

5 Estudos de Caso

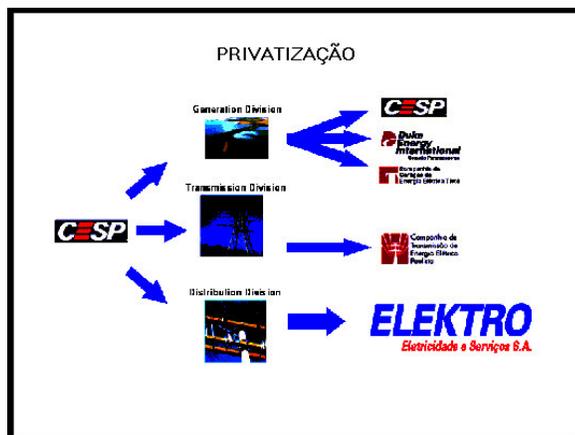
Os dados em estudo são as cargas ativa e reativa das subestações ARARAS 1 e ATIBAIA da concessionária ELEKTRO situada na cidade de Campinas – SP. Estas subestações foram escolhidas devido ao comportamento diferenciado entre elas, ou seja, a primeira é tipicamente industrial, enquanto que a segunda possui características residenciais. Os dados são horários e os anos escolhidos para pesquisa são 2000 e 2004, pois apresentam maior consistência.

O próximo item apresenta, brevemente, a concessionária Elektro, cujos dados de carga ativa e reativa foram utilizados com exemplo do modelo de regressão proposto.

5.1. Dados da Concessionária Elektro

A Elektro foi constituída em 6 de Janeiro de 1998, durante o programa estadual de privatização da rede de distribuição de energia elétrica da Cesp (Companhia Energética de São Paulo)(quadro 2). Em 17 de julho daquele mesmo ano, o controle acionário da empresa, que até então era do Governo do Estado de São Paulo, foi adquirido pela americana Enron.

Quadro 2 – Privatização da CESP



O contrato de concessão que estabelece as condições regulatórias para a operação da Elektro como empresa privada foi assinado em 27 de agosto de 1998 e estabelecia uma área de atuação em 223 municípios do Estado de São Paulo e 5 do Mato Grosso do Sul.

A Elektro possui 101 Centrais de Serviços de Rede (CSRs) em toda área de concessão, além da Sede Corporativa em Campinas, onde estão a Central de Atendimento ao Cliente (CAT) e o Centro de Operação de Distribuição (COD). São 38 CSRs com funções de coordenação das equipes técnicas e mais 63 CSRs com eletricitas estrategicamente alocados para um atendimento ágil. O número de subestações totaliza 120, e a extensão de rede primária atinge mais de 74,3 mil km.

Algumas subestações, por apresentarem grande instalação de compensação, acarretam dificuldades na análise, visto que a maioria dos medidores da concessionária Elektro divulga apenas os valores positivos da carga reativa, isto é, as cargas indutivas do sistema.

Como o número de subestações é muito elevado, fez-se necessária a escolha de algumas subestações consideradas mais importantes para a concessionária, tais como: ARARAS 1 e ATIBAIA. Estas subestações têm comportamentos diferentes entre si, a primeira é predominantemente industrial enquanto a segunda apresenta características residenciais.

O banco de dados dessas subestações é composto pelas cargas ativas (kW) e reativas (kVAr), hora a hora dos anos de 1999 a abril de 2004. Neste estudo, serão escolhidos somente os anos de 2000 e 2004, devido às inconsistências dos dados nos demais anos. Na análise com os dados de 2000 (item 5.2) a previsão da carga reativa no instante t utilizará, além de outras variáveis explicativas, a carga ativa real no mesmo instante. Mas, como este fato não é comum na prática, isto é, medir a potência ativa imediatamente antes que a reativa e assim prever a reativa, o segundo caso (item 5.3), com os dados do ano 2004, utiliza dados previstos de carga ativa no instante t para prever a carga reativa no mesmo instante.

5.2. Análise com Dados Reais de Carga Ativa

Como já comentado anteriormente, a carga reativa não apresenta um comportamento estatisticamente bem definido como a carga ativa. A partir disso, torna-se necessário encontrar uma maneira mais adequada para o estudo dos dados de carga reativa aproveitando a própria estrutura física da carga.

Segundo Li (1998) e Cinvanlar (1988), os dados de carga ativa e reativa são correlacionados linearmente. O que pode ser comprovado através da análise dos gráficos de dispersão (figura 7a e 7b) e dos coeficientes de correlação Pearson (equação 5.1).

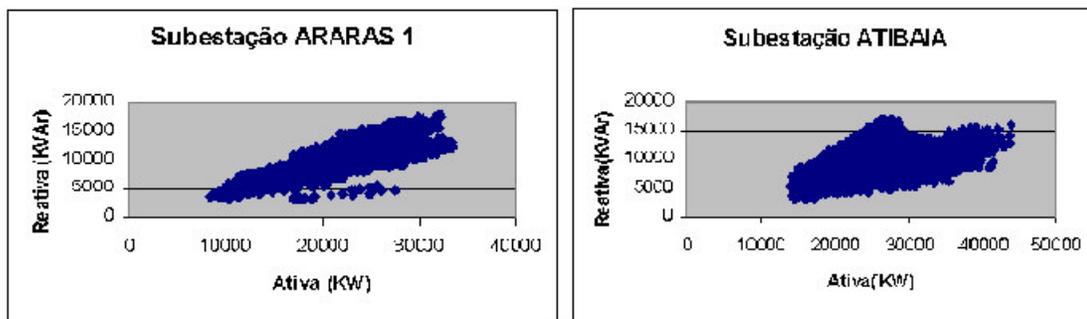


Figura 7-Relação entre carga ativa (KW) e reativa (KVAR), ano 2000, subestações: a) ARARAS 1 e b) ATIBAIA.

$$r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\left[\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (Y_i - \bar{Y})^2 \right]^{1/2}}; \quad 0 \leq |r| \leq 1 \quad (5.1)$$

Os coeficientes para as subestações ARARAS e ATIBAIA são, respectivamente, 86,6% e 52,7% e são significantes ao nível de significância de 1%.

A correlação é entre as cargas ativa e reativa é mais forte na subestação ARARAS, também é esta que apresenta comportamento mais homogêneo. Todavia, a correlação entre as cargas ativas e reativas nos dois casos é significativa, por isso, o estudo se baseia em encontrar um melhor modelo que estime previsões confiáveis da potência reativa aproveitando da consistência dos dados de potência ativa.

A formação de grupos no diagrama de dispersão entre as cargas ativa e reativa pode ser justificada pela presença de capacitores síncronos (*switched*), que deve operar de modo a dispor de uma reserva de potência reativa para controlar excursões rápidas de tensão durante contingências. Já, quando há somente um grupo no diagrama entre as cargas, indica que na subestação não tem compensadores de reativo, ou tem somente capacitores fixos (*shunt*), o qual destina-se a manter o perfil de tensão durante condição normal de operação e, portanto, em decorrência da sua própria natureza, injeta continuamente potência reativa no sistema (Civanlar, 1988).

Na figura 7a, observa-se a formação de dois grupos na subestação ARARAS que, após algumas análises, constatou-se que o grupo menor se tratava do mês de Fevereiro. O que pode ser a presença de capacitores síncronos neste mês.

Uma outra análise importante dos dados de carga reativa é qual a classe de consumo alimentada pela subestação em questão. Este dado, além de ser informado pela própria concessionária, pode ser avaliado através do Fator de Potência médio da subestação. Segundo Civanlar (1988), o valor médio do Fator de Potência em torno de 0,86 corresponde a uma subestação com características tipicamente industriais. Já quando este valor fica em torno de 0,95 corresponde a uma subestação tipicamente residencial.

Este foi um dos motivos principais da escolha das subestações ARARAS e ATIBAIA da concessionária Elektro, pois estas apresentam características diferentes. A primeira possui marcadamente cargas do tipo industrial, contrapondo-se à característica residencial da segunda subestação. Estas características se comprovam no perfil do Fator de Potência de cada subestação no ano 2000 (figura 8), onde se nota que para ARARAS o Fator de Potência fica em torno de 0,88, enquanto que para ATIBAIA o mesmo fica em torno de 0,92.

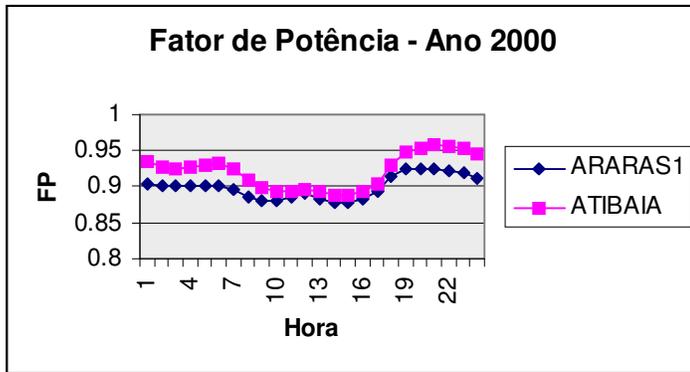


Figura 8 – Fator de Potência médio das subestações ARARAS1 e ATIBAIA no ano 2000

A série de potência reativa não tem um comportamento estatisticamente bem definido, porém algumas subestações (com pouca presença de capacitores síncronos) podem apresentar um comportamento satisfatório. Isto se comprova na figura 9a, onde a série apresentada tem um perfil estacionário na média, porém com bastante volatilidade.

