$

Figura 7-17 - Gráfico de Ajuste do Modelo de Regressão Múltipla para Demanda Diária.




Tabela 7-13 - Análise de Erros do Modelo de Regressão Linear Múltipla para o período de ajuste

Pearson	R ²	MAE	MSE	MAPE
0,57	0,32	169,37	47.313,77	4,02%

Na Figura 7-18 e na Tabela 7-14 são mostrados concomitantemente a conformação gráfica do período de previsão e a análise de erros encontrados.

Figura 7-18 - Gráfico para o Período de Previsão do Modelo de Regressão Linear Múltipla.




Tabela 7-14 - Análise de Erros do Modelo de Regressão Linear Múltipla para o período de previsão

Pearson	R ²	MAE	MSE	MAPE
0,57	0,35	112,23	21.836,59	2,71%

7.1.8 Modelo Híbrido de Médias Móveis e Regressão Linear Múltipla

Este modelo busca inserir a sazonalidade em previsões de regressão linear múltipla. Para tanto, utilizou-se um modelo híbrido de médias móveis e regressão linear múltipla. Adicionalmente às variáveis classificadas no método Stepwise, foram adicionadas as médias móveis ponderadas de dois dias anteriores agregadas com a parcela de aproximação, apresentada no item 7.7.1.

A equação encontrada para o modelo de Médias Móveis e Regressão Linear Múltipla é mostrada na Equação 7.5.

$$Demanda = -103 + 101 \times Temp.Mín. + 1,09 \times Vento + 1697 \times MédiaMóvel \quad (7.5)$$

A partir da Equação 7.5, foi possível a plotagem do gráfico mostrado na Figura 7.19, para o período de ajuste.

A análise de erros do período de ajuste deste modelo apresentou-se com resultados muito animadores e com melhor desempenho que os dos modelos anteriores. Os resultados de erros estão apresentados na Tabela 7-15

Figura 7-19 - Gráfico de Ajuste do Modelo de Regressão Múltipla com Médias Móveis para Demanda Diária.




Tabela 7-15 - Análise de Erros do Modelo de Híbrido de Regressão Linear Múltipla com Médias Móveis para o período de ajuste.

Pearson	R²	MAE	MSE	MAPE
0,67	0,44	151,07	39.050,44	3,59%

Utilizando a mesma equação (Equação 7.5) do período de ajuste, foi testado o período de previsão, igualmente com bons resultados. O gráfico da Figura 7-20 ilustra a previsão realizada e os resultados dos erros são apresentados na Tabela 7-16.

O período de previsão apresentou resultados de erros mais precisos que o período de ajuste. Entretanto, os coeficientes de correlação e determinação não apresentaram a mesma performance.

Figura 7-20 - Gráfico para o Período de Previsão do Modelo de Regressão Linear Múltipla e Médias Móveis.




Tabela 7-16 - Análise de Erros do Modelo de Regressão Linear Múltipla com Médias Móveis para o período de previsão.


Pearson	R ²	MAE	MSE	MAPE
0,41	0,17	138,24	32.272,38	3,31%

7.1.9 Redes Neurais Artificiais MLP-BP

O modelo de Redes Neurais Artificiais Multilayer Perceptron com algoritmo Backpropagation MLP-BP empregou as mesmas variáveis utilizadas pelo método Stepwise com Médias Móveis. Escolheu-se o algoritmo Backpropagation por ser um algoritmo simples, com um grande número de parâmetros de ajuste, de aproximação de cálculo inicial lento, mas de convergência com bons resultados.

Foram utilizadas três camadas de entrada, uma camada de saída e duas camadas ocultas com 15 e 11 neurônios, respectivamente na primeira (BP1) e segunda camada (BP2). A BP1 utilizou 100 épocas de treinamento com taxa de aprendizagem de 0,1 e a BP2 empregou 500 épocas de treinamento e igual taxa de aprendizagem (0,1). A Figura 7-21 esboça a topologia da rede MLP-BP utilizada.

Figura 7-21 – Topologia da Rede Neural Artificial MLP-BP 3-15-11-1



O resultado gráfico da previsão por Redes Neurais Artificiais Multilayer Perceptron com algoritmo Backpropagation é mostrado na Figura 7-22.

Quanto à análise de erros, a RNA MLP-BP utilizada proporcionou resultados de previsão mais contíguos à demanda real medida que os demais modelos vistos, inclusive com maior acurácia que o modelo híbrido de Regressão Múltipla com Médias Móveis. A Tabela 7-17 apresenta a análise de erros do modelo RNA MLP-BP 3-15-11-1, para o período de ajuste para dados diários.

Figura 7-22 - Gráfico de Ajuste do Modelo de Rede Neural Artificial MLP Backpropagation 3-15-11-1 para Demanda Diária.




Tabela 7-17 – Resultado de Erros para aplicação do Modelo de Rede Neural Artificial MLP Backpropagation 3-15-11-1 para o período de ajuste da demanda diária.

Pearson	R²	MAE	MSE	MAPE
0,70	0,50	140,85	35.245,54	3,36%

Na Figura 7.23 são apresentados os resultados para o período de previsão usando o Modelo RNA MLP-BP 3-15-11-1, enquanto na Tabela 7.18 são apresentados os resultados da análise de erros do período de ajuste.

O período de previsão do modelo de Redes Neurais Artificiais MLP-BP também obteve bons resultados. Entretanto não foi o modelo de melhor eficiência na previsão, contrariamente ao período de ajuste.

Figura 7-23 - Gráfico para o Período de Previsão do Modelo RNA MLP-BP




Tabela 7-18 - Resultado de Erros para aplicação do Modelo de Rede Neural Artificial MLP Backpropagation 3-15-11-1 para o período de previsão da demanda diária.


Pearson	R²	MAE	MSE	MAPE
0,37	0,13	134,48	28.688,63	3,22%

7.1.10 Redes Neurais Artificiais RBF

Finalizando o estudo de demanda diária, o Modelo de Redes Neurais Artificiais de Funções de Base Radial (RBF) foi estudado para os modelos diários de previsão.

A topologia da RNA RBF estudada possui 3 neurônios de entrada, 7 neurônios intermediários e 1 neurônio de saída. Sua configuração está demonstrada na Figura 7-24.

Figura 7-24 - Topologia da Rede Neural Artificial RBF 3-7-1.



A Figura 7-25 apresenta graficamente o resultado do ajuste realizado para a RNA RBF 3-7-1.

O algoritmo da RNA RBF 3-7-1 conseguiu convergir mais rapidamente que o algoritmo da RNA MLP-BP. Apresentou os melhores resultados dentre todos os modelos estudados e estes foram muito próximos dos resultados da RNA MLP-BP. O resultado da análise de erros da fase de ajuste do modelo RNA RBF está demonstrado na Tabela 7-19.

Figura 7-25 - Gráfico de Ajuste do Modelo de Rede Neural Artificial RBF para Demanda Diária.




Tabela 7-19 - Resultado de Erros da Aplicação do Modelo de Rede Neural Artificial RBF 3-7-1 para o período de ajuste.

Pearson	R²	MAE	MSE	MAPE
0,71	0,51	140,23	34.468,78	3,34%

Empregando-se a mesma configuração da RNA RBF do período de ajuste, foi realizada a previsão para o período seguinte de 14 dias. O modelo não obteve a melhor classificação dentre os modelos de previsão estudados. Porém, apresenta precisão suficiente, chegando de 0,09% a 0,25% de erro percentual entre alguns dados individuais de previsão. A Figura 7-26 apresenta o gráfico da previsão de demanda de abastecimento de água pelo do modelo de Redes Neurais Artificiais por meio do algoritmo de Função de Base Radial – RNA RBF 3-7-1.

A Tabela 7-20 exhibe a análise de erros da aplicação do modelo de Redes Neurais Artificiais RBF para o período de previsão de demanda diária.

O modelo RNA RBF superou todos os modelos estudados no período de ajuste. Todavia, não apresentou o mesmo desempenho na fase de previsão.

Figura 7-24 - Gráfico para o Período de Previsão do Modelo RNA RBF




Tabela 7-20 - Resultados de Erros do Modelo de Rede Neural Artificial RBF para o período de previsão

Pearson	R²	MAE	MSE	MAPE
0,39	0,15	125,96	29.088,77	3,00%

7.2 RESULTADOS DE PREVISÕES HORÁRIAS

Nesta seção estão demonstradas as previsões horárias do estudo de caso. O ajuste dos dados foram realizadas a partir de 144 observações horárias realizadas entre os dias 01/04/2010 a 06/04/2010. O período de previsão foi realizada para as 24 horas seguintes do dia 07/04/2010.

As curvas horárias de demanda de abastecimento de água obedecem a um padrão típico de configuração diária. Os valores mínimos ocorrem, em geral, entre o horário das 5 às 6 horas (madrugada), enquanto os valores máximos ocorrem em dois períodos observados diariamente, um pico máximo entre 11 e 12 horas (almoço) e outro pico entre 19 e 20 horas (banho).

Assim como na previsão diária, os melhores parâmetros obtidos no período de ajuste foram utilizados no período de previsão. Os resultados encontrados são apresentados a seguir.

7.2.1 Modelo de Médias Móveis

Para atenuação do efeito de erro de previsão de curto prazo, foi escolhido o menor período de recorrência (Pr) possível, ou seja, as duas horas que precede a previsão ou o ajuste.

Igualmente ao Modelo de Médias Móveis Diário, a média móvel utilizada foi a média móvel ponderada com a adição da parcela de aproximação, Equações 7.1, 7.2 e 7.3. O melhor valor de β utilizado na Equação 7.3 foi de 0,7, coincidentemente igual ao da previsão diária, e os coeficientes de ponderação a_1 e a_2 foram, respectivamente, iguais a 0,7 e 0,3. Desta forma a Equação 7.2 passou a ser representada conforme a Equação 7.6 para o período de ajuste horário.

As Figuras 7-25 e 7-26 mostram os resultados de ajuste de demandas horárias pelo modelo de médias móveis com e sem parcela de aproximação; $\beta=0,7$ e $\beta=0$; respectivamente.

$$xp_t = 0,7xp_{t-1} + 0,3xp_{t-2} + 0,7(xp_{t-1} - xp_{t-2}) \quad (7.6)$$

Assim como no caso da aplicação do modelo de média móvel para previsão de demanda diária, o modelo de média móvel ponderada com a adição da parcela de aproximação (Figura 7-27), para a demanda horária, produziu resultados melhores que o modelo de média móvel ponderada simples, em que $\beta=0$ (Figura 7-28).

Com $\beta=0$, o erro MAPE resultou em 12,09%, enquanto que com o $\beta=0,7$; o MAPE foi de 9,38% (Tabela 7-21). A comparação visual entre os gráficos das Figuras 7-25 e 7-26 demonstra a vantagem do uso do fator de aproximação na previsão da demanda tanto horária quanto diária, visto anteriormente.

Figura 7-25 - Gráfico de Ajuste da Demanda Horária pelo Modelo de Médias Móveis com Parcela de Aproximação.




Figura 7-26 - Gráfico de Ajuste da demanda horária pelo Modelo de Médias Móveis sem Parcela de Aproximação.




