

5

Resultados das Modelagens Empíricas HW, BJ e ANNSTLF

5.1

Informações iniciais

Este capítulo apresenta os resultados obtidos pela implementação empírica das modelagens descritas no capítulo 2, que tratou teoricamente a formulação da técnica Holt-Winters, e no capítulo 3, que abordou o método de Box & Jenkins. Recorda-se que os métodos HW e BJ foram aplicados à série de demanda horária por carga elétrica da região sudeste no período de janeiro a dezembro de 2003 e as análises feitas são referentes a este banco de dados.

O objetivo dessa etapa do trabalho é avaliar o desempenho preditivo dos modelos HW e BJ com base nas previsões 01 passo-à-frente e 24 passos-à-frente. Em seguida, serão realizadas as devidas comparações destes resultados com aqueles referentes ao ANNSTLF e, logicamente, algumas conclusões fundamentadas nestas informações serão expostas.

5.2

O banco de dados

Abaixo está um quadro-resumo do banco dados utilizado:

Tabela 5.1: Banco de séries de dados

01/01/03 – 31/10/03	dados para análise <i>in-sample</i>
01/11/03 – 31/12/03	dados para análise <i>out-of-sample</i>
série original <i>in-sample</i>	7296 observações
série original diferenciada <i>in-sample</i> (diferenciação para o caso do modelo BJ)	7103 observações
série original <i>out-if-sample</i>	1464 observações
série original diferenciada <i>out-of-sample</i> (diferenciação para o caso do modelo BJ)	1248 observações

5.3

O critério de comparação dos modelos: MAPE

O Mape é calculado por:

$$(\text{MAPE}) = \frac{\sum |\text{valor real} - \text{valor previsto}|}{\text{valor real}} \cdot (100)$$

n= número de observações

O Mape (erro absoluto médio percentual) é o critério empregado para avaliar a qualidade do modelo. Quando menor o MAPE *out-of-sample* e o Mape *in-sample*, melhor a modelagem.

5.4

A Modelagem por Holt-Winters

5.4.1

Modelo HW com duplos ciclos ‘sem’ erros estruturados e ‘sem’ damped

A otimização dos valores para os quatro hiperparâmetros do modelo HW estendido (alfa, beta, gama e delta) foi feita no software MATLAB 6.1 através do comando “função *fmincon* (alfa, beta, gama e delta)”. Para que cada observação do vetor de dados (7296 X 1) correspondesse a respectiva hora no vetor dos fatores diários (1X24) e dos fatores semanais (1X168), foi empregada a função “*Modd*”, disponível no pacote do programa, que permitiu o rodízio da série pelas colunas dos vetores do ciclo 1 e do ciclo 2.

Utilizando os 7296 dados *in-sample* para o procedimento de otimização e as equações e a metodologia apresentadas no capítulo 2, os valores ótimos definidos estão dispostos nas tabelas 5.2, 5.3 e 5.4.

Tabela 5.2: Valores ótimos dos hiperparâmetros e parâmetros HW duplo ciclos

hiperparâmetros	valor ótimo	parâmetros	valor em t = 7296
Alfa	0,7719	nível (t)	25911
Beta	0	tendência (t)	-1,076
Gama	1	fatores ciclo1	vide tabela 5.8
Delta	0.7841	fatores ciclo 2	vide tabela 5.9

Tabela 5.3: Fatores do ciclo 1 em t = 7296

Hora (t)	Fator do ciclo 1 na hora (t)
1	1.0135
2	0.99349
3	0.98043
4	0.97106
5	0.96838
6	0.97236
7	0.98054
8	0.98291
9	0.99064
10	0.99568
11	1.00450
12	1.00721
13	1.01210
14	1.01340
15	1.01270
16	1.01170
17	1.00340
18	0.97904
19	0.91516
20	0.98852
21	1.05540
22	1.00501
23	1.05570
24	1.04200
Soma total	24

Os fatores ótimos do ciclo 2 (semanal) estão no quadro 5.4.