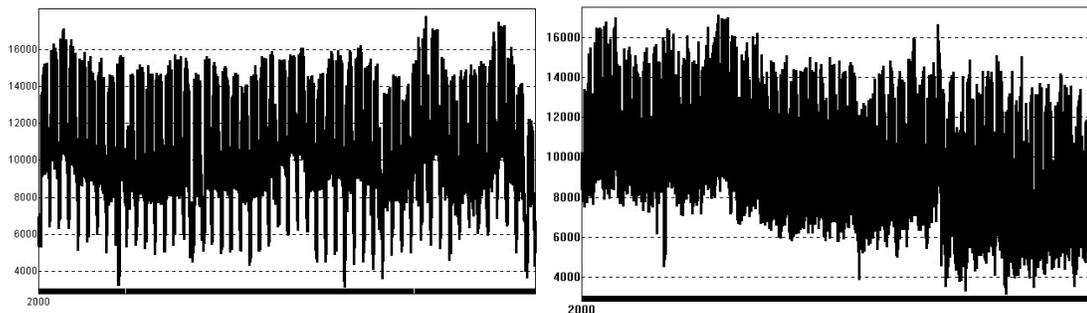


Figura 9 – Perfil de carga reativa ano 2000, subestações: a) ARARAS 1 e b) ATIBAIA

Já a figura 9b, apresenta o perfil de uma subestação com presença forte de compensadores fixos e síncronos, o que acarreta um comportamento heterocedástico, exigindo um modelo mais elaborado para uma previsão precisa.

A tabela 2 apresenta os resultados dos testes de normalidade (Kolmogorov-Smirnov) e homocedasticidade (Levene) calculados para a carga reativa de cada subestação. Observa-se que a análise do gráfico de perfil dos dados é confirmada com os resultados dos testes, ou seja, os dados de carga reativa do ano 2000 de cada subestação seguem uma distribuição Normal, porém com variância não constante.

Tabela 2 – Testes Kolmogorov-Smirnov e Levene para carga reativa de cada subestação do ano 2000

	Kolmogorov-Smirnov*		Levene*			
	Z	sig(2-tailed)	Estatística	df1	df2	sig
ARARAS	4.157	0.000	98.979	23	8760	0.000
ATIBAIA	4.695	0.000	24.165	23	8760	0.000

* Nível de significância de 5%

Analisando os histogramas das séries (figura 10) e algumas estatísticas descritivas (tabela 3), comprova-se a aproximação da distribuição normal, porém acentuada dispersão das mesmas.

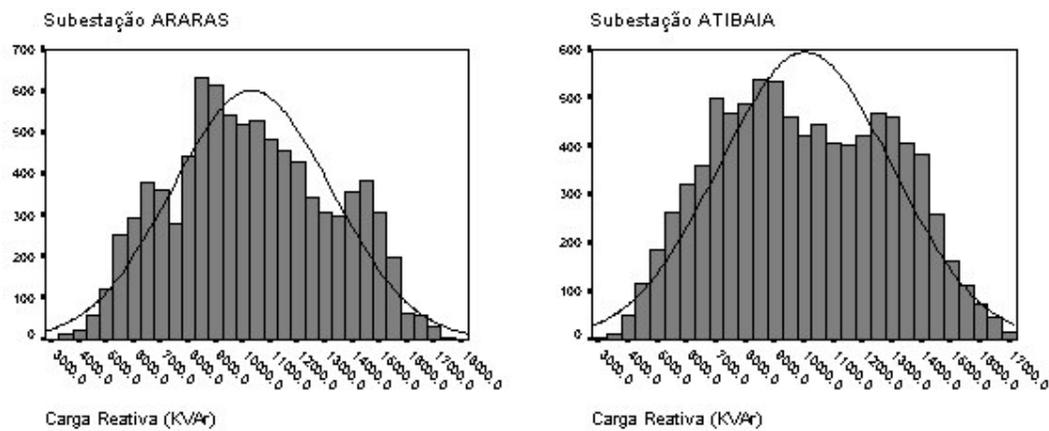


Figura 10 – Histograma de carga reativa ano 2000

Tabela 3- Estatísticas Descritivas

	ARARAS 1	ATIBAIA
N	8784	8784
Mínimo	3206	3204
Máximo	17770	17091
Média	10295.43	10019.68
Desvio Padrão	2906.29	2939.25
Assimetria	0.115	0.073
Curtose	-0.795	-0.913

Para a comparação dos resultados de previsão de carga reativa, é utilizado o MAPE (*Mean Absolute Percentual Erro*) descrito a seguir.

1. Erro de previsão:

$$e(i, j) = Y(i, j) - \hat{Y}(i, j)$$

2. Erro médio:

$$\bar{e}(j) = \frac{\sum_{i=1}^N e(i, j)}{N}$$

3. Erro absoluto médio

$$|\bar{e}(j)| = \frac{\sum_{i=1}^N |e(i, j)|}{N}$$

4. Erro quadrático médio

$$EQM(j) = \frac{\sum_{i=1}^N e^2(i, j)}{N}$$

5. Erro percentual

$$\text{erro percentual}(i, j) = \frac{|e(i, j)|}{Y(i, j)} \times 100$$

6. MAPE

$$MAPE(j) = \frac{\sum_{i=1}^N \text{erro percentual}(i, j)}{N}$$

onde

i : dia considerado

j : hora considerada

Y(i,j) : carga reativa real

$\hat{Y}(i, j)$: carga reativa prevista

N : número total de dias com carga prevista

Como a unidade de medida da potência ativa é kW e a de potência reativa é kVAr, usou-se, por conveniência, os dados tanto de carga reativa e ativa em PU (por unidade) para evitar incompatibilidade de unidades e grandezas. Os perfis de curva de carga em PU são formados pelas cargas horárias normalizadas pela demanda média de energia diária, ou seja:

$$P.U_{i,h} = \frac{C_{i,h}}{DM_i}, \quad i = \overline{1,365} \quad e \quad h = \overline{1,24} \quad (5.2)$$

onde

$$DM_i = \frac{\sum_{h=1}^{24} C_{hi}}{24}, \quad i = \overline{1,365}$$

Pode-se utilizar variáveis *dummy* como variável exógena para designar o período “verão” e “inverno” encontrado na classificação do Mapa Auto-Organizável de Kohonen, como feito em Albertson & Aylen (2003), porém, este método foi considerado desnecessário, visto que as equações horárias ficariam com o número de termos muito elevado.

Os bancos de dados das cargas reativa e ativa, ano 2000, das subestações ARARAS e ATIBAIA são formados, cada um, por 24 variáveis e 366 objetos. O objetivo do trabalho é fazer previsões horárias das cargas para cada subestação. A matriz de entrada possui dimensão 366x24.

Para inicializar o algoritmo do Modelo de Kohonen, escolhem-se pesos de modo aleatório, neste caso, foram escolhidos os mínimos e máximos de cada variável.

O mapa escolhido foi um bidimensional, inicialmente, composto por 8 neurônios. A distribuição dos dias em cada neurônio está mostrada na tabela 4.

Tabela 4 – Freqüência dos dias nos 8 neurônios

NEURÔNIOS	FREQÜÊNCIA	FREQÜÊNCIA RELATIVA(%)
1	60	16.39
2	34	9.29
3	23	6.28
4	71	19.40
5	16	4.37
6	101	27.60
7	14	3.83
8	47	12.84
Soma	366	100

Com esta topologia (8 neurônios), ficou difícil tirar maiores conclusões entres os grupos formados. O dados foram muito detalhados e espalhados.

Face as estes resultados, procurou-se “melhorar” os grupamentos obtidos baseando-se principalmente em um aspecto: Levando em consideração o problema de super-parametrização, deve-se lembrar que ao projetar um vetor de entrada de tamanho 24, tendo 8 neurônios, estão-se ajustando, pelo algoritmo de Kohonem, 192 parâmetros com dados de 366 dias. Dada esta consideração, resolveu-se reduzir o número de neurônios para 05 e, por conseguinte, reduzir o número de parâmetros a ser ajustado.

Após a mudança acima, acredita-se que melhores resultados foram obtidos em relação à Rede anterior, na medida em que houve uma “menor preocupação de detalhes” das características dos dados e estes ficaram mais concentrados. Os resultados são apresentados na Tabela 5.

Tabela 5 – Frequência de dias com 5 neurônios

DIAS	NEURÔNIOS	FREQUENCIA	FREQUENCIA RELATIVA(%)
Feriado/Domingo	1	54	14.75
Dia Útil do inverno	2	106	28.96
Segunda-feira.	3	89	24.32
Sábado	4	51	13.93
Dia Útil do verão	5	66	18.03
	Soma	366	100

Correspondendo, então, a Etapa I da modelagem proposta, os dados de cargas ativa e reativa das subestações ARARAS e ATIBAIA são classificados, segundo os Mapas Auto-Organizáveis de Kohonen (SOM), em 5 grupos (figura 11). Porém, a título de exemplificação, neste estudo são utilizados somente os dias úteis sem segunda-feira (área sombreada na figura 11 e na tabela 5).