Tabela 7-21 - Análise de Erros de Média Móvel Ponderada para o período de ajuste horário.

Valor de β	Pearson	R ²	MAE	MSE	MAPE
0,7	0,94	0,88	16,18	431,8	9,38%

O gráfico da Figura 7-27 apresenta a previsão horária usando o modelo de média móvel ponderada com fator de aproximação $\beta=0,7$:

A Tabela 7-22 destaca os resultados para o período de previsão para demanda horária.

Figura 7-27 - Gráfico para o período de previsão de Médias Móveis Ponderadas para demanda horária




Tabela 7-22 - Análise de Erros de Média Móvel Ponderada para o período de previsão para demanda horária.

Valor de β	Pearson	R^2	MAE	MSE	MAPE
0,7	0,90	0,82	14,79	474,3	8,71%

Observou-se que valores de β crescentes, maiores que 1, apresentam amplitudes também crescentes nos resultados, devido à maximização do coeficiente de aproximação. Por isso foi necessário inserir uma parcela ou fator que permitisse adequar as amplitudes e melhorar os ajustes e previsões.

7.2.2 Modelos de Suavização Exponencial

Embora os modelos de Suavização Exponencial tenham se apresentados apropriados ao período de ajuste, no período de previsão de demandas horárias não se mostraram adequados, uma vez que a previsão resultou em uma reta, por limitação do modelo. Por isso, decidiu-se suprimir o estudo de

modelos de suavização exponencial para as demandas horárias de abastecimento de água.

7.2.3 Modelo de Holt-Winters Aditivo

As equações para determinação das componentes de nível (Eq. 4.7), de tendência (Eq. 4.8) e de sazonalidade (Eq. 4.9) foram aplicadas aos dados da série de demanda horária e alcançaram os seguintes valores para as constantes de suavização de nível $\alpha=0,322$; tendência $\beta=0,001$ e sazonalidade $\gamma=0,999$.

Os resultados do uso do modelo de Holt-Winters Aditivo para o período de ajuste de demanda horária são mostrados na Figura 7-28. A Tabela 7-23 apresenta a análise de erros do modelo de Holt-Winters Aditivo para o período de ajuste de demanda horária.

Figura 7-28 - Gráfico de Ajuste do Modelo de Holt-Winters Aditivo para Demanda Horária




Tabela 7-23 - Análise de Erros do Modelo de Holt-Winters Aditivo para o período de ajuste.

α	β	γ	Pearson	R^2	MAE	MSE	MAPE
0,322	0,001	0,999	0,93	0,86	17,08	501,94	9,46%

De posse das constantes de suavização obtidas no período de ajuste, partiu-se para a etapa de previsão, cujos resultados são apresentados na Figura 7-29.

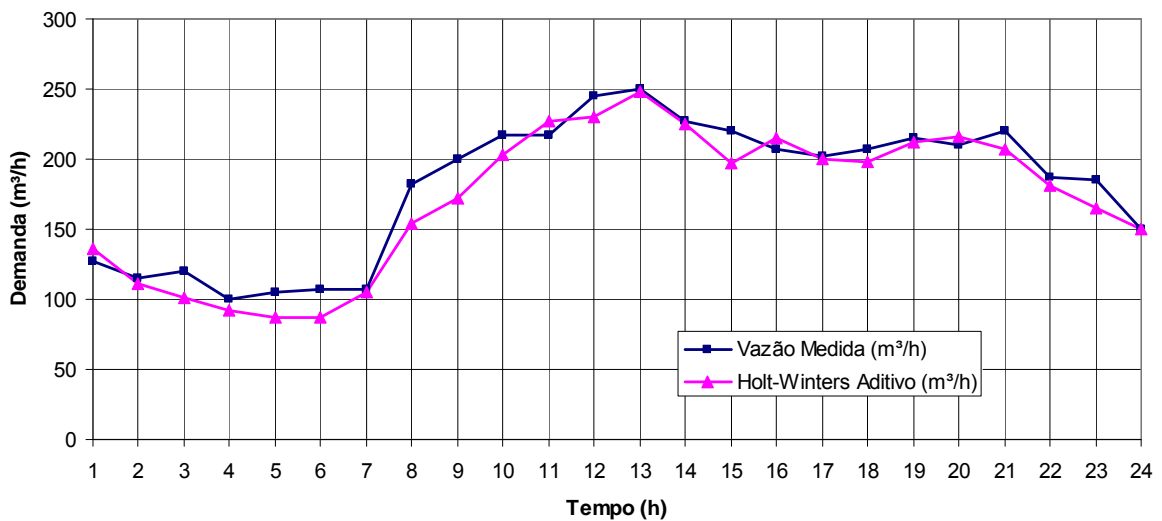


Figura 7-29 - Gráfico para o Período de Previsão do Modelo de Holt-Winters Aditivo para demanda horária.

Tabela 7-24 - Resultado de Erros do Modelo de Holt-Winters Aditivo para o período de previsão.

α	β	γ	Pearson	R ²	MAE	MSE	MAPE
0,322	0,001	0,999	0,98	0,95	11,16	192,59	6,79%

Assim como para o caso dos dados de demanda diária na aplicação deste modelo, os indicadores de erros MAE, MSE e MAPE do período de previsão, também apresentaram bons resultados, melhores que do período de ajuste, conforme a Tabela 7-24.

7.2.4. Modelo de Holt-Winters Multiplicativo

No modelo de Holt-Winters Multiplicativo para demandas horárias, as constantes de suavização de nível, tendência e sazonalidade calculadas foram: nível $\alpha=0,080$; tendência $\beta=0,001$ e sazonalidade $\gamma=0,745$.

Igualmente ao ocorrido com os modelos de Holt-Winters Aditivo e Multiplicativo para a demanda diária, o gráfico de ajuste das demandas horárias pelo

Modelo de Holt-Winters Multiplicativo (Figura 7-30) assemelha-se ao do modelo de Holt-Winters Aditivo (Figura 7-28):

A análise dos erros do Modelo de Holt-Winters Multiplicativo para a demanda horária está apresentada na Tabela 7-25.

Figura 7-30 - Gráfico de ajuste do Modelo de Holt-Winters Multiplicativo para demanda horária




Tabela 7-25 - Análise de Erros do Modelo de Holt-Winters Multiplicativo para o período de ajuste horário.

α	β	γ	Pearson	R^2	MAE	MSE	MAPE
0,080	0,001	0,745	0,92	0,86	16,92	496,96	9,87%

Como já observado para os dados de demanda diária, o modelo de Holt-Winters Multiplicativo por ser um modelo análogo ao modelo aditivo e, praticamente, não apresentar aumento de amplitude na série de ajuste, apresentou valores de erros muito semelhantes ao do Modelo de Holt-Winters Aditivo.

O modelo multiplicativo para o período de previsão assemelhou-se graficamente ao modelo aditivo com ligeiro aumento de amplitude, conforme a Figura 7-31.

Os erros do modelo multiplicativo foram minimizados em relação ao modelo aditivo com leve melhora dos erros, conforme Tabela 7-26.

Figura 7-31 - Gráfico para o Período de Previsão do Modelo de Holt-Winters Multiplicativo horário




Tabela 7-26 - Análise de Erros do Modelo de Holt-Winters Multiplicativo para o período de previsão.

Alfa	Beta	Gama	Pearson	R ²	MAE	MSE	MAPE
0,080	0,001	0,745	0,98	0,95	9,94	145,95	5,79%

7.2.5. Modelo de Box e Jenkins e Análise de FAC e FACP

Para a determinação do modelo mais provável de Box e Jenkins, foram analisadas as funções de autocorrelação (FAC) e função de autocorrelação parcial (FACP).

As Figuras 7-32 e 7-33 apresentam, respectivamente, o gráfico das funções de autocorrelação FAC e autocorrelação parcial FACP para os dados de demanda horária do estudo de caso.

Pela análise da FAC, observa-se a sazonalidade de um período completo de 24 eventos. Portanto, o valor de S do modelo ARIMA sazonal é 24.

Figura 7-32 – Função de Autocorrelação para dados horários de demanda com limite de significância de 95%






Figura 7-33 – Função de Autocorrelação Parcial para dados horários de demanda com limite de significância de 95%



O gráfico da Figura 7-34 permite a visualização da evolução da série com relação à média dos dados e indica que a série é praticamente estacionária, portanto a ordem $d=0$. A sazonalidade do modelo horário é diária, portanto, com ordem $D=1$ e sazonalidade S igual a 24, também identificado pela FAC visualmente no gráfico.

Figura 7-34 – Evolução da Série Temporal de demanda horária com relação à Média e Tendência Linear



Pela análise de FAC e FACP, ambas apresentam três valores inicialmente fora do intervalo de confiança, portanto a ordem máxima de P e Q é 3. Portanto, o modelo ARIMA sazonal inicial com ordem $(p,d,q) \times (P,D,Q)_S$ é dado por SARIMA $(1,0,1) \times (3,1,3)_{24}$.

A Tabela 7-27 apresenta os resultados de algumas ordens de $(p,d,q) \times (P,D,Q)_S$ para dados de demanda horária. O modelo SARIMA $(1,0,1) \times (1,1,2)_{24}$ superou o modelo provável, SARIMA $(1,0,1) \times (3,1,3)_{24}$, na fase de ajuste e foi empregado no período de previsão.

O gráfico para o melhor resultado do modelo de Box e Jenkins (SARIMA $(1,0,1) \times (1,1,2)_{24}$) para dados de demanda horária, no período de ajuste, é mostrado na Figura 7-35, enquanto para o período de previsão é apresentado na Figura 7.36.

Tabela 7-27 - Resultados das ordens SARIMA (p,d,q)x(P,D,Q)S para dados horários.

Ordem	Pearson	R ²	MAE	MSE	MAPE
(1,0,1)x(1,1,2) ₂₄	0,95	0,90	14,10	316,64	8,43%
(1,0,1)x(2,1,1) ₂₄	0,93	0,86	15,22	436,08	8,88%
(1,0,1)x(1,1,3) ₂₄	0,95	0,90	15,19	347,22	9,15%
(1,0,1)x(2,1,3) ₂₄	0,93	0,86	15,98	454,42	9,54%
(0,0,1)x(3,1,3) ₂₄	0,87	0,75	24,00	879,54	15,10%
(1,0,0)x(3,1,3) ₂₄	0,83	0,70	26,38	1073,25	16,26%
(1,0,1)x(3,1,3) ₂₄	0,83	0,69	26,65	1092,80	16,34%
(1,1,1)x(3,1,3) ₂₄	0,83	0,69	37,02	1870,46	23,43%

Figura 7-35 - Gráfico de Ajuste do Modelo de Box-Jenkins - ARIMA Sazonal para Demanda Horária.





Figura 7-36 - Gráfico para o Período de Previsão do Modelo de Box e Jenkins (SARIMA (1,0,1)x(1,1,2)24).



A Tabela 7-28 apresenta os resultados da análise de erros do Modelo de Box e Jenkins para o período de previsão horária. Os erros MAE, MSE e MAPE da fase de previsão apresentaram-se com valores menores que os do período de ajuste, igualmente aos modelos anteriores, inclusive, os valores de correlação e determinação apresentaram valores significativos.