Tabela 5.4: Fatores do ciclo 2 em t = 7296

Hora (t)	Fatores do ciclo 2 na hora (t)	Hora (t)	Fatores do ciclo 2 na hora (t)	Hora (t)	Fatores do ciclo 2 na hora (t)	Hora (t)	Fatores do ciclo 2 na hora (t)
1	0.80924	43	1.12040	85	0.98376	127	1.0830
2	0.76143	44	1.12150	86	0.99424	128	1.1319
3	0.75218	45	1.12420	87	1.00100	129	1.2091
4	0.75544	46	1.11210	88	1.01120	130	1.2492
5	0.77060	47	1.07480	89	1.02930	131	1.2680
6	0.80534	48	1.00160	90	1.08360	132	1.2486
7	0.87053	49	0.91084	91	1.23460	133	1.2178
8	0.91720	50	0.87298	92	1.29230	134	1.2230
9	0.98001	51	0.84441	93	1.28390	135	1.2242
10	1.00960	52	0.82993	94	1.23920	136	1.2143
11	1.01960	53	0.82978	95	1.18120	137	1.2065
12	0.99797	54	0.85316	96	1.10360	138	1.1834
13	0.96567	55	0.90425	97	1.01430	139	1.2193
14	0.95919	56	0.94295	98	0.96476	140	1.2072
15	0.94391	57	1.00130	99	0.91939	141	1.1997
16	0.92069	58	1.03350	100	0.88959	142	1.1769
17	0.90651	59	1.05300	101	0.87334	143	1.1251
18	0.87974	60	1.04910	102	0.85941	144	1.0330
19	0.90780	61	1.03710	103	0.81595	145	0.9451
20	0.87864	62	1.05980	104	0.79901	146	0.8927
21	0.85751	63	1.08010	105	0.83587	147	0.8655
22	0.84284	64	1.08200	106	0.87334	148	0.8571
23	0.80534	65	1.08150	107	0.90152	149	0.8647
24	0.74852	66	1.07960	108	0.92316	150	0.8995
25	0.68561	67	1.15120	109	0.94475	151	0.9690
26	0.66604	68	1.15960	110	0.95189	152	1.0145
27	0.66349	69	1.14830	111	0.96291	153	1.0837
28	0.66832	70	1.12680	112	0.99509	154	1.1182
29	0.68467	71	1.08800	113	1.03570	155	1.1404

Hora (t)	Fatores do ciclo 2 na hora (t)	Hora (t)	Fatores do ciclo 2 na hora (t)	Hora (t)	Fatores do ciclo 2 na hora (t)	Hora (t)	Fatores do ciclo 2 na hora (t)
30	0.72160	72	1.02280	114	1.1284	156	1.1246
31	0.78627	73	0.88667	115	1.3093	157	1.0931
32	0.83183	74	0.92136	116	1.4008	158	1.0931
33	0.89673	75	0.85226	117	1.4302	159	1.0900
34	0.93884	76	0.83651	118	1.3867	160	1.0715
35	0.96551	77	0.82941	119	1.3172	161	1.0544
36	0.96822	78	0.83110	120	1.2052	162	1.0273
37	0.96168	79	0.82579	121	1.1023	163	1.0569
38	0.98649	80	0.86125	122	1.0515	164	1.0326
39	1.01810	81	0.91920	123	1.0109	165	1.0164
40	1.03220	82	0.95254	124	0.9861	166	0.9967
41	1.05230	83	0.97576	125	0.9797	167	0.9552
42	1.05610	84	0.97601	126	1.0141	168	0.8762

Segundo a tabela 5.2 os números sugerem que, quanto ao ciclo 1 (diário), a informação do instante presente é muito importante para a previsão, pois $\gamma = 1$. Por outro lado, a tendência da série aparece totalmente relacionada a tendência dos dados passados ($\beta = 0,00$). Para o nível e para o ciclo2 (semanal) constata-se que o dado recente é mais importante para explicar a informação atual, mas há uma contribuição também dos dados passados ($\delta = 0,7841$).

O MAPE *in-sample* do modelo HW com dois ciclos para a série em estudo foi de 0,3434%. O gráfico 5.1 desenha o ajuste do modelo aos dados da amostra para 100 observações. Verifica-se que o ajuste *in-sample* é muito bom.

Gráfico 5.1: Ajuste do modelo HW com duplos ciclos *in-sample*

Com os valores ótimos obtidos, a equação de previsão do modelo pode ser escrita da seguinte maneira:

$$\hat{Z}_{7296}(\tau) = [(25911 + \tau (-1.076))] * \hat{c}_{1(t) h_1(t + \tau)} * \hat{c}_{2(t) h_2(t + \tau)}$$

↓
tabela 5.4

↓
tabela 5.5

Para 01 passo-à-frente: $\tau = 1$;

Para 24 passos-à-frente $\tau = 24$.

Para avaliar o poder de generalização do modelo para 01 hora e para 01 dia-à-frente a origem 't' precisa ser deslocada. Essa análise *out-of-sample* gera os seguintes resultados:

Caso A: HW com dois ciclos *out-of-sample* 01 passo-à-frente:

- MAPE = 0,53 %

Gráfico 5.2: Dados previstos X dados reais *out-of-sample* (01 passo) (horas 1 até 168 = 1 semana)






Gráfico 5.3: Dados previstos X dados reais *out-of-sample* (01 passo) (horas 169 até 336 = uma semana)



Caso B: HW com dois ciclos na análise *out-of-sample* 24 passos-à-frente:

- MAPE = 1,6 %

Gráfico 5.4: Dados previstos X dados reais *out-of-sample* (24 passos) (horas 1 até 100)



5.4.2

Modelagem HW com duplos ciclos e damped e 'sem' erros estruturados

A constante de amortecimento possibilita avaliar o quanto o modelo é sensível à tendência. A sensibilidade do modelo estimado à taxa de crescimento parece ser muito pequena em virtude dos valores ótimos assumidos pela tendência da série no procedimento *in-sample* de atualização dos parâmetros serem sempre inferiores à 0.5.