O período considerado “verão” equivale aos meses de Janeiro, Fevereiro, Outubro, Novembro e Dezembro. Já o período denominado “inverno” constitui os meses de Março, Abril, Maio, Junho, Julho, Agosto, Setembro. No período “verão” há 81 dias, sendo os dias úteis excluindo as 2ª feiras, então 65 dias “*in sample*” e 16 “*out of sample*”, correspondendo ao mês de Dezembro. No período “inverno” existem 112 dados. Para análise foram considerados 97 dados “*in*

sample” e 15 dados “*out of sample*”, que correspondem ao mês de Setembro, também dias úteis excluindo as 2ª feiras.

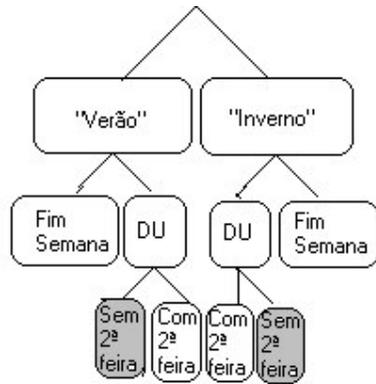


Figura 11 - Grupos dentro de cada subestação, ano 2000.

As análises também foram feitas para os horários de carga leve (“verão”=24h às 8h; “inverno”=23h às 7h), carga média (“verão”=9h às 18h; “inverno”=8h às 17h) e carga pesada (“verão”=19h às 23; “inverno”=18h às 22h).

Após vários testes “*bottom-up*”, isto é parte-se de um modelo mais simples e inclui-se novas variáveis até encontrar um modelo apropriado.

Dois modelos, Etapa II da modelagem proposta, com variáveis explicativas diferentes foram encontrados, um para cada período (“verão” e “inverno”) classificado pelo Mapa Organizável de Kohonen (Etapa I da modelagem proposta). Assim, para o “inverno”, tem -se:

$$\begin{aligned} Y_t &= -(c_0 + c_t) + \beta_1 X_t + \beta_2 X_{t-1} + \beta_3 Y_{t-1} + \beta_4 Y_{t-168} + u_t \\ u_t &= ru_{t-1} + \varepsilon_t \end{aligned} \quad (5.3)$$

onde:

Y_t : carga reativa em PU na hora t

X_t : carga ativa em PU na hora t

X_{t-1} : carga ativa em PU da hora $t-1$

Y_{t-1} : carga reativa em PU da hora $t-1$

Y_{t-168} : carga reativa em PU na mesma hora e dia da semana anterior

c_0 : carga reativa devido aos capacitores fixos (*shunt*)

c_t : carga reativa devido aos capacitores síncronos (*switched*)

β 's: coeficientes a serem estimados no modelo

ε_t : ruído aleatório associado ao modelo, onde se supõem que são independentes e identicamente distribuídos com densidade $N(0, \sigma^2)$.

Como não estão disponíveis os dados de carga devida aos capacitores síncronos, então o modelo será considerado em *OFF* (desligado). Assim, o modelo se torna:

$$\begin{cases} Y_t = \beta_0 + \beta_1 X_t + \beta_2 X_{t-1} + \beta_3 Y_{t-1} + \beta_4 Y_{t-168} + u_t \\ R(\beta)u_t = \varepsilon_t \\ R(\beta) \text{ é um AR}(1) \\ \beta_0 = -(c_0 + c_1) \end{cases} \quad (5.4)$$

onde:

Y_t : carga reativa em PU na hora t

X_t : carga ativa em PU na hora t

X_{t-1} : carga ativa em PU na hora $t-1$

Y_{t-1} : carga reativa em PU na hora $t-1$

Y_{t-168} : carga reativa em PU na hora $t-168$

ε_t : ruído aleatório associado ao modelo, onde se supõem que são independentes e identicamente distribuídos com densidade $N(0, \sigma^2)$.

A carga reativa na hora t é explicada pela carga ativa nos instantes t e $t-1$ e pela carga reativa na hora $t-1$ e pela carga reativa da hora t da semana anterior.

Para estimar os coeficientes com maior precisão, é utilizado o modelo dinâmico iterativo, cujo desenvolvimento relaciona o algoritmo de mínimos quadrados ponderados iterativamente com a função de peso do tipo Biquadrada e uma correção de autocorrelação a transformação de Cochran-Orcutt. Esse modelo atribui pesos à observação de acordo com a distância entre essa observação e o padrão dos dados, baseando-se no resíduo da observação. Os pesos são posteriormente utilizados para diminuir a influência da observação e revisados após cada iteração até que um ajuste robusto seja encontrado (Neter et al., 1996) tanto para os coeficientes da regressão quanto para o coeficiente dos resíduos, visto que, eles possuem correlação de primeira ordem.

Para o “verão”, tem -se:

$$\begin{cases} Y_t = \beta_0 + \beta_1 X_t + \beta_2 Y_{t-1} + \beta_3 Y_{t-168} + u_t \\ R(\beta)u_t = \varepsilon_t \end{cases}$$

$R(\beta)$ é um AR(1) (5.5)

$\beta_0 = -(c_0 + c_1)$

onde:

Y_t : carga reativa em PU na hora t

X_t : carga ativa em PU na hora t

Y_{t-1} : carga reativa em PU na hora $t-1$

Y_{t-168} : carga reativa em PU na hora $t-168$

ε_t : ruído aleatório associado ao modelo, onde se supõem que são independentes e identicamente distribuídos com densidade $N(0, \sigma^2)$.

Este modelo só difere do “inverno” pela ausência da carga ativa em $t-1$.

Como o objetivo principal deste trabalho é apresentar um modelo “ótimo” de previsão de carga reativa, e, como os grupos classificados pelo SOM separaram a segunda-feira dos demais dias da semana, quando é feita a previsão da hora 1 da terça-feira, o erro tende a ser elevado, pois automaticamente, o modelo utiliza a hora 24 da sexta-feira da semana anterior. Para amenizar um pouco este problema, outros modelos Dinâmicos Iterativos foram testados, porém somente na subestação ATIBAIA no grupo “verão” na hora 1 o modelo final ficou como segue:

$$\begin{cases} Y_t = \beta_0 + \beta_1 X_t + \beta_2 X_{t-24} + \beta_3 Y_{t-24} + \beta_4 Y_{t-1} + u_t \\ R(\beta)u_t = \varepsilon_t \end{cases}$$

$R(\beta)$ é um AR(1) (5.6)

$\beta_0 = -(c_0 + c_1)$

onde:

Y_t : carga reativa em PU na hora t

X_t : carga ativa em PU na hora t

Y_{t-1} : carga reativa em PU na hora $t-1$

Y_{t-168} : carga reativa em PU na hora $t-168$

ε_t : ruído aleatório associado ao modelo, onde se supõem que são independentes e identicamente distribuídos com densidade $N(0, \sigma^2)$.

Vale citar que, vários modelos foram implementados para comparação ao modelo híbrido proposto, contudo neste estudo serão apresentados somente os de melhores resultados. São eles, o modelo de regressão dinâmica estimado por mínimos quadrados ordinários e uma rede neural artificial (RN) com a arquitetura apresentada na tabela 6 (Bezerra, 2002):

Tabela 6 - Descrição das Variáveis da RN

Camada de Entrada	Descrição
4 neurônios (inverno); 3 neurônios (verão)	$X(d,h)$, $h=1...24$ $d=1...366$
Camada Escondida	
3 neurônios (inverno); 2 neurônios (verão)	
Camada de Saída	
1 neurônio	$Y(d,h)$ $h=1...24$

As tabelas 7 e 8 mostram os MAPES horários dos modelos em questão para os grupos “Inverno” e “verão” obtidos através do SOM das subestações ARARAS e ATIBAIA, respectivamente.

Tabela 7 – MAPE Subestação ARARAS – 2000

Hora	Inverno			Verão		
	Prop	RD	RN	Prop	RD	RN
1	1.60	2.29	2.01	1.94	4.72	2.71
2	1.16	1.59	1.91	2.02	14.19	2.14
3	1.45	2.38	1.65	1.54	6.60	1.57
4	1.30	1.44	1.31	1.99	6.40	2.11
5	1.81	2.21	1.72	1.68	4.60	2.31
6	1.36	1.83	2.16	2.66	11.31	2.60
7	1.70	1.29	1.60	3.31	3.66	6.39
8	0.90	0.87	1.22	1.20	4.19	1.21
9	0.54	0.71	0.98	1.16	4.94	2.12
10	0.88	0.89	0.97	1.39	2.68	1.77
11	1.27	1.41	1.94	1.67	2.99	1.99
12	1.38	1.34	2.09	2.30	3.83	1.30
13	0.51	0.44	1.55	2.82	3.74	2.22
14	1.11	1.36	1.05	1.92	2.69	2.27
15	0.82	1.19	1.12	1.74	5.03	2.60
16	0.92	0.80	1.18	2.94	2.79	2.63
17	1.52	0.83	1.21	1.90	4.71	3.21
18	1.08	1.51	0.99	3.00	2.18	2.08
19	1.35	0.85	1.29	2.00	2.39	2.47
20	0.96	1.24	1.76	3.27	3.10	2.98
21	1.14	1.13	1.24	1.14	2.67	1.16
22	1.24	1.42	1.21	1.58	2.76	1.87
23	1.06	0.95	2.24	2.09	2.14	2.73
24	1.05	1.30	1.54	2.79	4.64	4.23
Média	1.17	1.30	1.50	2.09	4.54	2.44
Carga Leve	1.37	1.69	1.68	2.12	6.70	2.81
Carga Média	0.99	0.98	1.33	2.08	3.56	2.22
Carga Pesada	1.16	1.23	1.30	2.02	2.61	2.24

NOTA: Nos dois grupos foram ilustrados os resultados *out of sample*, onde verão corresponde o mês de dezembro e inverno corresponde ao mês de setembro.