Tabela 7-28 - Análise de Erros do Modelo de Box e Jenkins para o período de previsão horária

Ordem	Pearson	R ²	MAE	MSE	MAPE
(1,0,1)x(1,1,2) ₂₄	0,98	0,96	10,40	167,10	5,79%

7.2.6. Modelo Híbrido de Médias Móveis e Regressão Linear Múltipla Stepwise

Para a previsão de demanda de séries horárias, o modelo de Regressão Linear Múltipla não se mostra um modelo adequado visto que as demandas horárias não obedecem um modelo linear de comportamento. Para comprovar tal afirmação, um modelo de regressão linear foi calculado e seu gráfico plotado na Figura 7-37 e a fórmula encontrada apresentada na Equação 7.5.

Figura 7-37 - Gráfico de Ajuste do Modelo de Regressão Linear para Demanda Horária.



$$Demanda = 181 + 4,59TempMéd - 1,32Umid + 5,34Pr ecip + 15,7Rajada - 22,8Vento \quad (7.5)$$

Uma maneira simples para compatibilização de dados não lineares para o cálculo da Regressão Linear Múltipla é a utilização de Médias Móveis como uma das variáveis preditoras.

Para este estudo, foram vinculados dados horários de temperatura média (°C), umidade (%), precipitação (mm), velocidade da rajada de vento (m/s) e velocidade do vento (m/s). A relevância de cada variável preditora foi determinada pelo método *Stepwise*. O gráfico da Figura 7-38 exibe o grau de importância, de 0 a 1, das variáveis independentes com relação à demanda:

O critério empregado para a admissão das variáveis foi possuir p-valor menor que 0,05. Sob esta condição, a variável pluviosidade (p-valor=0,89) foi desclassificada para a predição do modelo. Com a aplicação do método *Stepwise* para definir as variáveis, a Equação 7.5 passou a ter a configuração apresentada na Equação 7.6, cujos resultados da sua aplicação mostrados na Figura 7.39.

$$Demanda = 59,8 + 0,82MédiaMóvel - 0,105TempMéd - 0,271Umid + 4,4Rajada - 8,28Vento \quad (7.6)$$

Figura 7-38 - Gráfico de importância das variáveis preditoras





Figura 7-39 - Gráfico de Ajuste do Modelo Híbrido de Regressão Múltipla para Demanda Horária.



Os valores dos erros e dos coeficientes de correlação e determinação do modelo híbrido de Médias Móveis e Regressão Linear Múltipla são mostrados na Tabela 7-29.

Tabela 7-29 - Análise de Erros do Modelo Híbrido de Médias Móveis e Regressão Linear Múltipla para o período de ajuste.

Pearson	R²	MAE	MSE	MAPE
0,94	0,89	15,37	364,93	9,23%

A Figura 7-40 apresenta a configuração gráfica do período de previsão e a Tabela 7-30 apresenta os resultados dos erros encontrados. O período de previsão, neste caso, apresentou erros maiores que o período de ajuste.

Figura 7-40 - Gráfico para o Período de Previsão Horária do Modelo Híbrido de Médias Móveis e Regressão Linear Múltipla.




Tabela 7-30 - Análise de Erros do Modelo de Regressão Linear Múltipla para o período de previsão.


Pearson	R²	MAE	MSE	MAPE
0,91	0,82	16,53	460,03	10,08%

7.2.7. Redes Neurais Artificiais MLP-BP

Utilizando-se as mesmas variáveis encontradas pelo método Stepwise e com Médias Móveis, o modelo de Redes Neurais Artificiais Multilayer Perceptron com algoritmo Backpropagation MLP-BP foi aplicada para a previsão de demanda horária para o estudo de caso deste trabalho.

A melhor topologia de RNA MLP-BP apresentou quatro camadas de entrada, duas camadas ocultas com 10 (BP1) e 6 (BP2) neurônios e uma camada de saída. A BP1 utilizou 500 épocas de treinamento com taxa de aprendizagem de 0,1 e a BP2 empregou 1000 épocas de treinamento e igual taxa de aprendizagem (0,1). A Figura 7-41 esquematiza a arquitetura da rede MLP-BP utilizada.

Figura 7-41 – Topologia da Rede Neural Artificial MLP-BP 4-10-6-1.



O resultado gráfico da previsão de demanda horária por Redes Neurais Artificiais Multilayer Perceptron com algoritmo Backpropagation está demonstrada na Figura 7-42.

Igualmente aos modelos diários de previsão, a RNA MLP-BP utilizada proporcionou resultados de previsão mais próximos da demanda real medida que os demais modelos estudados até agora. A Tabela 7-31 apresenta o resultado de erros do modelo RNA MLP-BP para o período de ajuste para dados horários:

Figura 7-42 - Gráfico de Ajuste do Modelo de Rede Neural Artificial MLP Backpropagation para Demanda Diária.




Tabela 7-31 - Resultado de Erros do Modelo de Rede Neural Artificial MLP Backpropagation para o período de ajuste horário.

Pearson	R²	MAE	MSE	MAPE
0,95	0,91	13,3575	308,5	7,87%

Na Figura 7-43 é mostrado o resultado do ajuste para o período de previsão usando a RNA MLP-BP e na Tabela 7-32 são apresentados o resultados das análises de erros.

Assim como no modelo diário, o modelo RNA MLP-BP, não foi o modelo de melhor eficiência na previsão, opostamente ao encontrado no período de ajuste.

Figura 7-43 - Gráfico para o Período de Previsão Horária do Modelo RNA MLP-BP.




Tabela 7-32 – Resultado de Erros do Modelo de Rede Neural Artificial MLP Backpropagation para o período de previsão horária.


Pearson	R²	MAE	MSE	MAPE
0,91	0,83	18,21	553,75	10,68%

7.2.8. Redes Neurais Artificiais RBF

Para completar o estudo de previsão de demanda horária, o Modelo de Redes Neurais Artificiais de Funções de Base Radial RBF foram pesquisados para a previsão de demanda horária.

A arquitetura da RNA RBF estudada possui 2 neurônios de entrada, 7 neurônios intermediários e 1 neurônio de saída. Sua configuração está demonstrada na Figura 7-44.

Figura 7-44 - Topologia da Rede Neural Artificial RBF 2-7-1.



A Figura 7-45 apresenta graficamente o resultado do ajuste realizado para a RNA RBF e a análise de erros da fase de ajuste do modelo RNA RBF está demonstrado na Tabela 7-33.

Figura 7-45 - Gráfico de Ajuste do Modelo de Rede Neural Artificial RBF para Demanda Horária.

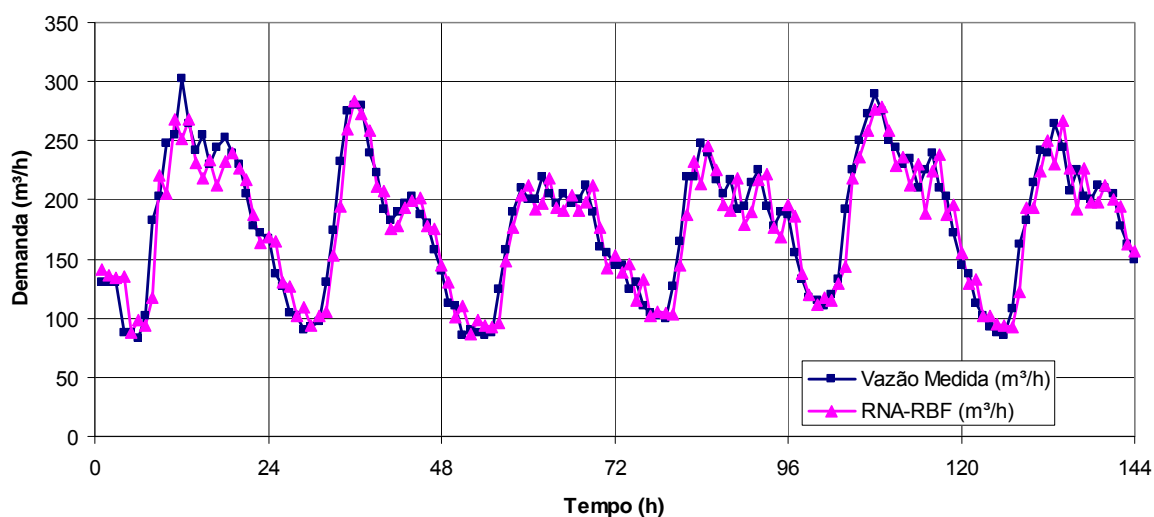


Tabela 7-33 - Análise de Erros do Modelo de Rede Neural Artificial RBF para o período de ajuste horário.

Pearson	R²	MAE	MSE	MAPE
0,94	0,89	14,81	357,86	8,70%

Empregando-se a mesma configuração da RNA RBF do período de ajuste, foi realizada a previsão do período seguinte de 24 horas. A Figura 7-48 proporciona a visualização do gráfico da previsão de demanda de abastecimento de água através do modelo de Redes Neurais Artificiais por meio do algoritmo de Função de Base Radial – RNA RBF.

A Tabela 7-34 traz a análise de erros do modelo de Redes Neurais Artificiais RBF para o período de previsão.

Figura 7-44 - Gráfico para o Período de Previsão horária do Modelo RNA RBF.




Tabela 7-34 - Análise de Erros do Modelo de Rede Neural Artificial RBF para o período de previsão horária.

Pearson	R²	MAE	MSE	MAPE
0,91	0,82	14,56	426,19	8,68%

7.3 COMPARAÇÃO DOS RESULTADOS

Após o estudo caso a caso dos modelos de previsão de demanda de abastecimento de água diários e horários, faz-se necessária a comparação dos resultados obtidos para verificação da desempenho de cada modelo.

Cabe salientar que os modelos limitaram-se ao período de trabalho de cada estudo de caso. Em outra época e na mesma abrangência física do local estudado, outros resultados poderão surgir devido à permanente dinâmica envolvida no abastecimento de água.

7.3.1 Resultados de Demandas Diárias

A eficiência dos modelos de previsão de demanda diária foi calculada em dois períodos: de ajuste (passado) e previsão (futuro). A Tabela 7-35 classifica os 10 modelos quanto ao ajuste diário:

Tabela 7-35 - Classificação da eficiência dos modelos no período de ajuste diário.

Classif.	Modelo	Pearson	R ²	MAE	MSE	MAPE
1	RNA RBF	0,71	0,51	140,23	34.468,78	3,34%
2	RNA MLP-BP	0,70	0,50	140,85	35.245,54	3,36%
3	Híbrido MM-Regressão	0,67	0,44	151,07	39.050,44	3,59%
4	Regress. Lin. Múlt.	0,57	0,32	169,37	47.313,77	4,02%
5	H-W Multiplicativo	0,47	0,22	184,61	55.262,77	4,44%
6	H-W Aditivo	-0,39	0,22	184,99	55.089,74	4,45%
7	Suav.Exp.Simples	0,26	0,07	217,00	74.228,68	5,21%
8	Suav.Exp.Dupla	0,26	0,07	216,97	74.282,99	5,21%
9	Médias Móveis	0,32	0,10	218,84	84.775,73	5,28%
10	S-ARIMA	-0,09	0,01	237,28	89.538,04	5,69%

Nota-se que os dois modelos de Redes Neurais Artificiais sobressaíram-se sobre os demais modelos. O modelo Híbrido de Médias Móveis e Regressão Linear Múltipla seguiram logo atrás dos modelos de RNA, potencializando as qualidades dos dois padrões integrantes do modelo híbrido. O

modelo ARIMA Sazonal não apresentou bom desempenho no ajuste de demandas diárias neste estudo de caso.

