

3

CARGA DE UMA DISTRIBUIDORA DE ENERGIA ELÉTRICA COM MODELOS ARMA

3.1

Introdução

A previsão da quantidade de energia elétrica que será demandada pelos seus clientes é extremamente importante para uma distribuidora de eletricidade. Em sabendo a quantidade de carga que lhe será demandada, a distribuidora poderá otimizar a sua carteira de contratos de fornecimento de energia, de forma a maximizar o seu lucro sem correr riscos de não poder fazer face a seus compromissos de fornecimento, reduzindo o desperdício de recursos escassos não só caros, mas também importantes.

A literatura sobre previsão de carga é bem farta em trabalhos de previsão, embora em sua maioria estes sejam a respeito de previsões de prazo curto e médio (Kodogiannis, 2000; Teixeira e Zaverucha, 2002; Soares e Souza, 2006; Soares e Medeiros, 2008; Hinman e Hickey, 2009).

No que diz respeito aos prazos de previsão da carga demandada, estes podem ser divididos em três grupos: curto prazo, médio e longo prazo. O chamado curto prazo refere-se a períodos da ordem de um dia, normalmente estendendo-se até a previsão do dia seguinte; considera-se médio prazo o tempo a partir do final do curto prazo e até cerca de um ano à frente, com o longo prazo sendo aquelas previsões que excedam um ano (Bunn, 2000; Alfares e Nazeeruddin, 2002). Estes autores consideram que, embora seja reconhecido que o mercado de energia elétrica tem características singulares, que o tornam de difícil modelagem através da aplicação direta de modelos de séries temporais, estes

métodos ainda parecem não só ser os mais populares, mas para a previsão de carga no curto prazo.

Alguns pesquisadores têm utilizado os métodos de séries temporais, abordagens reconhecidamente com foco na previsão de curto-prazo (Pindyck e Rubinfeld, 1998) para fazer previsões em prazos mais longos, utilizando modelos ARMA combinados com variáveis exógenas ligadas ao ambiente onde é observada a demanda, como temperatura e PIB, gerando os modelos conhecidos como ARMAX e outros parentes próximos (Weron, 2006). A escolha das variáveis exógenas sempre se centra em características demográficas e ambientais do local onde se observa o consumo de energia elétrica.

O problema de estudo do presente trabalho está centrado na extensão da aplicação deste tipo de modelos, que é feita por algumas operadoras nacionais, para a previsão de cargas demandadas em horizontes mais longos, muitas vezes estendendo-se a meses e anos.

A regra de bolso para modelos auto-regressivos de média móvel é que a sua previsão só deve ser estendida até um período máximo equivalente a $(p+q)$, onde p e q são, respectivamente, os números de defasagens para o modelo auto-regressivo e o de média móvel (Pindyck e Rubinfeld, 1998). Assim, a indagação que este trabalho procura responder é, “dado que a previsão está sendo feita com um modelo ARMA (apropriado para curto-prazo), até que ponto o erro de previsão esperado pode afetar a escolha da modelagem usada?”

Na seção (2) deste trabalho faremos uma breve revisão da bibliografia sobre séries temporais, incluindo os efeitos da modelagem do processo subjacente de geração de dados das séries (*DGP*), da capacidade preditiva de diferentes modelos em função da forma de modelagem dos dados observados, da influência da escolha de como particionar os dados entre amostra *in-sample* e amostra *out-of-sample*, na seção (3) apresentaremos a metodologia utilizada para modelagem dos dados disponíveis, na seção (4) apresentaremos uma discussão dos resultados obtidos com os modelos escolhidos e, finalmente, na seção (5) finalizaremos apresentando conclusões e sugestões para trabalhos futuros.

3.2

Referencial Teórico

No referencial teórico procuraremos falar sobre os trabalhos desenvolvidos na modelagem de cargas, com o objetivo de reconhecer quais são as modelagens mais utilizadas, e para que tipo de serviço de previsão elas mais se adaptam, se de longo, médio ou curto prazo.