Tabela 8 - MAPE Subestação ATIBAIA - ano 2000

Hora	Inverno			Verão		
	Prop	RD	RN	Prop	RD	RN
1	7.68	14.91	11.21	5.51	6.28	9.48
2	3.72	5.11	9.42	3.18	10.70	8.10
3	2.14	4.30	25.71	3.18	2.43	3.32
4	2.25	5.85	5.20	2.24	1.92	2.34
5	3.67	7.83	15.58	3.63	3.88	4.35
6	2.16	9.02	18.94	4.44	7.83	5.82
7	3.83	3.83	19.51	4.70	17.89	8.58
8	3.76	5.24	13.47	3.19	5.00	3.06
9	4.31	4.35	4.48	1.97	9.49	2.47
10	1.91	2.28	5.37	2.15	7.81	19.60
11	2.32	1.59	4.31	1.18	6.40	1.75
12	1.38	1.49	3.05	1.46	7.15	2.75
13	1.20	0.88	3.03	3.41	1.76	3.34
14	2.80	3.14	4.64	1.09	3.47	2.48
15	1.64	2.40	3.02	2.05	5.25	4.30
16	1.37	1.08	2.82	1.85	3.43	2.30
17	2.59	2.37	2.98	2.08	8.68	3.76
18	3.31	2.11	11.77	2.39	3.24	3.47
19	2.54	5.18	3.50	1.92	2.41	2.53
20	2.77	3.52	6.06	6.16	3.96	5.62
21	3.44	2.55	7.65	1.96	2.74	4.36
22	2.09	1.74	4.80	2.68	3.01	2.78
23	4.41	5.09	7.64	1.84	1.86	5.29
24	3.69	4.73	8.66	3.20	3.24	4.51
Média	2.96	4.19	8.45	2.81	5.41	4.85
Carga Leve	3.73	6.74	13.54	3.55	6.22	5.76
Carga Média	2.33	2.48	4.72	1.96	5.67	4.62
Carga Pesada	2.83	3.02	6.76	2.91	2.80	4.12

NOTA: Nos dois grupos foram ilustrados os resultados *out of sample*, onde verão corresponde o mês de dezembro e inverno corresponde ao mês de setembro.

Observa-se que, na média horária, o modelo proposto apresentou melhores resultados. As diferenças foram mais significativas na subestação ATIBAIA. O que pode ser explicado pelo comportamento mais homogêneo dos dados de carga reativa da subestação ARARAS.

Na subestação ARARAS, o modelo proposto apresentou desempenho inferior à regressão dinâmica convencional no período ‘inverno’ para carga média, mas, ao nível de significância de 5%, esta diferença não é estatisticamente significativa.

Na subestação ATIBAIA, cujos dados de carga reativa apresentam maior volatilidade, o modelo proposto superou significativamente em desempenho os demais modelos.

As figuras 12 e 13 comparam as previsões com os valores reais dos meses Setembro e Dezembro de 2000, respectivamente, para as subestações ARARAS e ATIBAIA.

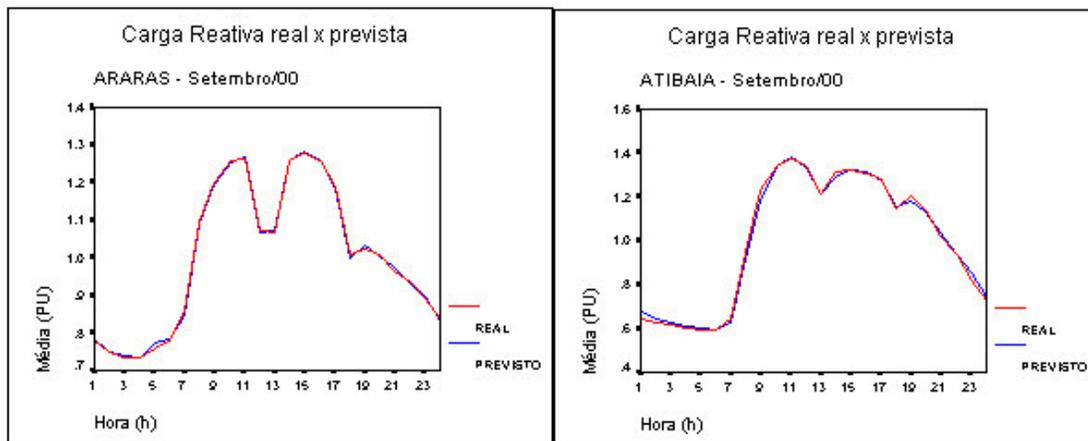


Figura 12 – Carga Reativa real x prevista para mês de setembro/00 para as subestações ARARAS e ATIBAIA.

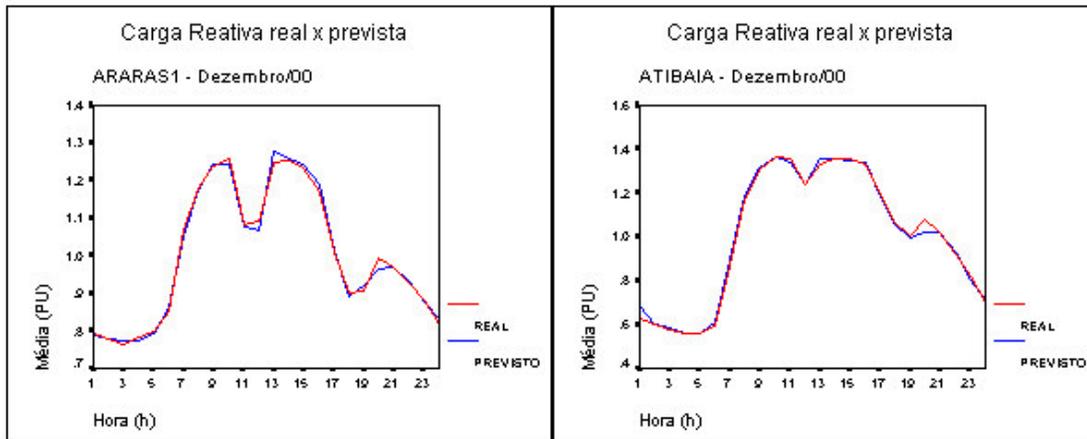


Figura 13 - Carga Reativa real x prevista para mês de dezembro/00 para as subestações ARARAS e ATIBAIA.

Observa-se que a análise através da média horária de todos os dias úteis (sem segunda-feira) dos meses de setembro e dezembro é bastante generalizada, ou seja, não permite uma visão detalhada do desempenho do modelo na previsão. O que se pode verificar é que, de maneira geral, os resultados obtidos pelo modelo RDR foram satisfatórios.

As figuras 14 e 15 também comparam as previsões com os valores reais dos meses Setembro e Dezembro de 2000, respectivamente, para as subestações ARARAS e ATIBAIA, porém mostram as comparações separadas por horários de carga – carga leve, carga média e carga pesada.

Observa-se que, nos horários de carga pesada o modelo obteve pior desempenho, tendeu a subestimar os resultados, exceto na subestação ARARAS no mês de setembro. No entanto, as falhas mais significativas do modelo proposto se deram nos horários de pico (de 6h às 8h, de 12h às 13h e 18h às 20h). Sabem-se, de estudos anteriores feitos com carga ativa (Ramanathan & Engle, 1997), que o comportamento delas nos horários de maior demanda é na forma de um pico (subida e descida brusca), porém, o mesmo não ocorre com a carga reativa, onde a transição é mais suave. Esta diferença pode explicar a subestimação do modelo nos horários de alta demanda, visto que, apesar da presença da carga ativa que apresenta picos nestes horários, há também presença e com várias defasagens da carga reativa o que faz com o resultado final da previsão fique mais suavizado que o valor real. Esta diferença foi mais marcante para o período de “verão” (dezembro).