Completando o estudo de demandas diárias de abastecimento de água, realizou-se a categorização de desempenho na fase de previsão diária, constantes na Tabela 7-36.

Tabela 7-36 - Classificação da eficiência dos modelos no período de previsão diária.

Classif.	Modelo	Pearson	R²	MAE	MSE	MAPE
1	Regress. Lin. Múlt.	0,59	0,35	112,24	21.836,59	2,71%
2	H-W Multiplicativo	0,68	0,46	115,09	21.804,63	2,79%
3	H-W Aditivo	0,67	0,45	117,03	22.338,97	2,84%
4	RNA RBF	0,39	0,15	125,96	29.088,77	3,00%
5	RNA MLP-BP	0,37	0,13	134,48	28.688,63	3,22%
6	Híbrido MM-Regressão	0,41	0,17	138,24	32.272,38	3,31%
7	Suav.Exp.Simples	0,20	0,04	147,59	36.974,51	3,59%
8	Suav.Exp.Dupla	0,75	0,56	148,58	37.030,31	3,61%
9	S-ARIMA	0,0003	0,02	155,10	43.030,37	3,74%
10	Médias Móveis	0,05	0,003	161,71	54.663,79	3,96%

A Regressão Linear Múltipla mostrou-se como um bom modelo de previsão, mantendo os valores dos coeficientes de determinação e correlação atingidos na fase de ajuste. Pela análise de erros, a Regressão Linear Múltipla minimizou os erros da fase de ajuste, proporcionando o menor erro absoluto, MAE, e percentual, MAPE, dos modelos de previsão diária.

Os modelos de Holt-Winters apresentaram boa performance para previsão, permanecendo praticamente empatados, classificando-se como segundo e terceiro modelos mais precisos. O modelo multiplicativo mostrou-se ligeiramente superior ao modelo aditivo nas fases de ajuste e previsão.

Os modelos de RNA continuaram proporcionando o mesmo padrão de erros, mostrando ligeira melhora, apresentando-se como modelos mais estáveis, assim como o modelo Híbrido de Médias Móveis e Regressão Linear Múltipla.

Já os modelos de Suavização Exponencial, ARIMA Sazonal e de Médias Móveis não apresentaram o mesmo desempenho dos demais modelos nas etapas de ajuste e previsão.

7.3.2 Resultados de Demandas Horárias

Ao contrário dos dados dos modelos de demanda diária, que apresentam um padrão linearizado, os dados de demandas horárias, por não apresentarem o mesmo padrão linear, não se adequam a alguns modelos (Suavização Exponencial Simples, Suavização Exponencial Dupla e Regressão Linear Múltipla).

Para uma tentativa de linearização das demandas horárias para a sua aplicação ao modelo de Regressão Linear Múltipla, foi acrescentado ao estudo um modelo Híbrido de Médias Móveis e Regressão Linear Múltipla.

A Tabela 7-37 apresenta a classificação obtida através do estudo de cada modelo sobre as demandas de abastecimento de água horárias do estudo de caso.

Tabela 7-37 - Classificação da eficiência dos modelos no período de ajuste horário.

Classif.	Modelo	Pearson	R ²	MAE	MSE	MAPE
1	RNA MLP-BP	0,95	0,91	13,36	308,54	7,87%
2	S-ARIMA	0,95	0,90	14,10	316,64	8,43%
3	RNA RBF	0,94	0,89	14,81	357,86	8,70%
4	Híbrido MM-Regressão	0,94	0,89	15,37	364,93	9,23%
5	Médias Móveis	0,94	0,88	16,18	431,78	9,38%
6	H-W Aditivo	0,93	0,86	17,08	501,94	9,46%
7	H-W Multiplicativo	0,92	0,86	16,92	496,96	9,87%

Assim como nos modelos diários de previsão, os modelos de Redes Neurais Artificiais também sobressaíram-se na fase de ajuste. Destaca-se também que o modelo de ARIMA Sazonal, opostamente ao ocorrido com os modelos diários, apresentou-se como um modelo de maior estabilidade e precisão no caso das demandas horárias.

A Rede Neural Artificial Multilayer Perceptron com a utilização do algoritmo Backpropagation – RNA MLP-BP, predominou sobre os outros modelos apresentando os melhores resultados de erros e coeficientes de determinação e correlação.

Já os modelos de Holt-Winters apareceram com menor desempenho na fase de ajuste das demandas horárias.

Finalmente, a Tabela 7-38 traz a eficiência dos modelos no período futuro de previsão horária:

Tabela 7-38 - Classificação da eficiência dos modelos no período de previsão horária.

Classif.	Modelo	Pearson	R²	MAE	MSE	MAPE
1	H-W Multiplicativo	0,98	0,95	9,94	145,95	5,79%
2	S-ARIMA	0,98	0,96	10,40	167,10	5,79%
3	H-W Aditivo	0,98	0,95	11,16	192,59	6,79%
4	RNA RBF	0,91	0,82	14,56	426,19	8,68%
5	Médias Móveis	0,90	0,82	14,79	474,33	8,71%
6	Híbrido MM-Regressão	0,91	0,82	16,53	460,03	10,08%
7	RNA MLP-BP	0,91	0,83	18,21	553,75	10,68%

De forma inusitada, o modelo de Holt-Winters Multiplicativo classificado como último modelo na categorização do período de ajuste, apresentou os melhores resultados na fase futura de previsão. Ao contrário, as Redes Neurais Artificiais MLP-BP, que foi o modelo mais eficiente na fase de ajuste, apresentou o pior desempenho na fase de previsão.

O modelo de ARIMA Sazonal mostrou-se estável nos dois períodos de estudo (ajuste e previsão), demonstrando adequação à previsão de demandas horárias de abastecimento de água.

8. CONCLUSÃO

O estudo desenvolvido neste trabalho buscou aplicar a previsão de demanda de abastecimento de água em séries diárias e horárias, usando os dados da zona alta da área de abastecimento do Centro de Reserva Maria Lúcia do Município de Londrina como estudo de caso.

Os modelos de séries temporais tiveram bons resultados na previsão de ajustes horários com os modelos de ARIMA Sazonal e Holt-Winters Multiplicativo. No estudo de demandas diárias, os modelos de séries temporais destacaram-se na fase de previsão.

A previsão de demanda de abastecimento de água trabalhado no estudo de caso apresentou a Regressão Linear Múltipla como o melhor resultado em previsão de demandas diárias e Holt-Winters Multiplicativo para as demandas horárias. Outro ponto importante apresentado neste trabalho foi a introdução do fator de aproximação para médias móveis.

Para as demandas diárias, as seguintes variáveis, Temperatura Mínima, Vento e Média Móvel obtiveram melhores resultados para correlação de ajuste, já para as demandas horárias, as variáveis de Média Móvel, Temperatura Média, Umidade do Ar, Velocidade da Rajada e Velocidade do Vento concluíram os melhores resultados de ajuste.

E os modelos de inteligência artificial, através dos modelos de Redes Neurais Artificiais apontaram-se como bons modelos de ajuste. A melhor topologia encontrada para as redes MLP-BP e RBF para as demandas diárias e horárias seguiram as seguintes configurações: RNA MLP-BP 3-15-11-1 (demanda diária), RNA RBF 3-7-1 (demanda diária), MLP-BP 4-10-6-1 (demanda horária) e RBF 2-7-1 (demanda horária).

O modelo híbrido permitiu a realização de previsões com a utilização de Regressão Linear Múltipla para os dados horários de demanda, mantendo um desempenho em torno da média dos demais modelos. Como se trata de um modelo de fácil compreensão, a introdução deste modelo neste trabalho contribuiu para facilitar a previsão de demandas diárias e horárias.

A partir do diagnóstico realizado pela comparação dos modelos de previsão, conclui-se que não existe um modelo ótimo de ajuste e previsão, embora alguns modelos tenham-se evidenciado em relação a outros.

O maior entendimento do comportamento da demanda de abastecimento de água proporciona subsídio para aperfeiçoar as condições de controle da operação dos sistemas de abastecimento, avaliando um adequado planejamento do futuro das cidades para garantir a sustentabilidade ambiental urbana.

9. REFERÊNCIAS BIBLIOGRÁFICAS

ABNT – ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS; **NBR 12211 – Estudos de concepção de sistemas públicos de abastecimento de água.** Rio de Janeiro: ABNT, 1992.

AMARAL, A. M. P.; SHIROTA, R. Consumo de água tratada: uma aplicação de modelos de séries temporais em Piracicaba. In.: XLI Congresso Brasileiro Da Sober, Juiz de Fora. **Anais...** Juiz de Fora, 2003.

AN, A.; SHAN, N.; CHAN, C.; CERCONI, N.; ZIARCO W. Discovering rules for water demand prediction: an enhanced rough-set approach. **Engineering Applications of Artificial Intelligence**, v. 9, n. 6, p. 645-653, 1996.

AZEVEDO, F. M.; BRASIL, L. M.; OLIVEIRA, R.C. L. **Redes Neurais com Aplicações em Controle e em Sistemas Especialistas.** Visualbooks, Florianópolis, 2000.

AZEVEDO, F.; CARVALHO, L. R.; GRINBERG, L. T.; FARFEL, J. M.; FERRETTI, R.; LEITE, R.; JACOB FILHO, W.; LENT, R.; HERCULANO-HOUZEL, S.. Equal numbers of neuronal and nonneuronal cells make the human brain an isometrically scaled-up primate brain. **Journal of Comparative Neurology**, v. 513, p. 532-541, 2009.

BABBITT, H. E.; DOLAND, J. J.; CLEASBY, J. L. **Abastecimento de Água.** São Paulo: Editora Edgard Blücher, 1973.

BARBASSA, A. P.; SILVA, J. B. da. Modelagem da demanda de água de abastecimento para a cidade de Pirassununga. In: 6a. Jornada Científica da UFSCar. **Anais...**, v. CD-ROM. p. 1365-1366, São Carlos, 2005.

BILLINGS, R. B.; JONES, C. V. **Forecasting Urban Water Demand.** 2ª ed. Denver: AWWA - American Water Works Association, 2008.

BOLZERN, P.; FRONZA, P. B.; BRUSASCA, G. Temperature effects on the winter daily electric load. **American meteorological society**, Boston, v. 21, p. 241-243, fev. 1982.

BORGES, V. M. N. A. **Acoplamento de um modelo de previsão de demanda de água a um modelo simulador em tempo real – estudo de caso: Sistema adutor metropolitano de São Paulo.** Dissertação (Mestrado em Engenharia Hidráulica). Escola Politécnica da Universidade de São Paulo, São Paulo, 2003.