A incorporação da variável de *damped trend* para os horizontes maiores que um, quando $\tau = 2, 3, 4, 5 \dots 24$, e empregando como default $\phi = 0.95$, cria um amortecimento da seguinte forma:

- quando $\tau = 2$: $damped = (0.95)^0 + (0.95)^1$
- quando $\tau = 3$: $damped = (0.95)^0 + (0.95)^1 + (0.95)^2$, e nesse raciocínio sucessivamente, até $\tau = 24$.
- quando $\tau = 24$: $damped = (0.95)^0 + (0.95)^1 + (0.95)^2 + (0.95)^3 + (0.95)^4 + (0.95)^5 + (0.95)^6 + (0.95)^7 + (0.95)^8 + (0.95)^9 + (0.95)^{10} + (0.95)^{11} + (0.95)^{12} + (0.95)^{13} + (0.95)^{14} + (0.95)^{15} + (0.95)^{16} + (0.95)^{17} + (0.95)^{18} + (0.95)^{19} + (0.95)^{20} + (0.95)^{21} + (0.95)^{22} + (0.95)^{23}$.

Corroborando com a hipótese inicial de um modelo pouco sensível à tendência, foi verificado que a constante de amortecimento, uma vez considerada endógena na modelagem, não causa um impacto significativo. O MAPE para 24 passos-à-frente passa de (1,5639 = 1,6%) “sem *damped trend*” para (1,570 = 1,6%) “com *damped trend*”. O *damped*, a grosso modo, piora o modelo provocando um aumento do erro, no entanto, esse acréscimo é irrelevante. Portanto, os resultados permanecem essencialmente idênticos aos apresentados na seção 5.3.1.

5.4.3

Modelagem Holt-Winters com duplos ciclos e ‘com’ erros estruturados

A modelagem HW com dois ciclos e adotando erros estruturados como um AR (1) seguiu basicamente os mesmos procedimentos efetuados na seção 5.3.1. Inicialmente foi preciso redefinir os valores dos hiperparâmetros do modelo, porém, considerando agora cinco hiperparâmetros (*alfa*, *beta*, *gama*, *delta*, *lambda*). Lembrando que *lambda* refere-se a sensibilidade do modelo ao erro imediatamente anterior.

Os valores definidos nesta situação 5.3.3 são mostrados na tabela 5.5.

Tabela 5.5: Valores ótimos dos hiperparâmetros e parâmetros HW duplo ciclos considerando o modelo com erros estruturados da forma AR (1).

hiperparâmetros	valor ótimo	parâmetros	valor em t = 7296
alfa	0.2041	nível (t)	25802
beta	0.0000	tendência (t)	-1.076
gama	0.0000	fatores ciclo1	vide tabela 5.3
delta	0.2784	fatores ciclo 2	vide tabela 5.4
lambda	0.8751	-	-

Nota-se que ao incorporar a estrutura de autocorrelação dos erros ao modelo, os valores otimizados do nível, tendência, fator 1 e fator 2, em relação ao caso da modelagem apenas com duplo ciclos (seção 5.3.1), são diminuídos. Isso significa

que o passado da série ganha uma importância ainda maior nesta formulação, em comparação ao primeiro caso, para explicar os valores presentes da demanda energética e, além disso, o erro cometido no período anterior é substancialmente necessário para explicar a informação atual.

Considerando o modelo com a presença de dependência entre os termos de erros aleatórios e os valores ótimos dos hiperparâmetros descritos na tabela 5.5, tem-se:

- MAPE *in-sample* = 0.30 %

Quanto aos novos valores do vetor de fatores diário e semanal, estes ficam praticamente inalterados em relação aos números expostos nas tabelas 5.3 e 5.4 da seção 5.3.1.

Sobre a análise *out-of-sample* para as previsões 01 passo-à-frente e 24 passos-à-frente, os resultados encontrados foram:

- MAPE *out-of-sample* 01 passo-à-frente: 0,47 %.
- MAPE *out-of-sample* 24 passo-à-frente: 1,531 %.

É evidente que essa última formulação em relação as duas anteriores é mais robusta e acurada. Os resultados *out-of-sample* são melhorados ao se incorporar ao modelo o termo de erro com um estrutura AR (1).

Tendo os resultados das três formas alternativas da modelagem HW, é preciso avaliar a modelagem aperfeiçoada por Box & Jenkins para finalmente realizar algumas comparações com as estimativas do ANNSTLF.