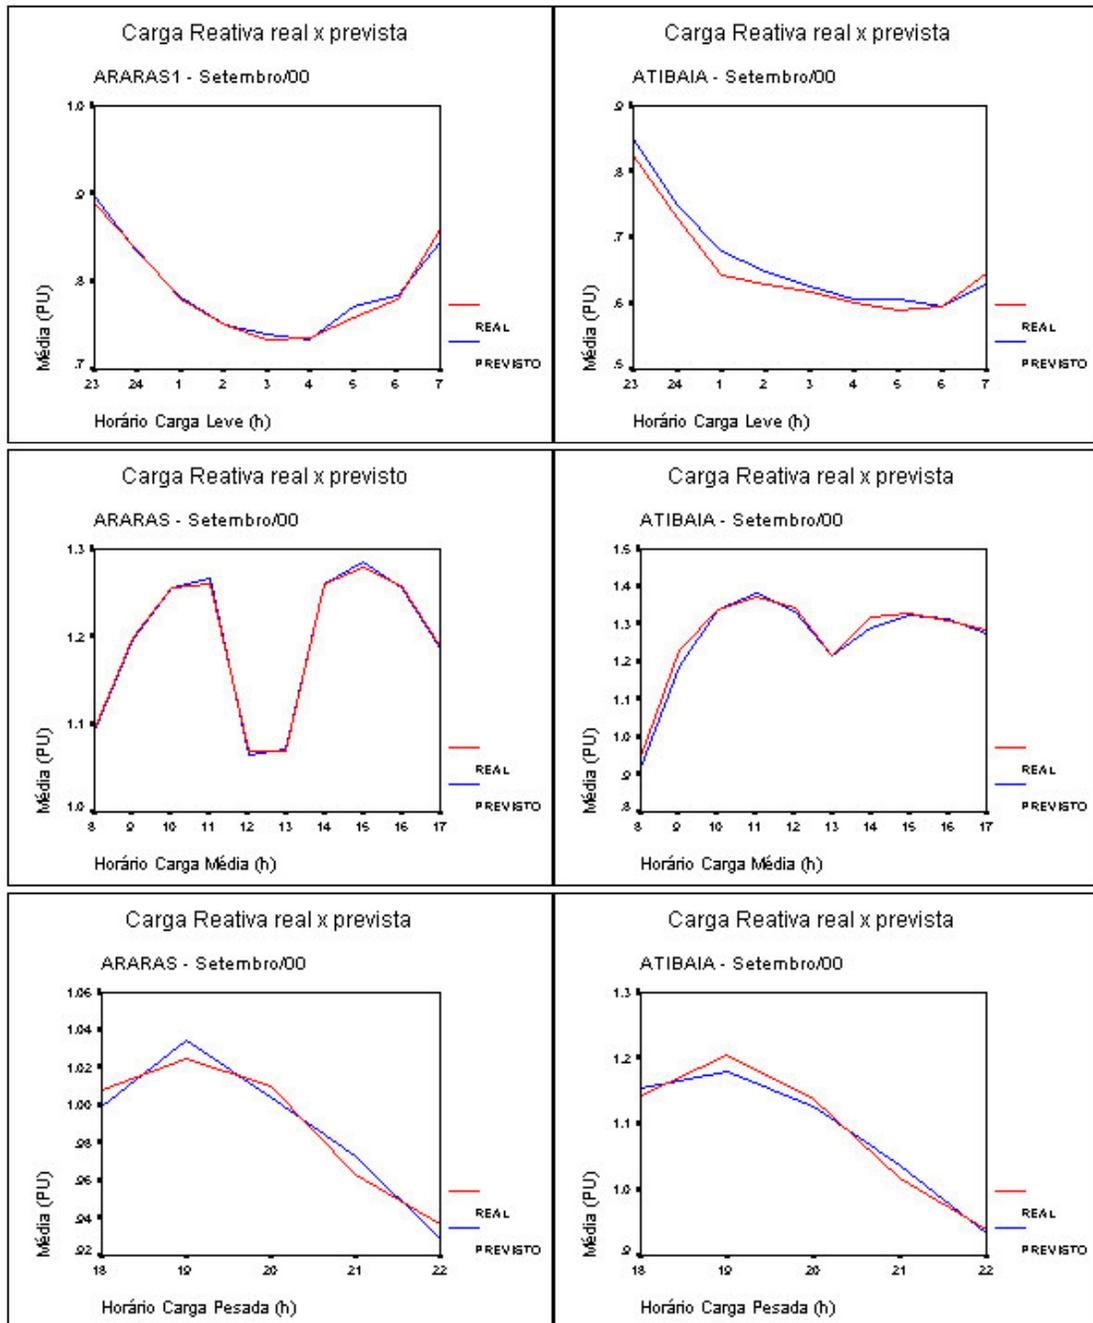


Figura 14 - Carga Reativa real x prevista por horário de carga no mês de setembro/00 das subestações ARARAS e ATIBAIA.

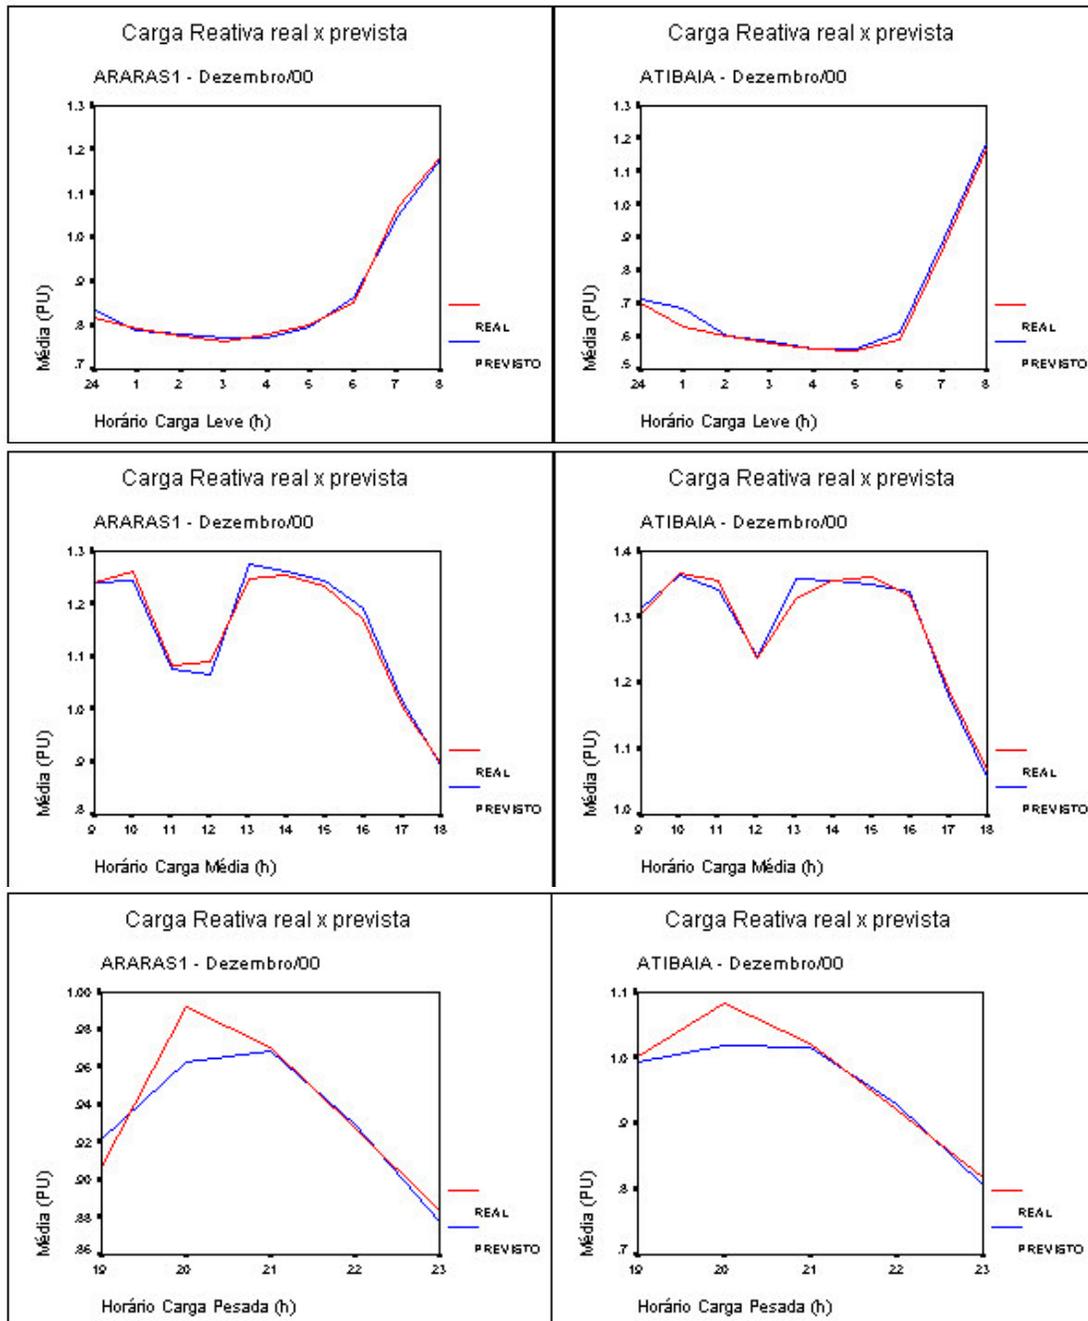


Figura 15 - Carga Reativa real x prevista por horário de carga no mês de dezembro/00 das subestações ARARAS e ATIBAIA.

As figuras 16 e 17 apresentam as comparações das previsões com os valores reais por dia útil, lembrando que na etapa 1 da modelagem, o grupo formado pelos dias úteis não incluiu a segunda-feira.

Para o mês de setembro (figura 16), nos horários de carga leve, para todos os dias, o modelo proposto superestimou os resultados. A diferença foi mais significativa na quinta-feira e na subestação ATIBAIA.

Nos horários de carga média, as previsões foram inferiores aos valores reais, exceto na quarta-feira da subestação ARARAS. Mais uma vez, a quinta-feira da subestação ATIBAIA apresentou uma diferença mais significativa.