BRAGA, A. de P.; CARVALHO, A. C. P. de L. F.; LUDEMIR, T. B. **Redes Neurais Artificiais: teoria e aplicações.** 1ª ed. Editora LTC, Rio de Janeiro, 2000.

DEPEXE, M. D.; FREIRE, F. J. A.; VIANNA, E. F. Proposta de gráfico de controle com limites flutuantes como ferramenta de auxílio no controle e programação da produção da ETA. 25º Congresso brasileiro de engenharia sanitária e ambiental. **Anais...** Recife, 2009.

DETONI, T. L.; DONDONI, P. C. A escassez da água: um olhar global sobre a sustentabilidade e a consciência acadêmica. **Revista do Centro de Ciências Administrativas**, Fortaleza, v. 14, n. 2, p. 191-204, dez. 2008.

DUBE, E.; ZAAG, P. Analysing water use patterns for demand management: the case of the city of Masvingo, Zimbabwe. **Physics and Chemistry of the Earth**. v.28, p. 805-815, 2003.

FALKENBERG, A. V. **Previsão de consumo de água em curto prazo**. Dissertação (Mestrado em Métodos Numéricos em Engenharia). Universidade Federal do Paraná, Curitiba, 2005.

FARIA, E. L.; ALBUQUERQUE M. P.; ALFONSO J. L. G.; CAVALCANTE J. T. P. **Previsão de Séries Temporais utilizando Métodos Estatísticos**. Centro Brasileiro de Pesquisas Físicas, Rio de Janeiro, 2008.

FIRAT, M.; TURAN, M. E.; YURDUSEV, M. A. Comparative analysis of fuzzy inference systems for water consumption time series prediction. **Journal of Hidrology**, v. 374, p. 235-241, 2009.

FORMIGA, K. T. M.; CHAUDHRY, F. H. Modelos de análise hidráulica de água considerando demanda dirigida pela pressão e vazamentos. **Revista Engenharia Sanitária e Ambiental**. v. 13, nº 2, p. 153-162, abr/jun 2008.

GATO, S.; JAYASURIYA, N.; ROBERTS, P. Temperature and rainfall thresholds for base use urban water demand modelling. **Journal of Hidrology**, v. 337, p. 364-376, 2007.

GOMES, H. P. **Eficiência hidráulica e energética em saneamento – análise econômica de projetos**. 2 ed. João Pessoa: Editora Universitária – UFPB, 2009.

GONÇALVES, F. **Excel Avançado 2003/2007 Forecast Análise e Previsão de Demanda**. Editora Ciência Moderna. Rio de Janeiro, 2007.

GUIZELLAOUI, S.; DJEBBAR, K. Prevision of the demand for water in the town of Constantine at the horizon of the year 2020. **Dessalination**. v. 206, p. 457-464, 2007.

HAYKIN, S. **Redes Neurais: Principios e Práticas**. 2ª ed. Editora Bookman, Porto Alegre, 2002.

HERRERA M.; TORGO L.; IZQUIERDO J.; PEREZ-GARCÍA R. Predictive models for forecasting hourly urban water demand. **Journal of Hidrology**, v. 387, p. 141-150, 2010.

IBGE – Instituto Brasileiro de Geografia e Estatística. **Contagem da População 2007**. Rio de Janeiro, 2007.

KOVÁCS, Z. L. **Redes Neurais Artificiais: Fundamentos e Aplicações**. Edição Acadêmica, São Paulo, 1996.

LERTPALANGSUNTI, N.; CHAN, C. W. MASON, R. TONTIWACHWUTHIKUL P. A toolset for construction of hybrid intelligent forecasting systems: application for water demand prediction. **Artificial intelligence in Engineering**, v.13, p. 21-42, 1999.

MAKRIDAKIS, S., WHEELWRIGHT, S. C. & HYNDMAN, R. J. **Forecasting – methods and applications**, 3ª ed., John Wiley, New York. 1998.

MOCCELLIN, J. V. **Métodos de Previsão para Gestão de Estoques e Planejamento da Produção**. Escola de Engenharia de São Carlos – Departamento de Engenharia de Produção. São Carlos, 2003

MONTGOMERY, D. C.; RUNGER, G. C. **Estatística Aplicada e Probabilidade para Engenheiros**. 2ª ed. Editora LTC, Rio de Janeiro, 2003.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de séries temporais**. 2ª ed. Editora Edgard Blücher, São Paulo, 2006.

MUKHOPADHYAY, A.; AKBER, A.; AL-AWADI, E. Analysis of flashwater consumption patterns in the private residences of Kuwait. **Urban Water**, v. 3, p. 53-62, 2001.

ODAN, F. K.; **Previsão de demanda para sistema de abastecimento de água**. Dissertação (Mestrado em Hidráulica e Saneamento). Escola de Engenharia de São Carlos da Universidade de São Paulo, São Carlos, 2010.

ONU – Organização das Nações Unidas, Department of Economic and Social Affairs. **World Population Prospects: The 2006 Revision, Highlights**. Nova Iorque: Organização das Nações Unidas, 2007.

PELLEGRINI, F. R. **Metodologia para implementação de sistemas de Previsão de demanda**. Dissertação (mestrado em Engenharia da Produção). Universidade Federal do Rio Grande do Sul, Porto Alegre, 2000.

PEREIRA FILHO, A. J.; RODRIGUES, L. C. T.; GINEZ, W. G. Impacto das condições meteorológicas no consumo de água na região metropolitana de São Paulo. In: XIII Congresso Brasileiro de Meteorologia, 2004, Fortaleza. PUDN2 - Planejamento Urbano e Desastres Naturais. **Anais...** Brasília, 2004.

PERRONI, J. C. A. **Avaliação do consumo de energia elétrica para produção de água subterrânea – o caso do abastecimento público da cidade de São Carlos – SP**. Dissertação (Mestrado em Hidráulica e Saneamento). Escola de Engenharia de São Carlos da Universidade de São Paulo, São Carlos, 2005.

PROTOPAPAS, A. L.; KATCHAMART, S.; PLATONOVA, A. Weather effects on daily water use in New York city. **Journal of Hydrologic Engineering**, ASCE, vol. 5, n. 3, p. 332-338, 2000.

RICCE, W. S.; CARAMORI, P. H.; MORAIS, H.; SILVA, D. A. B., ATAÍDE, L. T. Análise de Tendências na Temperatura e Precipitação em Londrina, Estado do Paraná. In: XV Congresso Brasileiro de Agrometeorologia. **Anais...** Belo Horizonte, 2009.

RUIJS, A.; ZIMMERMANN, A.; van den BERG, M. Demand and distributional effects of water pricing policies. **Ecological Economics**. v. 66, p. 506-516, 2008.

SACHET, M. A. C. Prognóstico de demanda de água mensal para efeito de planejamento operacional da produção de água. In.: XI Simpósio Luso-Brasileiro de Engenharia Sanitária e Ambiental. **Anais...** Natal, 2004.

SCARE, R. F.; ZYLBERSZTAJN D. Escassez de água e mudança institucional: Análise da regulação dos recursos hídricos nos Estados brasileiros. **RAC Eletrônica**, Rio de Janeiro, v. 1, p. 31-46, jan./abr., 2007.

SILVA, A. P. G.; BÁGGIO, M. A.; MAÓSKI, A. Modelos estatísticos multivariados de previsão de volumes medido e faturado em uma empresa de saneamento. 25º Congresso brasileiro de engenharia sanitária e ambiental. **Anais...** Recife, 2009.

SILVA, C. S. **Previsão multivariada da demanda horária de água em sistemas urbanos de abastecimento**. Tese (Doutorado em Engenharia Civil na área de concentração de Recursos Hídricos). Universidade Estadual de Campinas, Campinas, 2003.

SILVA, L. N. de C. **Análise e Síntese de Estratégias de Aprendizado para Redes Neurais Artificiais**. Dissertação (Mestrado em Engenharia Elétrica). Universidade Estadual de Campinas, Campinas, 1998.

SILVA, R. T.; ROCHA, W. S. Caracterização da demanda urbana de água. **Programa nacional de combate ao desperdício de água – PNCDA**, Brasília, 1999.

SILVA, W. T. P. **Modelagem aplicada à determinação da quota *per capita* de água: um instrumental para gestão de recursos hídricos no município de Cuiabá**. Dissertação (Mestrados em Ciências Florestais e Ambientais). Universidade Federal de Mato Grosso, Cuiabá, 2008.

TRAUTWEIN JR., B. **Avaliação de métodos para previsão de consumo de água para curtíssimo prazo: um estudo de caso para a empresa de saneamento**. Dissertação (Mestrado em Engenharia de Produção e Sistemas). Pontifícia Universidade Católica do Paraná, Curitiba, 2004.

TSUTIYA. M.T. **Abastecimento de Água**. Departamento de Engenharia Hidráulica e Sanitária da Escola Politécnica da Universidade de São Paulo, 1ª ed, São Paulo, 2004.

VASÍLIO, V. A. A.; JORGE, L. M. M. Gestão de volumes horários como ferramenta no auxílio a produção otimizada de água potável. Simpósio de pós-graduação em Engenharia Urbana. **Anais...** Maringá, 2009.

YASSUDA, E. R.; NOGAMI, P. S. **Técnica de abastecimento e tratamento de água**. v. 1, 2ª ed. São Paulo, CETESB, 1976.

ZHOU, S. L.; McMAHON T. A.; WALTON A.; LEWIS, J. Forecasting daily urban water demand: a case study of Melbourne. **Journal of Hydrology**, v. 236, p. 153-164, 2000.