5.5

Modelagem empírica por Box & Jenkins

5.5.1

Para 01 passo à frente BJ

Os resultados do método por Box & Jenkins estão colocados a seguir. Salienta-se que as informações estão baseadas no melhor modelo encontrado pela

técnica e, como foi visto no capítulo 3, os resíduos do modelo selecionado formam uma série ruído branco, o que garante que não há falta e nem excesso de parâmetros na modelagem. Neste caso, também nenhuma variável causal é extremamente relevante para prever a série.

Esta última constatação é importante ser mencionada, pois, um dos objetivos do estudo é comparar as previsões do modelo univariado aperfeiçoado BJ escolhido com as estimativas do ANNSTLF, lembrando que o software se utiliza das informações do tempo em suas previsões.

Os gráficos 5.5 e 5.6 mostra o ajuste *in-sample* do modelo para 336 observações.

Gráfico 5.5: Ajuste *in-sample* do modelo BJ com dois ciclos (horas 1 até 168)


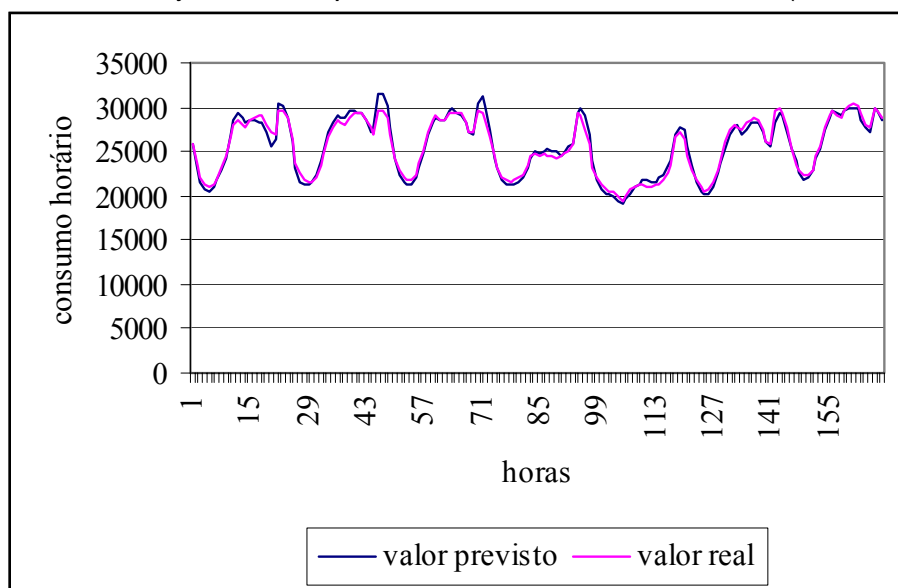



Gráfico 5.6: Ajuste *in-sample* do modelo BJ com dois ciclos (horas 169 até 336)

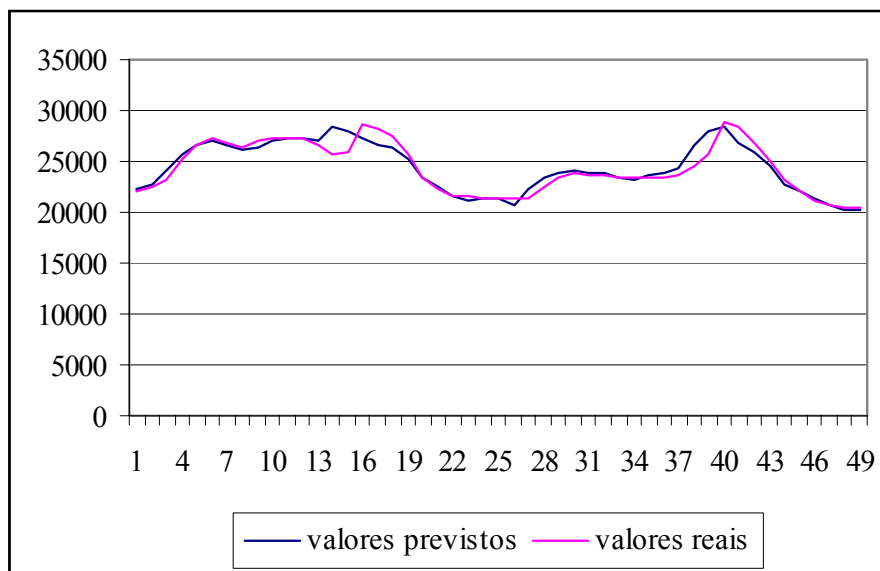
Os gráficos 5.5 e 5.6 possibilitam visualizar a discrepância que está ocorrendo entre os dados reais e as previsões *in-sample*.