Em seguida falaremos sobre a estacionaridade das séries, e em que medida o processo de geração de dados destas pode influenciar os resultados obtidos por modelagens feitas por um ou outro modo, bem como formas de diferenciar entre eles.

Por último, trataremos de que forma devemos encarar uma amostra (de séries temporais) sob o ponto de vista de qual influência pode ter sua manipulação.

3.2.1

Trabalhos Desenvolvidos

Na literatura sobre o assunto previsão de carga, pode-se encontrar vários trabalhos desenvolvidos sobre o assunto de previsão no curto prazo. Para este horizonte de previsão, é bastante comum o uso de séries temporais (Alfares e Nazeeruddin, 2002; Hahn *et al.*, 2009).

Entretanto, neste trabalho é abordada uma previsão considerada de longo prazo, isto é, uma previsão com um horizonte acima de um ano. Nestes casos, o que se procura é identificar a distribuição provável da demanda e não uma previsão pontual (Hyndman e Shu, 2010).

A respeito da previsão da demanda, em si, é bastante bem estabelecida a importância da temperatura como variável climática a ser introduzida nos modelos de previsão (Feinberg e Genethliou, 2005). Mirasgedis *et al.* (2006) usa modelos auto-regressivos combinados com variáveis climáticas, em diferentes cenários, para previsão de demanda até doze meses à frente.

Entretanto, a maioria dos trabalhos publicados considera que a eletricidade é utilizada tanto para o para o resfriamento em dias quentes, como para o aquecimento em dias frios, os chamados *HDD* (*hot degree days*) e *CDD* (*cold degree days*), o que não é o caso para as localidades brasileiras, em geral, onde não há grandes sequências de dias significativamente frios.

No caso da modelagem de energia elétrica, essa influência é fortemente moderada pela situação social que ditará a propriedade (ou não) da eletricidade como uma fonte expressiva de aquecimento.

Para a previsão de carga em horizontes mais longos, a tendência é de usar técnicas modernas como lógica *fuzzy*, redes neurais e sistemas especialistas (Kandil *et al.*, 2002; Chang *et al.*, 2011; Chen e Wang, 2012), embora regressões também tenham sido usadas (Manera e Marzullo, 2005; Bianco *et al.*, 2009)

Previsões de carga no curto prazo permitem o uso de técnicas estatísticas, como regressões e séries temporais (Shyh-Jier e Kuang-Rong, 2003; Taylor, 2003; Taylor e Mcsharry, 2007; Taylor, 2012), muitas vezes acoplando-se variáveis exógenas (Chao-Ming *et al.*, 2005), principalmente quando se deseja estender o horizonte de previsão.

3.2.2

Séries Estacionárias por Tendência vs Diferenciação

Uma das primeiras preocupações dos pesquisadores ao se defrontarem com uma série temporal deve ser a de determinar a sua (da série) estacionaridade ou não (Brooks, 2008), uma vez que o uso de métodos desenvolvidos para séries estacionárias em dados não estacionários pode levar a regressões espúrias, ou seja, regressões que parecem boas, mas na realidade não tem qualquer significado prático.

No caso de séries temporais financeiras e econômicas, dois tratamentos alternativos dos dados podem levar a resultados bastante diferentes, sendo eles o tratamento das séries com sendo estacionárias

por diferenciação (*DS*) ou séries estacionárias por tendência (*TS*) (Diebold e Kilian, 2000).

O trabalho anterior defende que o uso de testes de raiz unitária das séries a serem modeladas podem ajudar, grandemente, na escolha dos modelos a serem utilizados, confirmando a orientação anterior da necessidade da constatação de estacionaridade. Por outro lado, os autores produzem evidências sobre qual das alternativas oferece a melhor capacidade de previsão, entre sempre diferenciar (as séries), nunca diferenciar ou testar a existência de uma raiz unitária antes de fazer a modelagem.