Já nos horários de carga pesada, as diferenças entre as previsões e os valores reais nos dias úteis não apresentaram uniformidade. Ou seja, para alguns dias o modelo subestimou os resultados, mas para outros ele superestimou.

Para o mês de dezembro (figura 17), na subestação de ARARAS, o modelo superestimou na terça-feira e quarta-feira, e subestimou na quinta-feira e sexta-feira. Já na subestação ATIBAIA, para todos os dias o modelo proposto superestimou os resultados.

Nos horários de carga média, as diferenças entre as previsões e os valores reais nos dias úteis não apresentaram uniformidade.

Nos horários de carga pesada, o modelo proposto subestimou as previsões em todos os dias. A diferença foi mais significativa na subestação ATIBAIA.

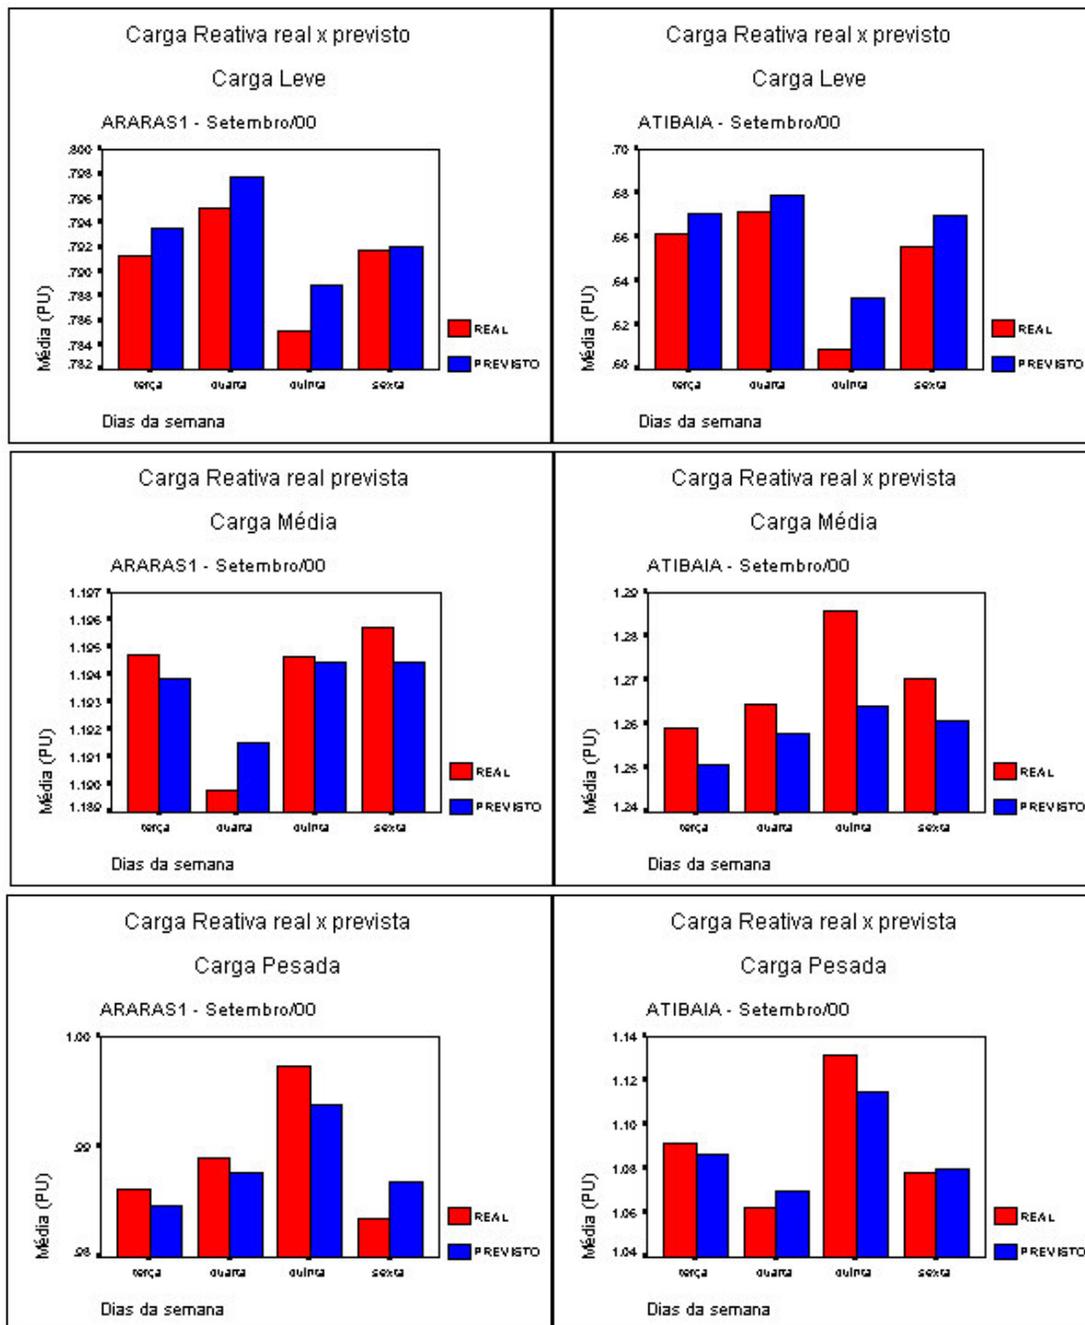


Figura 16 - Carga Reativa real x prevista por horário e por dia útil de carga no mês de setembro/00 das subestações ARARAS e ATIBAIA.

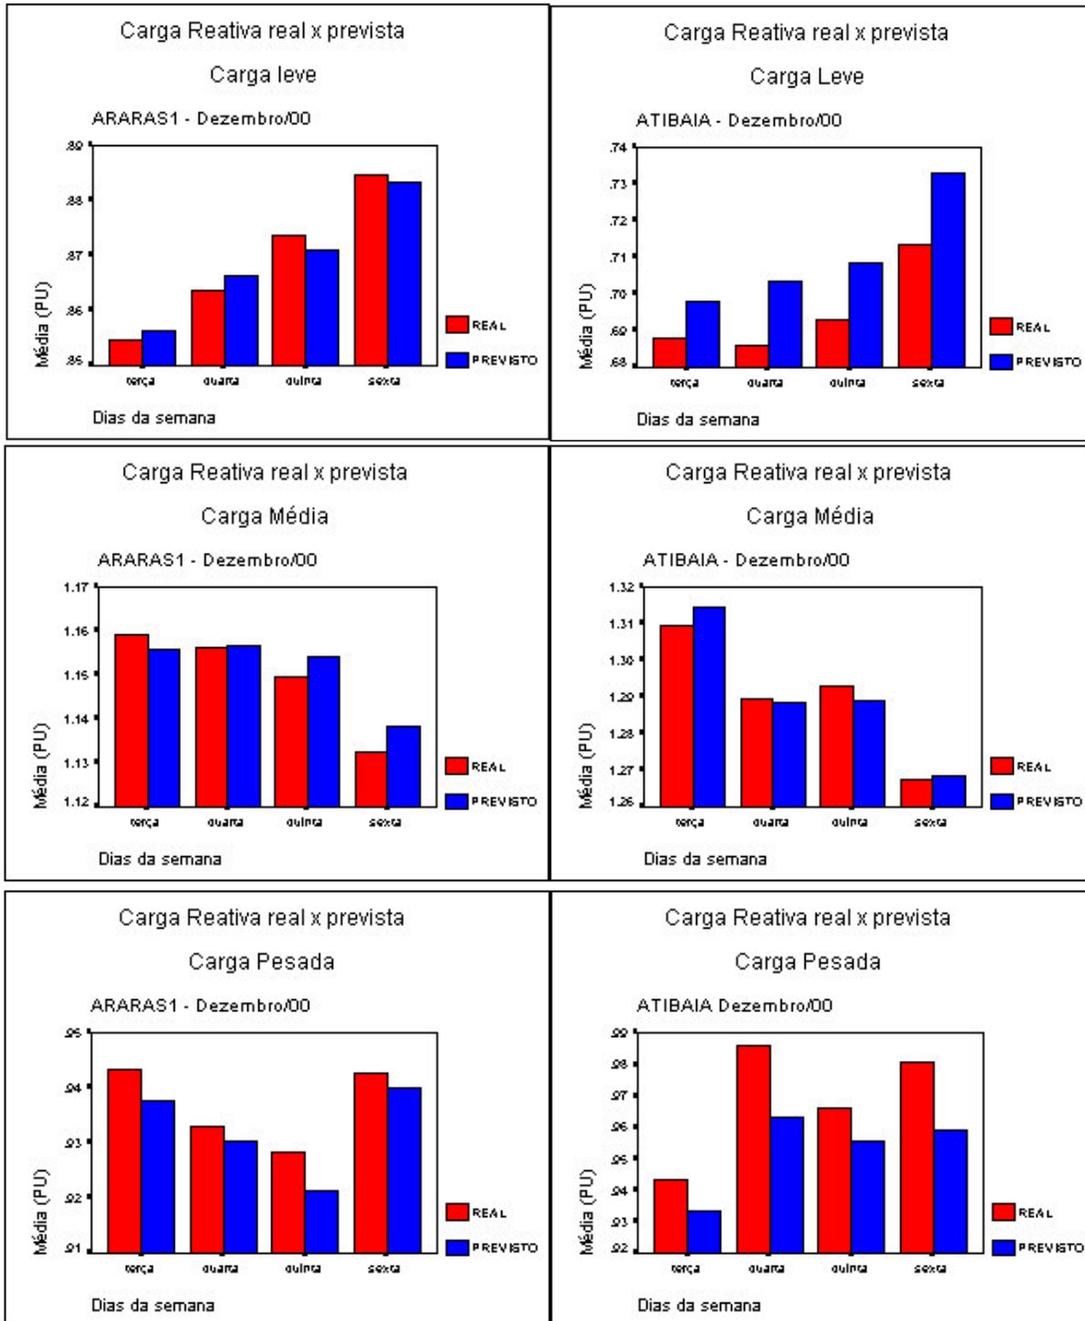


Figura 17 - Carga Reativa real x prevista por horário e por dia útil de carga no mês de dezembro/00 das subestações ARARAS e ATIBAIA.