Para a averiguação *out-of-sample* foram usadas 1248 observações da série diferenciada que foram guardadas com o intuito de avaliar o poder de generalização do modelo estimado. Em 01 passo-à-frente, tem-se os gráficos 5.7 e 5.8 que fazem o delineamento dos dados reais e as previsões.

Gráfico 5.7: Valor previsto X valor real BJ (*out-of-sample* 168 horas) 01 passo-à-frente

O Gráfico 5.8 plota menos dados que a figura 5.7, apenas 48 observações e mostra com mais detalhes o quanto as informações reais e previstas se distanciam.

Gráfico 5.8: Valor previsto X valor real BJ (*out-of-sample* 48 dados) 01 passo-à-frente



Em resumo:

Tabela 5.6: MAPE *in-sample* X MAPE *out-of-sample* (01 passo-à-frente).

MAPE <i>in-sample</i>	0,78%
MAPE <i>out-of-sample</i> 01 passo-à-frente	1,10%

O MAPE *out-of-sample* que é o critério para avaliar o poder de generalização do modelo, para 01 passo-à-frente foi 1,1%, um valor alto se for levado em conta que o ANNSTLF, nas suas previsões 24 passos-à-frente, possui um MAPE inferior a 2% para a região sudeste.

Como a intenção deste estudo é averiguar tanto as previsões 01 passo-à-frente quanto as previsões 24 passos-à-frente, é preciso ainda avaliar o desempenho preditivo do modelo BJ 01 dia-à-frente ou 24 horas. Isto será avaliado na próxima seção.

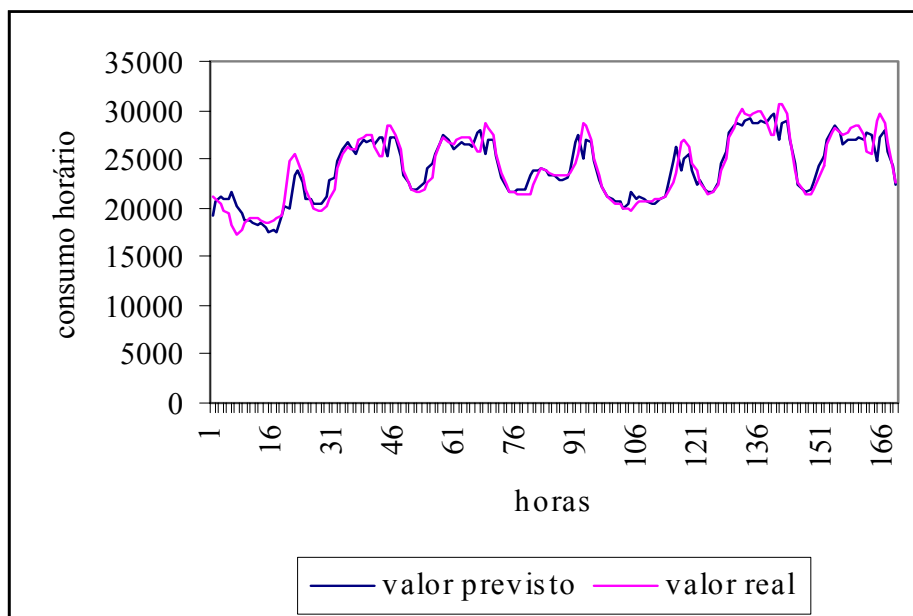
5.5.2

Para 24 passos – à – frente BJ

Com a pretensão de prever 24 passos à frente, é necessário ter a previsão de Z_{7103} (23) de acordo com a equação do modelo apresentada no capítulo III. Isso exigiu que se fizesse as previsões para além de 01 passo-à-frente, ou seja, o cálculo das previsões 02; 03; 04;23 horizontes a fim de prever 24 passos-à-frente. Embora essas previsões intermediárias não estejam no foco da pesquisa e em debate, é válido deixar registrado que o MAPE das mesmas não ultrapassa o limite dos 2,0% no máximo.

A previsão, na origem $t = 7103$ para 24 passos-à-frente, foi iniciada prevendo a observação 7127. Logo, dos dados *out-of-sample*, perdeu-se 24 observações ($1248 - 24 = 1224$ previsões realizadas). A seguir o gráfico 5.9 traduz os valores reais e previstos.

Gráfico 5.9: Valores reais X valores previstos BJ (24 passos à frente). *out-of-sample*



O valor do MAPE *out-of-sample* para 24 passos-à-frente é 2,2%. Nota-se uma piora nos resultados, em relação às previsões 01 passo-à-frente (MAPE 1,10%). Para todas as observações, o MAPE *out-of-sample*, individualmente para cada dado, é maior do que o MAPE *in-sample* em todos os casos sinalizando que

o modelo já não é adequado para efetuar as previsões pretendidas quando τ (horizonte de previsão) = 24.

Sobre esta implementação empírica BJ realizada, apresenta-se a tabela 5.7 que dispõe as principais informações de interesse.