Indo além do caso acima, outro trabalho (Clements e Hendry, 2001) procura estudar a que tipo de erro pode estar sujeita a modelagem de uma série de dados em que o processo de geração de dados (*DGP* – *data generating process*) é um processo de diferenciação ou um processo com tendência, no caso da modelagem ser feita admitindo que o caso contrário é, na verdade, o *DGP*.

A grande indicação deste trabalho, considerando os dois tipos de processo com erros de ARMA e incerteza na estimação dos parâmetros, é que a variância do erro de previsão tende a ser mais bem comportada, quando a modelagem é feita por um *TS* (*trend stationary*) do que por um *DS* (*difference stationary*), exceto no caso em que a taxa de aumento da parte *in-sample* da amostra for maior do que a de aumento do horizonte de previsão.

3.2.3 Manipulação da Amostra

Uma das maiores preocupações com as amostras utilizadas em trabalhos empíricos diz respeito a “manipulação” das amostras. Esta manipulação pode ocorrer quando o mesmo conjunto de dados é utilizado mais de uma vez para inferências diferentes, ou seleção de modelos distintos; quando isto acontece, diz-se que os dados foram “manipulados”,

pois sempre existe a possibilidade de que resultados satisfatórios possam ter sido obtidos por pura sorte.

Como este tipo de procedimento é sabidamente frequente com dados de séries temporais, tal prática, embora devendo ser evitada, torna-se endêmica, o que faz ser extremamente importante a existência de testes simples e robustos que possam diferenciar entre o puro fator sorte e uma real melhoria da capacidade de previsão (Diebold e Mariano, 1995).

Se tais testes forem disponíveis, será possível examinar os dados disponíveis com um grande grau de certeza de que eventuais melhorias na previsão terão sido resultado de melhores modelos, e não pura sorte (White, 2000)

O trabalho inicial de White (2000), conquanto tenha tocado no ponto chave do problema, no que diz respeito ao controle do tamanho e dimensionamento da amostra, não fornece robustez à, por exemplo, escolha de janelas de estimação e de previsão, ou começo e fim de uma série temporal.

Trabalhos subsequentes pretendem justamente resolver o problema decorrente do número de modelos alternativos, para diferentes escolhas de dados, sendo que várias propostas podem ser encontradas na literatura, apenas considerando-se modelagens diferentes com a mesma amostra (Hansen, 2005; McCracken, 2007).

Outra forma de manipular os dados consiste na definição de diferentes partições da amostra disponível, para testes *in-sample* e *out-of-sample*. Nestes casos, a simples mudança do posicionamento do limite para final de um tipo de janela e começo da outra janela, pode fazer com que o desempenho preditivo de um modelo seja alterado significativamente.

Na realidade, possíveis distorções podem ocorrer em função da simples escolha de diferentes pontos de divisão da amostra, tornando inócuos os resultados dos testes convencionais de capacidade preditiva. Isto acontece apenas porque a divisão da amostra em duas partes é encarada como uma variável a ser considerada (Hansen e Timmermann, 2012).

O maior problema neste tipo de procedimento, o de escolha de janelas de estimação e previsão, é que não existem guias ou sugestões, sejam elas regras formais ou as chamadas regras-de-bolso. Assim, a escolha deste ponto de divisão fica extremamente vulnerável a práticas de “mineração de dados”, com o único objetivo de uma escolha de divisão da amostra que maximize o resultado que se pretende observar.

A preocupação com fenômenos como o descrito acima ensejou a produção de testes de capacidade preditiva que fossem robustos em relação à escolha do tamanho da janela de estimação (Rossi e Inoue, 2012).

3.3 Metodologia

O presente trabalho procurou reproduzir o procedimento utilizado em uma distribuidora nacional de energia elétrica, utilizando dados de carga, temperatura e PIB, para produzir uma previsão de carga demandada.