As figuras 18 e 19 apresentam as autocorrelações (ACF) dos resíduos das previsões, para cada subestação, dos meses setembro (“inverno”) e dezembro (“verão”) respectivamente.

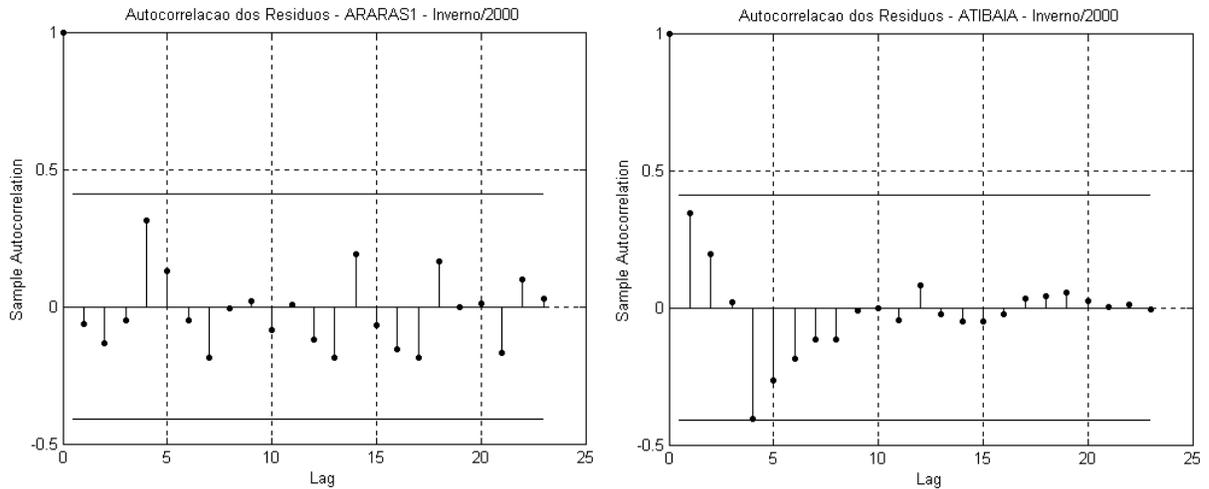


Figura 18 – Autocorrelação dos resíduos das previsões de “inverno” das subestações ARARAS e ATIBAIA ano 2000.

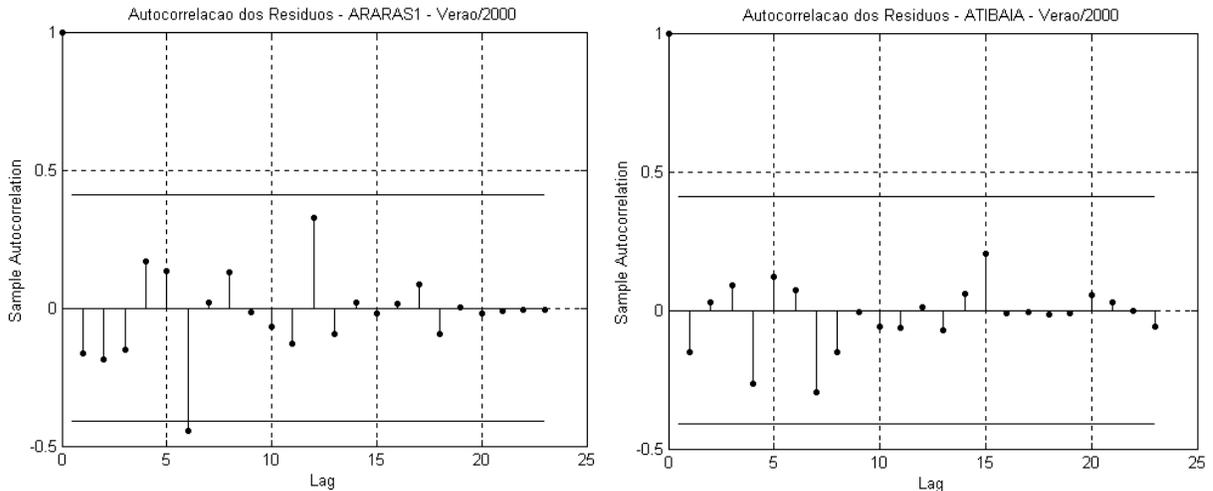


Figura 19 - Autocorrelação dos resíduos das previsões de “verão” das subestações ARARAS e ATIBAIA ano 2000.

Observa-se que, como o modelo híbrido proposto incorpora uma correção a autocorrelação dos erros, ao nível de significância de 5%, as autocorrelações dos resíduos das previsões são estatisticamente nulas. Exceto às 6 horas do período “verão” na subestação ARARAS, onde os resíduos foram diferentes de zero o que é normal, pois o intervalo de confiança é de 95%.

Vale lembrar que a correção incorporada ao modelo proposto é uma correção de autocorrelação de primeira ordem. Então, caso existam autocorrelações de ordem superiores, o desempenho do modelo pode ser afetado. Todavia, de maneira geral, os resultados foram satisfatórios.

5.3. Análise com Dados Previstos de Carga Ativa

Os dados de carga ativa, até abril de 2004, foram previstos para cada dia da semana a partir das previsões anuais de mercado fornecidas pela concessionária Elektro.

Primeiramente, foram tomados os dados de consumo horário envolvendo as SE de ARARAS e ATIBAIA da concessionária Elektro, no período de 01/01/99 à 31/12/03. Em seguida, foi feito o cálculo da Demanda Média anual (DMH(a)), sendo (a) 1999,2000,2001,2002,2003.

$$DMH^{(a)} = \frac{\sum_m \sum_d \sum_h L_{h,d,m}^{(a)}}{8760}$$

onde : $L_{h,d,m}^{(a)} \Rightarrow$ Consumo em MW

$h = 1 - 24$

$d = 1 - 31(30,28)$

$m = 1 - 12$

$8760 \Rightarrow$ Total de no ano

Uma vez que a demanda média evolui no tempo e de modo a obter dados comparáveis entre os anos analisados, os dados foram transformados em pu (por unidade), na base DMH(a).

$$\frac{L_{h,d,m}^{(a)}}{DMH^{(a)}} = P_{h,d,m}^{(a)}$$

As Curvas por unidade (em pu) por hora foram agregadas, para cada mês m (1-12) e para cada dia d (1- 9). Considerados dias normais da semana, feriados e dias próximos a feriados com possibilidade de compensação (feriados prolongados).

$$l_{hi}^{(d,m)} = \{p_{h,d,m}^{(a)}\} \quad i=1, \dots, n_{(d,m)}$$

onde: $n_{(d,m)} \Rightarrow$ número total de perfis do grupo (d,m)

Para cada grupo (d,m) de curvas em pu, foram calculados a média e o desvio padrão para cada SE:

$$l_h^{*(d,m)} = \sum_{i=1}^{n_{(d,m)}} \frac{l_{hi}^{(d,m)}}{n_{(d,m)}}$$

$$dp[l_h^{*(d,m)}] = \sqrt{\frac{\sum (l_{hi} - l_h^*)^2}{(n_{(d,m)} - 1)}}$$

A finalidade desta análise é verificar se os valores previstos de carga calculados a partir das previsões de mercado se encontram dentro do intervalo de confiança com um desvio padrão para mais e para menos.

A concessionária em questão (Elektro) possui previsões de mercado de energia total até o ano de 2009 por Município. Sabe-se, também que cada subestação tem um percentual de participação em cada Município, ou seja, uma subestação pode alimentar um município como todo ou somente partes isoladas de vários municípios. Com isso, a previsão de mercado por subestação deve ser multiplicada pelo percentual de participação de cada uma nos respectivos municípios.

Os percentuais de participação em cada município foram obtidos do cadastro técnico da empresa, onde é possível identificar para cada unidade consumidora a energia medida e a qual subestação a mesma encontra-se conectada.

Um exercício de previsão foi feito para o ano de 2004 até o mês de Abril. As figuras 20 e 21 apresentam como exemplo as segundas-feiras do mês de Janeiro para as duas subestações em estudo (ARARAS I e ATIBAIA) e as figuras 22 e 23 apresentam as terças-feiras do mês de Março de 2004 também para as duas subestações. As curvas correspondentes à média e as dos limites superior e inferior foram obtidas a partir da análise estatística e da DMH(2004) do estudo de

mercado. As demais correspondem a valores efetivamente verificados por medição.