Tabela 5.7: MAPE *in-sample* X MAPE *out-of-sample* (01 e 24 passos-à-frente)

MAPE <i>in-sample</i>	0,78%
MAPE <i>out-of-sample</i> (01 passo- à -frente)	1,10%
MAPE <i>out-of-sample</i> (24 passos -à- frente)	2,20%

5.6

As previsões do ANNSTLF e as previsões por Holt-Winters e Box & Jenkins

No capítulo 4, foram colocados alguns detalhes importantes para a compreensão de como são obtidas as estimativas do ANNSTLF. Apesar de se reconhecer as vantagens do software, questionou-se algumas de suas limitações que acabam por despertar o desejo de buscar novas formas para gerar as previsões do consumo de carga de curto prazo, a fim de executar com sucesso o controle do sistema elétrico brasileiro de forma mais eficiente e menos custosa.

As modelagens descritas nos capítulos 2 e 3, cujas análises e resultados empíricos estão aqui colocados, servem para avaliar um pouco mais o programa em uso pelo ONS, já que os dados em investigação são os mesmos com os quais o órgão trabalha e prevê.

Ressalta-se que, o ANNSTLF entrou em uso no Brasil em julho de 2003 e aqui foram verificados os dados para todos os 12 meses de 2003. Além disso, a análise *out-of-sample* foi feita para os meses de novembro e dezembro e o MAPE fornecido pelas previsões do ANNSTLF é relativo ao período da aplicação do programa no país em 2003, aproximadamente os últimos 6 meses do ano.

A partir dos resultados da tabela 5.8, que resume as informações apuradas neste capítulo, pode-se expor algumas importantes considerações.

Tabela 5.8: Comparações do MAPE do ANNSTLF X BJ X HW

Tipo de modelo	MAPE <i>in-sample</i>	MAPE <i>out-of-sample</i>
ANNSTLF 01 passo (sudeste)	-	-
ANNSTLF 24 passos (sudeste)	-	1,41 %
BJ duplo ciclos 01 passo	0,78%	1,10 %
BJ duplo ciclos 24 passos	0,78%	2,20 %
HW duplo ciclos 01 passo	0,3434 %	0,53 %
HW duplo ciclos 24 passos	0,3434 %	1,60 %
HW duplo ciclos e damped 24 passos	0,3434%	1,60%
HW duplo ciclos e erros AR(1) 01 passo	0,30%	0,47 %
HW duplo ciclos e erros AR(1) 24 passos	0,30%	1,531 %

Embora os dados desta pesquisa se refiram unicamente ao subsistema do sudeste brasileiro, para uma averiguação mais completa e consistente, os resultados das modelagens BJ e HW, mostrados nas seções anteriores, serão comparados com as previsões do ANNSTLF para as regiões sudeste, sul, nordeste e norte. A razão de se proceder dessa forma ficará clara no decorrer das análises que se seguirão.

As tabelas 5.9, 5.10, 5.11 e 5.12 dizem respeito às previsões 24 passos-à-frente para os subsistemas mencionados feitas pelo ANNSTLF. O MAPE para as previsões 01 passo-à-frente do programa não pôde ser fornecido, pois o órgão considera essa informação confidencial. O conteúdo dos quadros são de domínio público e foram divulgados em um encontro de usuários do programa ocorrido na Flórida/EUA em 2004.

Tabela 5.9: MAPE ANNSTLF para o sudeste em 2003 e 2004

1 day ahead 2003 - SouthEast										
	Mon	Tue	Wed	Thu	Fri	Sat	Sun	Workday	Weekday	Allday
All Hours	1.62	1.35	1.30	1.18	1.81	1.27	1.31	1.46	1.29	1.41
Total Day	1.25	1.03	1.00	0.77	1.46	0.81	0.87	1.10	0.84	1.03
Peak Load	1.26	1.07	1.22	1.09	1.58	1.33	1.26	1.24	1.30	1.26
1 day ahead 2004										
All Hours	1.67	1.00	1.30	1.02	1.60	1.36	1.25	1.32	1.30	1.31
Daily Total	1.45	0.68	0.98	0.57	1.17	1.04	0.74	0.97	0.89	0.95
Peak Load	1.74	1.35	1.30	1.29	1.58	1.31	1.07	1.45	1.19	1.37

Fonte: ONS

Tabela 5.10: MAPE ANNSTLF para o sul em 2003 e 2004

1 day ahead 2003 - South										
	Mon	Tue	Wed	Thu	Fri	Sat	Sun	Workday	Weekday	Allday
All Hours	2.05	1.65	1.49	1.76	2.12	1.85	2.17	1.81	2.01	1.87
Total Day	1.54	1.16	1.12	1.39	1.66	1.26	1.58	1.38	1.42	1.39
Peak Load	2.08	1.85	1.66	1.86	1.64	2.23	2.25	1.82	2.24	1.94
1 day ahead 2004										
All Hours	3.42	1.82	1.92	1.99	2.50	1.94	3.76	2.35	2.87	2.50
Daily Total	3.07	1.45	1.52	1.65	2.09	1.25	3.03	1.97	2.17	2.01
Peak Load	3.22	1.67	2.17	2.89	1.89	2.47	3.32	2.38	2.91	2.52