Para tal fim, foram colecionados dados de carga efetivamente demandada, acumulados em frequência mensal e oriundos de banco de dados da própria distribuidora, bem como dados públicos de temperatura média e evolução do PIB. Os primeiros a partir de dados da agência norte-americana NOAA (*National Oceanographic and Atmospheric Administration*), disponíveis no site http://www.cdc.noaa.gov/cgi-bin/db_search/SearchMenus.pl), e os últimos disponíveis no site do Banco Central do Brasil (<https://www.bcb.gov.br/pec/Indeco/Port/ie1-54.xls>). O período considerado neste trabalho foi o de Jan/2003 até Jul/2012, para todas as variáveis utilizadas.

Todos os cálculos foram feitos utilizando-se o programa *Eviews 7*, da *Quantitative Micro Software*.

3.3.1 Qualificação dos Dados

A escolha pelos dados do IBC-Br, conforme produzidos pelo Banco Central, ao invés dos dados do IBGE, mais populares entre os pesquisadores brasileiros, é justificada pelo fato da estatística do Banco Central ser computada diretamente na frequência mensal, enquanto que o dado mensal divulgado pelo IBGE é, na verdade, oriundo de uma interpolação de estatísticas originalmente calculadas em frequência maior do que mensal.

Uma vez de posse das séries de dados que serão utilizadas, torna-se necessário decidir um ponto de divisão para o final da parte *in-sample* e começo da porção *out-of-sample*. Na Tabela 3-1 são apresentadas as estatísticas descritivas das séries utilizadas.

Neste ponto, as considerações sobre manipulação da amostra parecem ser muito importantes e pertinentes; entretanto, devido à característica e o objetivo do trabalho de endereçar a pergunta - “dado que a previsão está sendo feita com um modelo apropriado para curto-prazo, até que ponto o erro de previsão esperado pode afetar a escolha da modelagem usada?” – esta decisão deixa de ser fundamental.

Nesse caso a capacidade preditiva de um modelo sobre outro, ou a localização de um ponto de divisão da amostra, é irrelevante, pois o que se pretende demonstrar é que, justamente, o modelo mais sofisticado e com variáveis exógenas não oferece vantagem sobre o mais parcimonioso, uma vez que o erro esperado ao se estender a previsão faz com que os resultados sejam estatisticamente indistinguíveis.

Desta forma, o intervalo completo de observações totalizando 115 meses foi dividido em duas partes, sendo a porção *in-sample* considerada de Jan/2003 a Jul/2010 (91 observações) e a porção *out-of-sample*, com 24 observações, indo de Ago/2010 a Ago/2012.

Tabela 3-1 – Estatísticas Descritivas das Séries de Dados

	Média	mediana	sigma	assimetria	curtose	Jarque-Bera		
						valor	prob	obs
carga (MWh)	1.199.640	1.192.912	138.198	0,135	1.966.274	5,471	0,06485	115
temp (°C)	27,6	28,0	2,2	0,395	2,4	4,887	0,08681	115
IBC-Br	122,95	123,64	14,3	0,081	1,9	6,409	0,04058	115

Tabela 3-2 – Testes de Estacionaridade da Carga, PIB e Temperatura

Hipótese Nula: MWH é estacionária		
		Estat.-LM
Estatística de teste de Kwiatkowski-Phillips-Schmidt-Shin		1,224513
Valores críticos assintóticos*:	nível de 1%	0,739000
	nível de 5%	0,463000
	nível de 10%	0,347000
<i>* Kwiatkowski-Phillips-Schmidt-Shin (1992, Tabela 1)</i>		
Hipótese Nula: IBC-Br é estacionária		
		Estat.-LM
Estatística de teste de Kwiatkowski-Phillips-Schmidt-Shin		1,233794
Valores críticos assintóticos*:	nível de 1%	0,739000
	nível de 5%	0,463000
	nível de 10%	0,347000
<i>* Kwiatkowski-Phillips-Schmidt-Shin (1992, Tabela 1)</i>		
Hipótese Nula: TEMPERATURA é estacionária		
		Estat.-LM
Estatística de teste de Kwiatkowski-Phillips-Schmidt-Shin		0,164415
Valores críticos assintóticos*:	nível de 1%	0,739000
	nível de 5%	0,463000
	nível de 10%	0,347000
<i>*Kwiatkowski-Phillips-Schmidt-Shin (1992, Tabela 1)</i>		

Como observado anteriormente, é necessário efetuar testes de estacionaridade das séries utilizadas, com vistas à escolha da forma de modelagem possível de ser utilizada para cada uma delas.