_____. Forecasting operational demand for an urban water supply zone. **Journal of Hidrology**, v.259, p. 189-202, 2002.

ANEXO A

DADOS DE DEMANDA DIÁRIA

Dia	Demanda	Tmax	Tmed	Tmin	Umid	Vento 10m	Precip	Insol	Radiaç	Nebul(9h)	Nebul(15h)	Nebul(21h)
seg, 01/12/08	4.300,00	33,90	19,20	26,50	51,00	180,00	0,00	11,80	575,00	0,00	7,00	2,00
ter, 02/12/08	3.876,00	28,60	18,80	21,20	78,70	198,00	8,80	3,00	249,00	10,00	10,00	6,00
qua, 03/12/08	4.089,00	26,60	15,40	20,20	53,50	228,00	3,30	12,30	633,00	2,00	7,00	0,00
qui, 04/12/08	4.204,00	28,50	14,40	21,80	45,20	227,00	0,00	11,00	589,00	4,00	7,00	4,00
sex, 05/12/08	4.419,00	29,20	15,80	23,20	47,20	197,00	0,00	12,00	615,00	7,00	8,00	2,00
sáb, 06/12/08	4.545,00	31,70	17,10	24,50	47,40	197,00	0,00	11,70	578,00	1,00	7,00	3,00
dom, 07/12/08	4.138,00	33,40	18,60	26,00	44,10	187,00	0,00	12,20	633,00	0,00	7,00	0,00
seg, 08/12/08	4.369,00	33,80	19,40	27,00	45,20	204,00	0,00	10,60	569,00	2,00	8,00	2,00
ter, 09/12/08	4.313,00	35,20	20,60	26,70	54,30	143,00	0,00	8,30	510,00	0,00	8,00	10,00
qua, 10/12/08	4.135,00	27,60	20,90	23,30	83,70	221,00	0,00	0,00	217,00	10,00	10,00	8,00
qui, 11/12/08	3.991,00	28,80	20,40	23,90	79,10	140,00	10,00	3,70	326,00	10,00	9,00	3,00
sex, 12/12/08	4.454,00	29,40	19,00	23,60	61,20	280,00	0,00	10,50	584,00	4,00	9,00	6,00
sáb, 13/12/08	4.483,00	28,70	17,50	23,20	51,20	382,00	0,00	9,60	597,00	9,00	5,00	5,00
dom, 14/12/08	4.073,00	30,50	16,50	23,80	48,10	306,00	0,00	11,70	627,00	4,00	3,00	2,00
seg, 15/12/08	4.008,00	25,80	18,80	21,80	79,30	202,00	0,00	5,00	337,00	9,00	8,00	4,00
ter, 16/12/08	3.934,00	27,40	17,80	21,80	81,90	170,00	15,50	6,60	423,00	10,00	10,00	4,00
qua, 17/12/08	4.042,00	27,80	17,80	21,70	76,20	199,00	5,80	10,00	467,00	7,00	10,00	0,00
qui, 18/12/08	4.190,00	30,10	17,40	23,90	59,20	228,00	2,00	12,00	630,00	5,00	7,00	0,00
sex, 19/12/08	4.473,00	31,40	18,20	24,50	51,00	239,00	0,00	12,50	619,00	0,00	6,00	0,00
sáb, 20/12/08	4.514,00	32,20	17,60	25,40	46,40	226,00	0,00	11,90	585,00	0,00	7,00	0,00
dom, 21/12/08	4.153,00	32,10	18,60	26,20	49,50	206,00	0,00	12,40	604,00	2,00	7,00	1,00
seg, 22/12/08	4.506,00	32,20	19,80	26,30	52,10	227,00	0,00	11,70	582,00	6,00	8,00	0,00
ter, 23/12/08	4.596,00	32,60	21,10	27,50	51,30	214,00	0,00	12,30	578,00	3,00	7,00	1,00
qua, 24/12/08	4.701,00	34,40	21,20	27,40	56,20	164,00	0,00	10,20	578,00	3,00	8,00	10,00
qui, 25/12/08	3.856,00	30,00	20,50	24,20	78,30	207,00	4,20	7,60	462,00	8,00	5,00	8,00
sex, 26/12/08	4.330,00	30,80	20,20	23,70	67,40	234,00	7,20	7,90	519,00	8,00	8,00	9,00
sáb, 27/12/08	4.150,00	26,20	16,40	21,50	68,40	360,00	16,80	4,30	429,00	10,00	9,00	0,00
dom, 28/12/08	4.066,00	31,20	17,10	25,10	55,30	304,00	0,00	12,50	639,00	0,00	7,00	0,00
seg, 29/12/08	4.561,00	33,80	20,00	27,10	56,10	121,00	0,00	9,50	513,00	0,00	8,00	0,00
ter, 30/12/08	4.502,00	35,50	21,40	26,70	63,40	150,00	0,00	8,50	524,00	2,00	9,00	10,00
qua, 31/12/08	4.568,00	31,60	21,60	24,80	78,80	243,00	13,80	5,40	458,00	9,00	7,00	10,00
qui, 01/01/09	3.794,00	29,50	20,00	24,30	76,40	182,00	4,80	5,90	447,00	9,00	9,00	4,00
sex, 02/01/09	3.941,00	24,50	20,60	21,70	95,00	162,00	0,00	0,00	121,00	10,00	10,00	9,00
sáb, 03/01/09	3.962,00	26,50	20,30	22,10	85,40	129,00	20,80	4,20	343,00	10,00	9,00	2,00
dom, 04/01/09	3.706,00	25,90	16,20	19,80	80,20	318,00	2,80	5,30	414,00	8,00	9,00	10,00
seg, 05/01/09	3.803,00	23,20	15,50	18,00	85,40	298,00	27,80	4,30	372,00	10,00	8,00	2,00
ter, 06/01/09	4.136,00	28,00	15,90	21,50	66,30	296,00	3,20	9,80	535,00	5,00	6,00	0,00
qua, 07/01/09	4.156,00	30,40	16,90	23,30	60,20	198,00	0,00	12,10	632,00	0,00	7,00	1,00
qui, 08/01/09	4.234,00	31,80	17,50	25,30	48,60	124,00	0,00	12,20	587,00	0,00	6,00	0,00
sex, 09/01/09	4.489,00	33,40	17,80	26,50	41,30	126,00	0,00	12,20	590,00	2,00	5,00	3,00
sáb, 10/01/09	4.484,00	32,20	20,00	25,50	62,30	219,00	0,10	11,10	560,00	3,00	7,00	10,00
dom, 11/01/09	3.909,00	24,60	18,80	21,60	84,20	257,00	13,00	2,00	263,00	10,00	9,00	4,00
seg, 12/01/09	4.356,00	31,70	18,80	25,90	64,70	173,00	0,20	10,60	530,00	2,00	8,00	2,00
ter, 13/01/09	4.302,00	32,80	21,20	25,50	75,10	117,00	0,00	6,40	454,00	9,00	10,00	9,00

Dia	Demanda	Tmax	Tmed	Tmin	Umid	Vento 10m	Precip	Insol	Radiaç	Nebul(9h)	Nebul(15h)	Nebul(21h)
qua, 14/01/09	4.175,00	32,00	20,00	25,10	69,40	163,00	0,40	3,70	371,00	9,00	4,00	9,00
qui, 15/01/09	4.071,00	26,80	20,30	23,30	82,30	197,00	7,80	0,30	280,00	10,00	10,00	3,00
sex, 16/01/09	4.271,00	27,60	20,20	23,20	90,20	114,00	0,00	1,20	287,00	9,00	10,00	9,00
sáb, 17/01/09	3.805,00	22,20	19,40	20,20	97,10	202,00	69,80	0,10	91,00	10,00	10,00	9,00
dom, 18/01/09	3.870,00	25,60	19,60	22,30	87,30	132,00	10,00	2,00	301,00	10,00	9,00	2,00
seg, 19/01/09	3.860,00	25,60	20,30	22,60	92,60	160,00	39,20	1,20	224,00	10,00	10,00	9,00
ter, 20/01/09	4.275,00	28,90	20,00	23,70	79,40	151,00	18,40	7,60	445,00	10,00	7,00	6,00
qua, 21/01/09	4.072,00	24,00	19,60	21,20	80,40	263,00	0,00	0,20	293,00	9,00	10,00	10,00
qui, 22/01/09	4.195,00	27,60	19,20	22,80	64,70	354,00	0,00	6,80	521,00	8,00	9,00	6,00
sex, 23/01/09	4.487,00	27,50	16,80	22,00	63,40	436,00	0,00	11,50	597,00	3,00	6,00	2,00
sáb, 24/01/09	4.553,00	27,80	17,20	23,20	65,30	436,00	0,00	7,50	444,00	3,00	8,00	4,00
dom, 25/01/09	4.156,00	27,80	20,80	23,20	84,00	395,00	0,00	3,70	300,00	10,00	7,00	8,00
seg, 26/01/09	4.041,00	22,60	20,80	21,70	96,30	308,00	11,60	0,00	163,00	10,00	10,00	9,00
ter, 27/01/09	4.184,00	25,00	19,80	21,90	91,00	279,00	32,00	1,80	298,00	10,00	9,00	9,00
qua, 28/01/09	3.955,00	27,00	20,40	22,70	93,20	212,00	7,60	1,60	252,00	10,00	9,00	10,00
qui, 29/01/09	4.385,00	27,80	21,20	22,90	86,20	170,00	9,20	4,20	350,00	10,00	8,00	4,00
sex, 30/01/09	4.655,00	29,60	20,50	24,80	77,20	223,00	0,60	6,10	423,00	10,00	6,00	6,00
sáb, 31/01/09	4.638,00	31,80	19,80	25,00	75,70	191,00	0,00	7,50	456,00	3,00	6,00	2,00
dom, 01/02/09	4.279,00	30,80	19,20	24,40	69,90	188,00	0,00	9,10	495,00	3,00	8,00	4,00
seg, 02/02/09	4.391,00	29,80	20,20	24,70	72,60	152,00	0,00	7,40	439,00	7,00	9,00	8,00
ter, 03/02/09	4.028,00	27,20	19,90	22,80	84,60	274,00	34,50	2,50	285,00	10,00	10,00	8,00
qua, 04/02/09	4.310,00	30,20	19,80	24,00	73,30	125,00	22,20	8,20	483,00	9,00	5,00	0,00
qui, 05/02/09	4.577,00	31,60	19,20	24,80	71,50	181,00	0,00	8,30	493,00	10,00	8,00	3,00
sex, 06/02/09	4.659,00	32,20	19,90	23,90	77,80	144,00	0,00	8,80	465,00	5,00	8,00	9,00
sáb, 07/02/09	4.560,00	31,60	20,40	24,20	82,90	136,00	0,70	2,40	313,00	9,00	9,00	6,00
dom, 08/02/09	4.301,00	30,20	20,80	25,40	79,30	107,00	3,80	3,70	326,00	10,00	10,00	10,00
seg, 09/02/09	4.536,00	32,00	22,00	25,20	79,80	105,00	0,00	4,40	361,00	10,00	10,00	10,00
ter, 10/02/09	4.447,00	29,80	21,60	25,30	77,50	172,00	18,80	3,70	384,00	10,00	7,00	0,00
qua, 11/02/09	4.179,00	28,80	21,80	24,00	92,20	192,00	0,10	1,30	213,00	10,00	9,00	10,00
qui, 12/02/09	4.375,00	30,00	20,20	24,40	77,10	152,00	23,10	8,50	452,00	4,00	8,00	8,00
sex, 13/02/09	4.412,00	27,00	19,40	22,70	66,10	260,00	0,40	9,40	472,00	9,00	9,00	0,00
sáb, 14/02/09	4.798,00	27,80	16,20	22,10	71,90	358,00	0,00	10,20	508,00	3,00	7,00	3,00
dom, 15/02/09	4.042,00	27,80	18,60	22,90	71,90	309,00	0,00	5,90	352,00	10,00	7,00	6,00
seg, 16/02/09	3.976,00	23,80	21,00	21,70	94,60	266,00	26,20	0,00	158,00	10,00	10,00	10,00
ter, 17/02/09	4.300,00	28,60	20,30	23,20	82,10	290,00	23,80	5,70	417,00	10,00	7,00	4,00
qua, 18/02/09	4.559,00	32,20	20,00	26,20	63,70	159,00	0,50	11,70	505,00	5,00	7,00	3,00
qui, 19/02/09	4.676,00	32,00	20,80	26,20	68,20	183,00	0,00	11,30	559,00	3,00	7,00	0,00
sex, 20/02/09	4.670,00	32,00	20,20	24,90	75,00	182,00	0,00	8,40	419,00	2,00	8,00	7,00
sáb, 21/02/09	4.636,00	31,00	20,30	25,30	68,90	120,00	24,80	6,60	376,00	3,00	10,00	4,00
dom, 22/02/09	4.159,00	33,90	21,20	27,30	63,00	114,00	0,00	10,10	490,00	3,00	7,00	0,00
seg, 23/02/09	4.370,00	32,80	21,80	24,80	86,10	127,00	0,00	6,60	348,00	3,00	10,00	10,00
ter, 24/02/09	4.108,00	31,00	20,00	23,70	81,20	131,00	19,10	7,50	447,00	9,00	7,00	10,00
qua, 25/02/09	4.036,00	26,80	19,00	22,30	89,20	197,00	32,80	0,60	263,00	10,00	8,00	10,00
qui, 26/02/09	4.074,00	28,80	20,30	23,50	81,10	252,00	22,80	3,10	271,00	10,00	7,00	7,00
sex, 27/02/09	4.173,00	28,40	21,20	23,60	87,60	155,00	3,70	1,50	241,00	10,00	7,00	10,00
sáb, 28/02/09	4.546,00	31,00	20,80	25,20	74,30	133,00	9,90	8,40	460,00	8,00	7,00	10,00
dom, 01/03/09	4.212,00	33,80	20,20	27,30	64,80	147,00	0,00	10,00	519,00	5,00	7,00	0,00
seg, 02/03/09	4.258,00	33,80	21,20	26,70	64,90	103,00	0,00	9,30	499,00	7,00	5,00	0,00
ter, 03/03/09	4.177,00	33,00	19,40	25,80	59,10	137,00	0,00	9,60	457,00	8,00	5,00	0,00
qua, 04/03/09	4.164,00	33,40	20,40	26,60	53,30	101,00	0,00	11,10	544,00	3,00	2,00	0,00