Fonte: ONS

Tabela 5.11: MAPE ANNSTLF para o norte em 2003 e 2004

1 day ahead 2003 - North										
	Mon	Tue	Wed	Thu	Fri	Sat	Sun	Workday	Weekday	Allday
All Hours	1.84	1.83	1.59	1.47	1.96	1.88	2.18	1.74	2.03	1.87
Total Day	1.31	1.40	1.01	1.01	1.39	1.22	1.48	1.22	1.35	1.26
Peak Load	1.55	1.81	1.11	1.35	1.71	1.69	1.67	1.50	1.68	1.56
1 day ahead 2004										
All Hours	1.77	1.62	1.45	1.43	1.45	1.46	1.61	1.55	1.54	1.54
Daily Total	1.39	1.30	1.04	1.07	1.15	0.99	0.89	1.19	0.94	1.12
Peak Load	1.38	1.19	1.14	0.99	1.36	1.28	1.07	1.21	1.17	1.20

Fonte: ONS

Tabela 5.12: MAPE ANNSTLF para o nordeste em 2003 e 2004

1 day ahead 2003 - NorthEast										
	Mon	Tue	Wed	Thu	Fri	Sat	Sun	Workday	Weekday	Allday
All Hours	1.72	1.43	1.47	1.51	1.61	1.86	1.73	1.55	1.80	1.62
Total Day	1.20	0.93	1.06	1.14	1.04	1.27	1.04	1.07	1.16	1.10
Peak Load	1.82	1.25	1.29	1.38	1.17	1.69	1.60	1.38	1.65	1.46
1 day ahead 2004										
All Hours	2.20	1.62	1.95	1.60	1.93	2.03	1.91	1.86	1.97	1.89
Daily Total	1.53	1.25	1.47	1.17	1.41	1.26	1.02	1.36	1.14	1.30
Peak Load	2.17	1.75	1.35	1.50	1.59	1.42	1.55	1.67	1.49	1.62

Fonte: ONS

Pode ser visto pela tabela 5.9 que, para o sudeste, em todas as horas e em todos os dias em 2003, o MAPE, que aparece assinalado, é de 1,41%, quase metade do MAPE calculado para o modelo Box & Jenkins em 24 passos-à-frente (2,2%), e também inferior ao MAPE do modelo HW assumindo dois ciclos (1,6%) e HW com dois ciclos e erros estruturados (1,53%). O MAPE para as regiões norte e nordeste, como pode ser notado nos quadros 5.11 e 5.12, apresenta números muito parecidos com o MAPE do sudeste. Os seus MAPE são inferiores ao do modelo BJ e aos do HW nas formulações especificadas.

Para o subsistema sul, que como foi explicado na capítulo 4 tem as piores previsões fornecidas pelo ANNSTLF havendo a necessidade inclusive de um retreinamento da rede, conforme a tabela 5.10, apesar do seu MAPE, para todos os dias e todas as horas ser superior ao verificado nas outras três regiões e que estão expostos nas tabelas 5.9, 5.11 e 5.12, comparativamente aos 2,2% da modelagem BJ, o seu MAPE é baixo: 1,87% em 2003 e 2,5% em 2004. É alto se for comparado com aos 1,6 e 1,53% dos modelos HW, mas esse contraste deve ser visto com reservas porque os dados foram pesquisados somente para a região sudeste.

Os quatro quadros anteriores ainda trazem detalhes quanto ao MAPE por dia da semana, para dias úteis e para os fins de semana. Há informações para o ano de 2003 que se referem aos mesmos dados que foram modelados no estudo e para o ano de 2004, que serve como registro para pautar e corroborar as conclusões extraídas por este trabalho.

É interessante comentar que as tabelas permitem também dizer que o MAPE das segundas-feiras encontra-se mais próximo do MAPE calculado nos fins de

semana que nos demais quatro dias comuns de trabalho. Esta observação foi salientada no capítulo precedente e este capítulo confirma e entra em concordância com a recomendação sugerida pelo ONS quanto a cautela para avaliar o comportamento da demanda por carga elétrica, especialmente, nesse primeiro dia útil da semana.

5.7

Detalhes adicionais da modelagem HW por dias da semana, horas e feriados

É interessante observar, para a modelagem HW, como se comportam as suas previsões em cada hora do dia, por dias úteis, fins de semana e feriados. Este detalhamento será colocado como curiosidade apenas para o modelo HW, já que os resultados desses modelos superam aqueles obtidos pelos modelos BJ.