Como na literatura observa-se que em séries curtas, de poucos anos de duração, pode ser extremamente difícil a rejeição da existência de uma raiz unitária, foram empregados dois testes, com abordagens opostas, para verificar a estacionaridade ou não de cada série: o teste ADF, cuja

Tabela 3-3 – Teste de Raiz Unitária da Carga, PIB e Temperatura

Hipótese Nula: MWH tem uma raiz unitária		
	Estatística-t	Prob.*
Estatística de teste Dickey-Fuller Aumentado	-0.366439	0.9097
Valores críticos testes:		
	nível 1%	-3.495677
	nível 5%	-2.890037
	nível 10%	-2.582041
<i>*MacKinnon (1996) valores-p para um lado</i>		
Hipótese Nula: IBC-Br tem uma raiz unitária		
	Estatística-t	Prob.*
Estatística de teste Dickey-Fuller Aumentado	-1,163340	0.6879
Valores críticos testes:		
	nível 1%	-3.495677
	nível 5%	-2.890037
	nível 10%	-2.582041
<i>*MacKinnon (1996) valores-p para um lado</i>		
Hipótese Nula: TEMPERATURA tem uma raiz unitária		
	Estatística-t	Prob.*
Estatística de teste Dickey-Fuller Aumentado	-6,942026	0.0000
Valores críticos testes:		
	nível 1%	-3.495677
	nível 5%	-2.890037
	nível 10%	-2.582041
<i>*MacKinnon (1996) valores-p para um lado</i>		

hipótese nula é a existência de uma raiz unitária (Dickey e Fuller, 1981; Taylor, 2003; Ozorio *et al.*, 2012), e o teste KPSS com hipótese nula de estacionaridade da série (Kwiatkowski *et al.*, 1992). Os resultados são apresentados na Tabela 3-2 e Tabela 3-3.

Como pode ser observado pelos resultados dos testes de estacionaridade, ambas as séries de carga e evolução do PIB, tem suas estatísticas de testes rejeitando a hipótese de estacionaridade e acolhendo a de existência de uma raiz unitária, ao passo que a da temperatura tem a propriedade de estacionaridade bem definida.

Tendo estabelecido a condição básica para efetuar as regressões das séries, o próximo passo é tratar de escolher o modelo de regressão ARMA mais apropriado para cada série, sempre utilizando esta forma popular de modelagem, e introduzindo as variáveis exógenas temperatura e IBC-Br para o caso da modelagem da carga.

Tabela 3-4 – Resultado da Regressão da Temperatura

Variável Dependente: TEMPERATURA Método: MQO Amostra (ajustada): 2003M03 2010M07 Observações incluídas: 89 após ajustes				
Variável	Coeficiente	Erro Padrão	Estatística-t	Prob.
@MONTH=1	28,73246	0,168074	170,9508	0,0000
@MONTH=2	29,89045	0,168027	177,8912	0,0000
@MONTH=3	29,85521	0,140640	212,2810	0,0000
@MONTH=4	28,19741	0,141539	199,2204	0,0000
@MONTH=5	25,22260	0,139399	180,9385	0,0000
@MONTH=6	24,70496	0,142219	173,7106	0,0000
@MONTH=7	24,75984	0,138787	178,4011	0,0000
@MONTH=8	27,24025	0,166523	163,5824	0,0000
@MONTH=9	27,92999	0,168479	165,7770	0,0000
@MONTH=10	29,05239	0,168096	172,8320	0,0000
@MONTH=11	28,90241	0,167894	172,1469	0,0000
@MONTH=12	29,31462	0,167812	174,6875	0,0000
AR(2)	0,240630	0,112605	2,136937	0,0359
MA(12)	-0,898901	0,039129	-22,97300	0,0000
R-quadrado	0,854743	Variável dependente média		27,73708
R-quadrado ajustado	0,829565	D.P. variável dependente		2,159460
E.P. da regressão	0,891506	Critério de Akaike		2,751650
Soma quadrados resid.	59,60878	Critério de Schwarz		3,143121
Log verossimilhança	-108,4484	Critério de Hannan-Quinn		2,909441
Estat. Durbin-Watson	1,977267			