Dia	Demanda	Tmax	Tmed	Tmin	Umid	Vento 10m	Precip	Insol	Radiaç	Nebul(9h)	Nebul(15h)	Nebul(21h)
qui, 05/03/09	4.079,00	35,00	19,40	27,80	48,70	143,00	0,00	11,30	559,00	2,00	0,00	0,00
sex, 06/03/09	4.289,00	34,80	21,80	27,90	62,50	129,00	0,00	9,30	444,00	3,00	9,00	3,00
sáb, 07/03/09	4.416,00	32,40	21,20	24,50	86,10	168,00	0,70	7,00	359,00	3,00	10,00	8,00
dom, 08/03/09	3.215,00	31,40	19,60	22,90	82,20	143,00	16,60	5,80	330,00	2,00	9,00	10,00
seg, 09/03/09	4.105,00	30,00	17,40	23,80	71,80	182,00	25,50	8,90	466,00	6,00	6,00	3,00
ter, 10/03/09	3.953,00	29,40	20,40	23,00	84,90	113,00	0,00	3,10	296,00	10,00	7,00	10,00
qua, 11/03/09	4.102,00	25,40	20,40	22,70	86,60	171,00	31,30	1,70	228,00	10,00	7,00	8,00
qui, 12/03/09	4.047,00	27,40	21,20	23,10	91,90	108,00	1,20	4,30	317,00	9,00	10,00	10,00
sex, 13/03/09	4.251,00	28,50	20,40	23,50	83,10	128,00	26,80	3,80	349,00	10,00	8,00	7,00
sáb, 14/03/09	4.502,00	30,20	19,50	23,90	64,50	143,00	0,00	9,00	453,00	9,00	7,00	0,00
dom, 15/03/09	4.087,00	30,00	17,30	23,50	54,30	173,00	0,00	11,20	538,00	0,00	2,00	0,00
seg, 16/03/09	3.769,00	30,80	16,00	23,80	57,90	162,00	0,00	11,00	525,00	0,00	5,00	0,00
ter, 17/03/09	4.146,00	31,80	17,60	24,30	57,60	182,00	0,00	10,90	529,00	0,00	3,00	3,00
qua, 18/03/09	4.156,00	30,10	17,80	23,80	65,90	135,00	0,00	8,40	470,00	5,00	7,00	0,00
qui, 19/03/09	4.202,00	30,40	17,60	24,50	62,50	322,00	0,00	9,70	486,00	3,00	8,00	4,00
sex, 20/03/09	4.274,00	29,20	20,20	23,30	75,60	368,00	0,20	3,40	348,00	10,00	7,00	9,00
sáb, 21/03/09	4.351,00	25,40	20,30	22,20	86,20	175,00	0,20	0,20	219,00	9,00	9,00	4,00
dom, 22/03/09	4.052,00	28,50	19,50	23,20	77,80	140,00	0,00	5,80	372,00	9,00	7,00	7,00
seg, 23/03/09	4.230,00	30,60	19,40	24,70	64,50	180,00	0,00	10,80	483,00	0,00	6,00	0,00
ter, 24/03/09	4.198,00	31,40	18,90	24,80	57,90	203,00	0,00	10,20	487,00	0,00	6,00	3,00
qua, 25/03/09	4.228,00	30,20	18,00	23,40	61,70	268,00	0,00	10,70	492,00	3,00	8,00	0,00
qui, 26/03/09	4.364,00	30,60	18,00	23,90	61,60	312,00	0,00	8,00	463,00	9,00	6,00	0,00
sex, 27/03/09	4.542,00	30,40	19,20	24,20	68,00	229,00	0,00	5,90	399,00	7,00	8,00	8,00
sáb, 28/03/09	4.444,00	30,20	21,00	23,70	83,40	154,00	0,00	6,30	308,00	8,00	9,00	10,00

ANEXO B

DADOS DE DEMANDA HORÁRIA

Dia e Hora	DEMANDA	Média Móvel	Temperatura Média	Umidade Relativa	Precipitação	Velocidade da Rajada	Velocidade do Vento
01/04/2010 00:00	130,00	130,00	21,60	77,00	0,00	4,60	2,80
01/04/2010 01:00	130,00	130,00	20,60	83,40	0,00	4,50	3,00
01/04/2010 02:00	130,00	130,00	20,00	86,30	0,00	2,60	1,40
01/04/2010 03:00	87,50	130,00	20,10	84,90	0,00	4,10	2,90
01/04/2010 04:00	87,50	62,00	19,40	88,60	0,00	5,50	3,00
01/04/2010 05:00	82,50	87,50	19,40	88,60	0,00	5,70	3,80
01/04/2010 06:00	102,50	79,50	19,10	89,80	0,00	4,70	3,30
01/04/2010 07:00	182,50	114,50	18,70	90,90	0,00	2,50	1,80
01/04/2010 08:00	202,50	230,50	20,40	83,20	0,00	4,50	3,20
01/04/2010 09:00	247,50	214,50	21,80	76,50	0,00	7,20	4,70
01/04/2010 10:00	255,00	274,50	24,00	69,10	0,00	6,70	4,30
01/04/2010 11:00	302,50	259,50	26,00	61,70	0,00	6,20	3,60
01/04/2010 12:00	265,00	331,00	27,40	57,70	0,00	5,50	3,00
01/04/2010 13:00	242,50	242,50	28,60	53,40	0,00	6,60	3,00
01/04/2010 14:00	255,00	229,00	29,60	46,50	0,00	6,80	2,90
01/04/2010 15:00	230,00	262,50	29,80	46,80	0,00	6,20	2,20
01/04/2010 16:00	245,00	215,00	29,70	45,40	0,00	4,00	1,90
01/04/2010 17:00	252,50	254,00	28,90	49,10	0,00	5,40	2,20
01/04/2010 18:00	240,00	257,00	27,70	53,00	0,00	3,00	2,10
01/04/2010 19:00	230,00	232,50	26,10	59,30	0,00	3,40	2,20
01/04/2010 20:00	205,00	224,00	25,00	64,90	0,00	2,60	1,50
01/04/2010 21:00	177,50	190,00	24,60	66,50	0,00	3,20	2,50
01/04/2010 22:00	172,50	161,00	23,30	73,10	0,00	2,40	1,80
01/04/2010 23:00	167,50	169,50	22,40	78,30	0,00	4,20	3,00
02/04/2010 00:00	137,50	164,50	22,10	80,10	0,00	4,80	2,90
02/04/2010 01:00	127,50	119,50	22,20	80,20	0,00	6,20	4,60
02/04/2010 02:00	105,00	121,50	20,90	86,70	0,00	2,70	1,90
02/04/2010 03:00	102,50	91,50	20,20	88,00	0,00	3,30	2,20
02/04/2010 04:00	90,00	101,00	19,80	87,40	0,00	4,00	2,60
02/04/2010 05:00	92,50	82,50	19,00	91,20	0,00	2,90	1,90
02/04/2010 06:00	97,50	94,00	18,80	91,00	0,00	3,20	2,20
02/04/2010 07:00	130,00	100,50	18,40	92,40	0,00	3,00	2,20
02/04/2010 08:00	175,00	149,50	20,40	83,70	0,00	3,30	1,90
02/04/2010 09:00	232,50	202,00	22,10	76,90	0,00	3,90	2,30
02/04/2010 10:00	275,00	267,00	23,60	72,20	0,00	4,80	2,80
02/04/2010 11:00	280,00	300,50	24,30	71,50	0,00	4,90	2,80
02/04/2010 12:00	280,00	283,00	23,90	73,10	0,00	6,00	2,90
02/04/2010 13:00	240,00	280,00	22,20	84,80	0,00	5,70	3,30
02/04/2010 14:00	222,50	216,00	21,00	94,90	0,20	3,20	1,90
02/04/2010 15:00	192,50	212,00	20,90	96,70	0,20	3,70	2,10
02/04/2010 16:00	182,50	174,50	21,40	96,00	0,00	3,60	2,00
02/04/2010 17:00	190,00	176,50	21,80	94,60	0,00	2,80	1,70
02/04/2010 18:00	197,50	194,50	21,80	95,70	0,00	2,10	1,20
02/04/2010 19:00	202,50	202,00	21,10	98,80	0,00	2,40	1,80