É válido esclarecer que os dias definidos como feriados referem-se a datas consideradas como feriados oficiais e nacionais. Para o ano de 2003, estes dias são relativos as seguintes datas:

- 01/01/03 – Confraternização Universal
- 04/03/03 – Carnaval
- 18/04/03 – Paixão
- 21/04/03 – Tiradentes
- 01/05/03 – Dia do Trabalho
- 19/06/03 – Corpus Christi
- 15/11/03 – Proclamação da República
- 25/12/03 – Natal

Dessas datas somente as duas últimas constam no conjunto de dados para a previsão *out-of-sample*. As demais encontram-se no banco de dados *in-sample*.

Os MAPE do modelo HW com dois ciclos para os feriados mencionados e para cada dia da semana pode ser conferido na tabela 5.13.

Tabela 5.13: MAPE - previsões 2003 com discriminação de data e dias.

Datas e Dias da semana	MAPE <i>in-sample</i>	MAPE <i>out-of-sample</i> 24 passos-à-frente
segunda-feira	0,243605	2,227896
terça-feira	0,192068	1,962544
quarta-feira	0,142894	0,963255
quinta-feira	0,091287	0,278933
sexta-feira	0,110512	0,480987
sábado	0,165973	0,678922
domingo	0,279483	0,968555
feriados	0,394126	2,889744

A tabela 5.14 permite verificar os valores dos MAPE por hora do dia.

Tabela 5.14: MAPE horário

Hora do dia	MAPE <i>in-sample</i>	MAPE <i>out-of-sample</i> 24 passos-à-frente
01	0,0447870	0,6272200
02	0,2465200	1,9696000
03	0,1237100	0,8586200
04	0,1292100	0,8680100
05	0,2682900	1,9939400
06	0,0220060	0,4098000
07	0,0693380	0,8617800
08	0,1533900	0,9362800
09	0,1672222	0,9962000
10	0,2356900	1,1596700
11	0,3498800	1,5160000
12	0,2932300	1,995830
13	0,4835300	2,0528900
14	0,7001100	2,9718300
15	0,6411400	2,0474750
16	0,6355200	1,8474750

17	0,4543200	1,8743200
18	0,4605300	1,9543200
19	0,6479900	1,9979000
20	0,0062124	0,6664100
21	0,0967350	0,1358700
22	0,1755100	0,8060100
23	0,2306100	0,8960000
24	0,0104100	0,4123600

5.8

Considerações finais

As análises apresentadas ao longo do capítulo buscaram explicitar os resultados empíricos da aplicação dos modelos estendidos Box & Jenkins e Holt-Winters aos dados da demanda por carga elétrica do sudeste brasileiro em 2003. Algumas outras informações sobre os procedimentos efetuados para se definir os modelos que foram utilizados na implementação estão detalhados nos capítulos 2 e 3.

Os resultados obtidos foram comparados com aqueles fornecidos pelo ANNSTLF, que se baseia na técnica de uma rede neural e emprega como entrada tanto dados da própria série de demanda quanto informações da temperatura prevista. Sob este ponto de vista, os valores do MAPE para as previsões 01 passo-à-frente e 24 passos-à-frente do modelo BJ podem até ser considerados satisfatórios, pois num método univariado somente dados defasados da série são usados e, portanto, os dados do tempo foram ignorados. Num outro tipo de modelagem por Box & Jenkins usando uma função de transferência pode-se incluir a variável temperatura, mas essa forma de modelo não foi explorada no trabalho.

Já a modelagem HW com dois ciclos e/ou erros estruturados apresentou resultados melhores que os da modelagem BJ, mas não superaram as previsões pelo ANNSTLF. Como das previsões em posse do ONS dependem o bom desempenho e funcionamento do sistema elétrico e a qualidade dos investimentos

a serem feitos. Quanto menor o erro, melhor a previsão e decisões com maiores possibilidades de acertos e sucesso são tomadas.

Sabendo que a utilização do ANNSTLF vem atrelado a um custo financeiro, pode ser que a perda em precisão ao se prever a demanda por carga com um modelo univariado como BJ ou HW, que obteve melhor desempenho, compense a economia e a autonomia que o órgão ganha para manipular os modelos conforme as necessidades que surgem.

Este capítulo teve por finalidade a comparação de duas importantes modelagens univariadas aperfeiçoadas com a modelagem do ANNSTLF, sem contudo, pretender com isso fechar a questão. Ao contrário, o interesse maior do trabalho como um todo é abrir um leque de opções e possibilidades para que as previsões da demanda elétrica sejam feitas da melhor forma possível, gerando ganhos para todos e com o mínimo de desperdícios possível. Neste sentido, para atingir esse objetivo os estudos devem ser continuados futuramente.