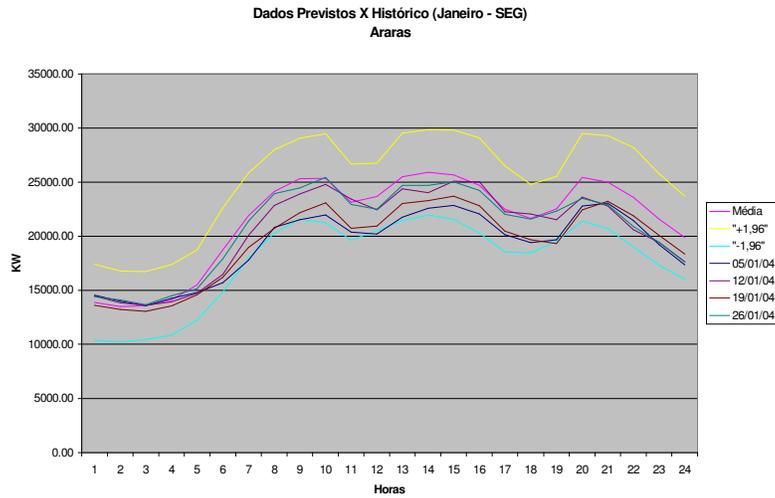


Figura 20 - 2ª feira de Janeiro/04, subestação ARARAS

Observa-se que as curvas de medição estão sistematicamente entre o limite inferior e a média, o que significa que se a previsão for baseada na curva pu média a tendência será de superestimar a potência requerida. Este efeito não é desejável e correções devem ser implementadas (inicialmente no percentual que a subestação atende do município) de modo que seja minimizado.

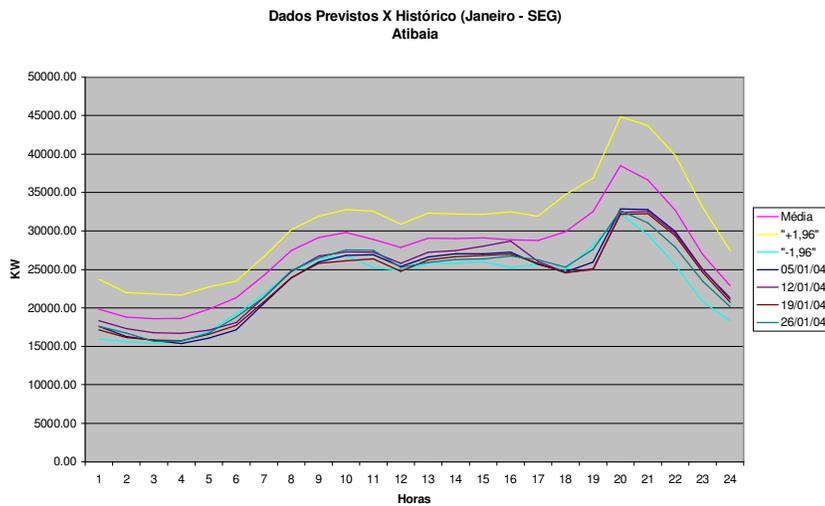


Figura 21 - 2ª feira de Janeiro/04, subestação ATIBAIA

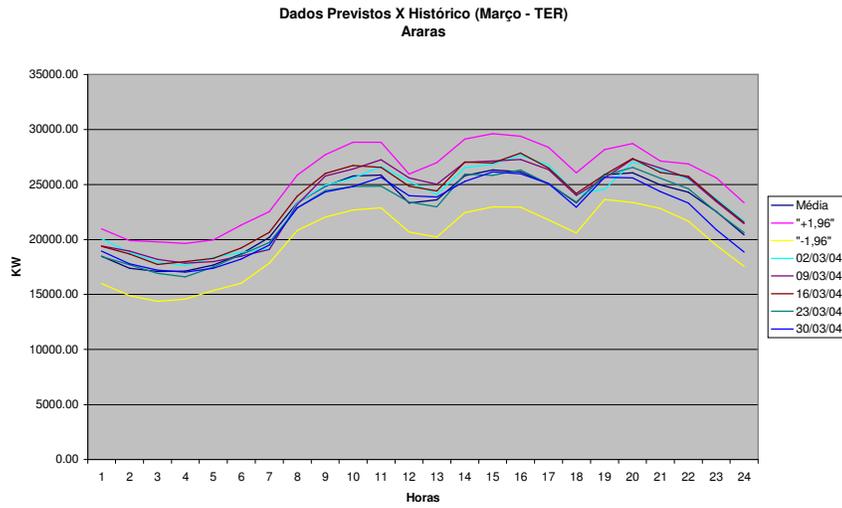


Figura 22 - 3ª feira de Março/04, subestação ARARAS

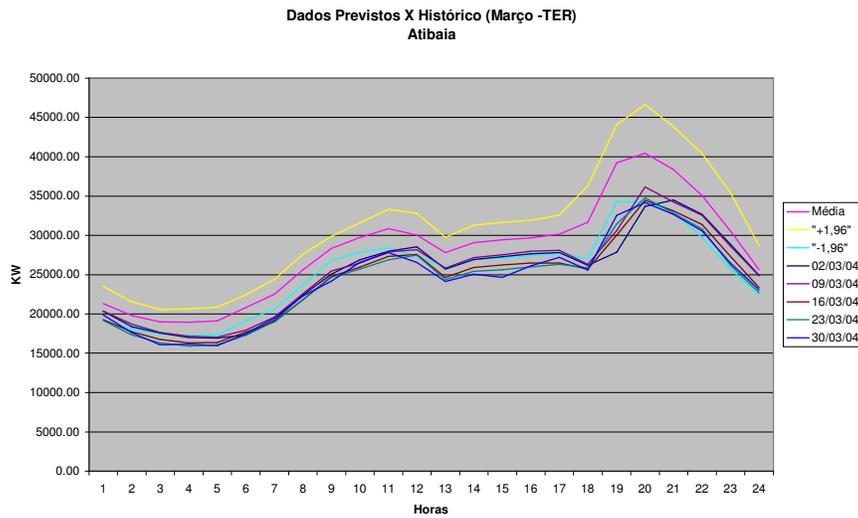


Figura 23 - 3ª feira de Março/04, subestação ATIBAIA

As previsões feitas para a subestação ARARAS apresentaram melhores resultados devido ao comportamento mais homogêneo da mesma em relação à subestação ATIBAIA. Atribui-se este comportamento diferenciado ao fato da subestação ARARAS possuir marcadamente cargas do tipo industrial, contrapondo-se à característica residencial da subestação ATIBAIA.

A previsão de carga reativa no instante t , através do modelo híbrido proposto, utilizará os dados de carga ativa previstos no mesmo instante e em instantes anteriores conforme a significância dos coeficientes estimados. Neste caso específico, a previsão será feita para as terças-feiras do mês de abril, por isso será utilizado o modelo estimado para o período “inverno”, como mostrado a seguir:

$$\begin{cases} Y_t = \beta_0 + \beta_1 X_t + \beta_2 X_{t-1} + \beta_3 Y_{t-1} + \beta_4 Y_{t-168} + u_t \\ R(\beta)u_t = \varepsilon_t \end{cases} \quad (5.7)$$

$R(\beta)$ é um AR(1)

onde:

Y_t : carga reativa em PU na hora t

X_t : carga ativa em PU na hora t

X_{t-1} : carga ativa em PU na hora $t-1$

Y_{t-1} : carga reativa em PU na hora $t-1$

Y_{t-168} : carga reativa em PU na hora $t-168$

ε_t : ruído aleatório associado ao modelo, onde se supõem que são independentes e identicamente distribuídos com densidade $N(0, \sigma^2)$.

A tabela 9 mostra os erros percentuais absolutos médios (MAPE) para as previsões horárias das terças-feiras do mês de março ano 2004.

As análises também foram feitas para os horários de carga leve (23h às 7h), carga média (8h às 17h) e carga pesada (18h às 22h).

Tabela 9 – MAPE carga ativa e reativa das terças-feiras de março/2004

Hora	ATIVA (%)	REATIVA (%)
1	3.26	6.60
2	4.10	4.78
3	2.77	2.62
4	2.76	6.70
5	2.01	3.93
6	2.03	3.73
7	4.50	13.43
8	2.31	3.54
9	2.63	5.75
10	3.16	2.26
11	2.79	9.24
12	4.46	3.93
13	2.26	7.86
14	2.41	5.82
15	1.69	2.10
16	2.94	3.68
17	3.16	2.77
18	1.90	3.85
19	3.00	2.21
20	2.49	6.36
21	3.19	2.30
22	3.49	7.25
23	3.89	8.07
24	4.27	2.04
Média	2.98	5.03
Carga Leve	3.29	5.77
Carga Média	2.78	4.69
Carga Pesada	2.81	4.39

Observa-se que, a previsão de potência reativa apresentou um erro maior pois é diretamente ligada aos dados de potência ativa previstos, ou seja, como estas já apresentaram erros consideráveis (média horária de 2.98%), então estes erros se propagaram para a previsão de reativo. Ainda assim, os resultados, ao nível de significância de 5%, foram considerados satisfatórios. Visto que, quanto melhor a previsão de carga ativa melhor será o desempenho do modelo proposto na previsão da carga reativa.