Dia e Hora	DEMANDA	Média Móvel	Temperatura Média	Umidade Relativa	Precipitação	Velocidade da Rajada	Velocidade do Vento
02/04/2010 20:00	187,50	205,50	20,70	100,00	0,00	1,50	1,00
02/04/2010 21:00	180,00	178,50	20,50	100,20	0,00	1,50	1,00
02/04/2010 22:00	157,50	175,50	20,90	98,60	0,00	1,40	0,80
02/04/2010 23:00	140,00	144,00	20,80	99,80	0,00	1,70	1,00
03/04/2010 00:00	112,50	129,50	21,00	98,50	0,00	2,40	1,80
03/04/2010 01:00	110,00	96,00	20,80	99,20	0,00	2,30	1,60
03/04/2010 02:00	85,00	108,50	21,00	98,40	0,00	4,20	2,50
03/04/2010 03:00	90,00	70,00	21,10	97,00	0,00	4,50	2,50
03/04/2010 04:00	87,50	93,00	21,10	96,50	0,00	4,40	2,80
03/04/2010 05:00	85,00	86,00	20,90	97,20	0,00	4,00	2,60
03/04/2010 06:00	87,50	83,50	20,90	97,40	0,00	3,80	2,40
03/04/2010 07:00	125,00	89,00	20,70	98,30	0,60	4,50	2,60
03/04/2010 08:00	157,50	147,50	20,50	100,00	2,20	2,70	1,60
03/04/2010 09:00	190,00	177,00	20,30	100,20	11,60	4,90	3,20
03/04/2010 10:00	210,00	209,50	20,20	100,20	6,60	6,20	3,60
03/04/2010 11:00	200,00	222,00	20,10	100,20	3,00	6,40	3,80
03/04/2010 12:00	200,00	194,00	20,10	100,20	4,20	6,40	3,90
03/04/2010 13:00	220,00	200,00	20,30	100,20	0,40	5,20	2,80
03/04/2010 14:00	205,00	232,00	20,70	100,20	0,60	2,30	1,30
03/04/2010 15:00	197,50	196,00	21,00	100,20	0,00	4,50	2,60
03/04/2010 16:00	205,00	193,00	21,50	99,70	0,00	4,00	2,70
03/04/2010 17:00	197,50	209,50	21,20	99,90	0,00	3,30	2,30
03/04/2010 18:00	200,00	193,00	21,30	99,60	0,00	2,60	1,50
03/04/2010 19:00	212,50	201,50	21,20	99,60	0,00	3,90	2,50
03/04/2010 20:00	190,00	220,00	21,10	99,50	0,00	5,00	3,10
03/04/2010 21:00	160,00	176,50	21,20	99,50	0,00	3,00	2,20
03/04/2010 22:00	155,00	142,00	21,20	99,70	0,00	2,50	1,60
03/04/2010 23:00	145,00	152,00	21,10	99,90	0,00	2,40	1,80
04/04/2010 00:00	145,00	139,00	20,90	99,90	0,00	1,80	1,30
04/04/2010 01:00	125,00	145,00	20,60	99,90	0,00	2,20	1,70
04/04/2010 02:00	130,00	113,00	20,50	99,50	0,00	1,60	0,90
04/04/2010 03:00	110,00	133,00	20,70	99,90	0,00	1,10	0,40
04/04/2010 04:00	105,00	98,00	20,60	99,90	0,00	1,40	0,60
04/04/2010 05:00	102,50	102,00	20,30	100,20	1,20	3,00	1,80
04/04/2010 06:00	100,00	101,00	20,30	100,20	0,00	2,20	1,30
04/04/2010 07:00	127,50	98,50	20,30	100,10	0,00	1,30	0,60
04/04/2010 08:00	165,00	144,00	20,70	99,10	0,00	3,30	2,10
04/04/2010 09:00	220,00	187,50	21,30	98,50	0,00	2,00	1,20
04/04/2010 10:00	220,00	253,00	21,50	97,00	0,00	1,40	0,70
04/04/2010 11:00	247,50	220,00	22,50	93,40	0,00	1,60	0,70
04/04/2010 12:00	240,00	264,00	23,80	87,90	0,00	1,60	0,60
04/04/2010 13:00	217,50	235,50	25,10	79,00	0,00	3,00	1,30
04/04/2010 14:00	205,00	204,00	26,00	74,90	0,00	3,80	1,70
04/04/2010 15:00	217,50	197,50	26,50	72,40	0,00	2,70	1,50
04/04/2010 16:00	192,50	225,00	28,10	66,20	0,00	3,70	1,60
04/04/2010 17:00	195,00	177,50	27,90	65,70	0,00	4,80	1,80
04/04/2010 18:00	215,00	196,50	26,00	74,60	0,00	2,10	1,20
04/04/2010 19:00	225,00	227,00	24,80	74,80	0,00	1,80	1,10
04/04/2010 20:00	195,00	231,00	23,30	84,30	0,00	2,30	1,80

Dia e Hora	DEMANDA	Média Móvel	Temperatura Média	Umidade Relativa	Precipitação	Velocidade da Rajada	Velocidade do Vento
04/04/2010 21:00	177,50	177,00	23,20	86,80	0,00	1,70	1,30
04/04/2010 22:00	190,00	167,00	22,50	92,00	0,00	2,00	1,60
04/04/2010 23:00	187,50	197,50	22,20	93,80	0,00	5,00	2,20
05/04/2010 00:00	155,00	186,00	22,40	91,90	0,00	6,60	4,40
05/04/2010 01:00	132,50	135,50	21,90	92,20	0,00	5,10	3,30
05/04/2010 02:00	117,50	119,00	21,30	96,20	0,00	2,10	1,00
05/04/2010 03:00	115,00	108,50	21,20	94,30	0,00	3,00	2,00
05/04/2010 04:00	110,00	113,50	21,10	90,10	0,00	3,70	2,60
05/04/2010 05:00	120,00	107,00	21,30	86,20	0,00	4,70	3,20
05/04/2010 06:00	132,50	126,00	20,50	88,80	0,00	3,30	2,40
05/04/2010 07:00	192,50	140,00	20,60	86,90	0,00	3,30	2,20
05/04/2010 08:00	225,00	228,50	22,10	79,30	0,00	4,70	2,80
05/04/2010 09:00	250,00	244,50	23,20	74,30	0,00	5,80	3,30
05/04/2010 10:00	272,50	265,00	24,30	70,40	0,00	7,90	3,80
05/04/2010 11:00	290,00	286,00	24,90	67,10	0,00	6,30	4,10
05/04/2010 12:00	275,00	300,50	26,00	63,00	0,00	6,60	3,50
05/04/2010 13:00	250,00	266,00	26,00	63,20	0,00	5,90	3,10
05/04/2010 14:00	245,00	235,00	26,00	64,90	0,00	5,40	2,70
05/04/2010 15:00	230,00	242,00	26,10	65,10	0,00	6,60	3,80
05/04/2010 16:00	235,00	221,00	25,20	69,00	0,00	5,70	3,10
05/04/2010 17:00	210,00	238,00	24,40	71,20	0,00	7,30	4,30
05/04/2010 18:00	225,00	195,00	23,50	74,40	0,00	6,10	3,10
05/04/2010 19:00	240,00	234,00	22,40	76,10	0,00	6,90	3,20
05/04/2010 20:00	210,00	249,00	22,00	78,50	0,00	6,10	3,30
05/04/2010 21:00	202,50	192,00	21,20	82,10	0,00	8,30	4,70
05/04/2010 22:00	172,50	198,00	17,90	99,60	1,80	9,20	5,80
05/04/2010 23:00	145,00	154,50	16,30	99,80	0,00	9,50	5,80
06/04/2010 00:00	137,50	128,50	15,50	99,60	0,00	7,90	4,80
06/04/2010 01:00	112,50	133,00	15,20	100,00	2,40	5,40	3,40
06/04/2010 02:00	102,50	97,50	15,10	100,20	0,20	5,90	3,10
06/04/2010 03:00	92,50	96,50	15,30	100,20	0,00	3,80	2,40
06/04/2010 04:00	87,50	86,50	15,10	100,20	0,00	4,70	2,40
06/04/2010 05:00	85,00	84,50	14,70	98,60	0,20	7,60	4,90
06/04/2010 06:00	107,50	83,50	14,60	96,40	0,00	5,30	3,00
06/04/2010 07:00	162,50	121,00	14,10	97,70	0,00	4,60	2,50
06/04/2010 08:00	182,50	195,50	14,50	98,50	0,00	2,50	1,60
06/04/2010 09:00	215,00	194,50	15,90	89,70	0,00	2,90	1,50
06/04/2010 10:00	242,50	234,50	17,80	81,10	0,00	4,90	2,50
06/04/2010 11:00	240,00	259,00	19,20	74,00	0,00	5,70	3,30
06/04/2010 12:00	265,00	238,50	20,10	70,50	0,00	7,90	4,20
06/04/2010 13:00	245,00	280,00	21,30	61,50	0,00	8,30	5,20
06/04/2010 14:00	207,50	233,00	22,40	57,50	0,00	8,30	4,70
06/04/2010 15:00	225,00	185,00	22,30	56,20	0,00	8,30	5,10
06/04/2010 16:00	202,50	235,50	22,80	53,90	0,00	9,80	5,60
06/04/2010 17:00	200,00	189,00	21,20	52,50	0,00	9,30	6,20
06/04/2010 18:00	212,50	198,50	19,80	60,20	0,00	7,00	4,10
06/04/2010 19:00	210,00	220,00	17,80	68,60	0,00	7,30	3,70
06/04/2010 20:00	205,00	208,50	16,90	72,20	0,00	6,40	3,60
06/04/2010 21:00	177,50	202,00	15,70	78,40	0,00	3,40	2,50

Dia e Hora	DEMANDA	Média Móvel	Temperatura Média	Umidade Relativa	Precipitação	Velocidade da Rajada	Velocidade do Vento
06/04/2010 22:00	162,50	161,00	15,00	80,50	0,00	4,10	2,40
06/04/2010 23:00	150,00	153,50	14,30	82,90	0,00	3,30	2,40
07/04/2010 00:00	127,50	142,50	13,20	87,20	0,00	2,40	1,80
07/04/2010 01:00	115,00	114,00	13,50	87,30	0,00	1,80	1,30
07/04/2010 02:00	120,00	107,50	13,10	86,70	0,00	1,70	1,10
07/04/2010 03:00	100,00	123,00	12,50	88,90	0,00	2,20	1,10
07/04/2010 04:00	105,00	88,00	11,60	90,40	0,00	2,60	2,10
07/04/2010 05:00	107,50	108,00	11,30	91,10	0,00	3,30	1,80
07/04/2010 06:00	107,50	109,00	11,40	89,10	0,00	3,10	2,40
07/04/2010 07:00	182,50	107,50	11,70	87,30	0,00	3,10	2,00
07/04/2010 08:00	200,00	227,50	14,00	79,30	0,00	2,20	0,90
07/04/2010 09:00	217,50	210,50	15,60	75,10	0,00	4,40	2,70
07/04/2010 10:00	217,50	228,00	18,00	67,50	0,00	7,50	3,70
07/04/2010 11:00	245,00	217,50	19,60	61,70	0,00	5,20	2,50
07/04/2010 12:00	250,00	261,50	20,80	57,90	0,00	6,00	2,50
07/04/2010 13:00	227,50	253,00	22,80	54,20	0,00	5,10	2,40
07/04/2010 14:00	220,00	214,00	23,00	51,50	0,00	6,00	3,20
07/04/2010 15:00	207,50	215,50	23,90	50,90	0,00	5,20	2,40
07/04/2010 16:00	202,50	200,00	24,10	49,60	0,00	4,40	2,10
07/04/2010 17:00	207,50	199,50	22,70	55,50	0,00	4,40	2,70
07/04/2010 18:00	215,00	210,50	22,30	57,20	0,00	7,10	4,20
07/04/2010 19:00	210,00	219,50	19,70	67,10	0,00	4,10	2,70
07/04/2010 20:00	220,00	207,00	18,50	71,00	0,00	4,60	3,00
07/04/2010 21:00	187,50	226,00	17,40	74,90	0,00	3,90	2,70
07/04/2010 22:00	185,00	168,00	16,40	79,60	0,00	2,80	1,60
07/04/2010 23:00	150,00	183,50	16,20	79,90	0,00	3,00	2,00