3.3.2 Regressão das Variáveis

A regressão da temperatura, a série que apresenta características de estacionaridade, foi efetuada através de um modelo ARMA como apresentado na Tabela 3-4. No caso deste tipo de modelagem, a consideração do ótimo foi feita através da observação de quatro critérios: (i) a melhor eliminação de correlação dos resíduos, (ii) a minimização do critério de informação, (iii) a parcimoniosidade dos do modelo obtido, e (iv) todos os coeficientes obtidos deveriam ser significantes a, no mínimo, 5%.

Na realidade, estes critérios orientaram a modelagem de todas as variáveis (Brooks, 2008), incluindo temperatura, carga e IBC-Br, embora no caso das duas últimas houvesse a preocupação adicional de escolha de que forma seria abordada a não estacionaridade dos valores, se através da diferenciação dos valores observados ou se através da introdução de uma tendência determinística.

É importante notar que o resultado da regressão confirma a esperada existência de uma grande sazonalidade mensal da variável, conforme pode ser visto pela relevância dos coeficientes das variáveis *dummy* incluídas para todos os meses do ano.

Em seguida, passamos à regressão do IBC-Br que, como foi indicado acima, serviu como proxy do PIB. Esta variável apresentou-se não estacionária, conforme os testes feitos (e apresentados acima), pelo que tornou-se necessário que fosse tomada uma decisão da forma que seria feita a modelagem, se com o auxílio de diferenciação ou através da adição de um tendência, a fim de que fosse evitada uma regressão espúria, conforme indicado anteriormente.

A regressão que melhor se encaixou nos critérios mencionados e, ainda assim, apresentou uma boa capacidade preditiva conforme o R^2 -ajustado, tem seus resultados conforme a Tabela 3-5 e é uma regressão na qual uma tendência foi incluída.

Tabela 3-5 – Resultado da Regressão do IBC-Br

Variável Dependente: IBC-Br Método: MQO Amostra (ajustada): 2004M01 2010M07 Observações incluídas: 79 após ajustes				
Variável	Coefficiente	Erro Padrão	Estatística-t	Prob.
@TREND	0,725348	0,219239	3,308480	0,0015
AR(12)	0,961076	0,033402	28,77269	0,0000
MA(1)	0,784614	0,054171	14,48406	0,0000
MA(2)	0,897385	0,046176	19,43417	0,0000
MA(3)	0,355017	0,039953	8,885871	0,0000
MA(10)	-0,241889	0,041096	-5,885937	0,0000
MA(12)	-0,490795	0,031500	-15,58082	0,0000
R-quadrado	0,956897	Variável dependente média		120,8603
R-quadrado ajustado	0,953305	D.P. variável dependente		11,19625
E.P. da regressão	2,419406	Critério de Akaike		4,689355
Soma quadrados resid.	421,4539	Critério de Schwarz		4,899306
Log verossimilhança	-178,2295	Critério de Hannan-Quinn		4,773468
Estat. Durbin-Watson	1,783830			

No caso da regressão da carga, o primeiro modelo a ser ajustado foi o que combinava uma regressão ARMA com duas variáveis exógenas, quais fossem a temperatura e o IBC-Br, da mesma forma usada na prática por distribuidora nacional.

Como a série de carga apresentou características não estacionárias, foi necessário que se efetuasse um teste que permitisse mostrar que a adição da variável IBC-Br seria suficiente para retirar a característica não estacionária da série original, tornando-a estacionária e permitindo que a regressão por MQO fosse feita sem que houvesse problemas com os resultados.

Assim, os resíduos de uma regressão da carga contra a variável IBC-Br fazendo papel de variável independente foram submetidos a testes de estacionaridade ADF e KPSS (como mencionado anteriormente), sendo as estatísticas obtidas unânimes em apontar para uma hipótese de série estacionária.

Desta forma, foi feita a regressão final cujos resultados são mostrados na Tabela 3-6.

Seguindo o mesmo procedimento, foram feitas regressões da carga combinando uma regressão ARMA com apenas uma variável exógena, por vez, a temperatura e o IBC-Br e, finalmente, foram feitas regressões

Tabela 3-6 – Regressão da Carga vs temperatura e IBC-Br

Variável Dependente: MWH				
Método: MQO				
Amostra (ajustada): 2004M01 2010M07				
Observações incluídas: 79 após ajustes				
Variável	Coefficiente	Erro Padrão	Estatística-t	Prob.
IBC_BR	7651,246	301,1072	25,41038	0,0000
TEMPERATURA	12456,82	1369,813	9,093807	0,0000
AR(12)	0,942651	0,027840	33,85934	0,0000
MA(12)	-0,861557	0,029666	-29,04162	0,0000
R-quadrado	0,974351	Variável dependente média		1171934,
R-quadrado ajustado	0,973325	D.P. variável dependente		94565,30
E.P. da regressão	15444,81	Critério de Akaike		22,17724
Soma quadrados resid.	1,79E+10	Critério de Schwarz		22,29721
Log verossimilhança	-872,0009	Critério de Hannan-Quinn		22,22530
Estat. Durbin-Watson	1,683725			

da carga sem quaisquer variáveis exógenas, apenas buscando-se verificar qual seria o melhor ajuste para contornar a falta de estacionaridade da série, seja por diferenciação ou pela adição de uma tendência.

Todos os resultados obtidos estão apresentados na Tabela 3-7, Tabela 3-8, Tabela 3-9 e Tabela 3-10.

3.3.3 Avaliação do Desempenho Preditivo

Finalmente foi possível fazer a aferição da capacidade preditiva dos vários modelos, considerando que no caso da utilização de variáveis exógenas para previsão, e levando-se em conta que elas mesmas não estão disponíveis, seria necessário fazer a sua previsão.

Novamente foi adotado o mesmo procedimento utilizado na prática, que se baseava na previsão das variáveis exógenas através dos modelos ARMA ajustados anteriormente.

Em seguida, a previsão, por cada modelo, foi feita utilizando-se a metodologia *in-sample/out-of-sample*¹ para aferição dos resultados obtidos. O gráfico mostrado na Figura 3-1 permite a observação dos resultados obtidos, da mesma forma que os erros de previsão em relação

¹ Para uma descrição desta técnica recomenda-se consultar (Brooks, 2008)

Tabela 3-7 – Regressão da Carga vs temperatura

Variável Dependente: MWH				
Método: MQO				
Amostra (ajustada): 2004M01 2010M07				
Observações incluídas: 78 após ajustes				
Variável	Coeficiente	Erro Padrão	Estatística-t	Prob.
@TREND	7408,214	1853,223	3,997475	0,0001
TEMPERATURA	8758,905	1357,701	6,451277	0,0000
AR(1)	0,749032	0,077923	9,612487	0,0000
SAR(12)	0,934013	0,044483	20,99720	0,0000
R-quadrado	0,939718	Variável dependente média		1173610,
R-quadrado ajustado	0,937275	D.P. variável dependente		93988,89
E.P. da regressão	23539,57	Critério de Akaike		23,02067
Soma quadrados resid.	4,10E+10	Critério de Schwarz		23,14153
Log verossimilhança	-893,8063	Critério de Hannan-Quinn		23,06906
Estat. Durbin-Watson	2,137606			

Tabela 3-8 – Regressão da Carga vs IBC-Br

Variável Dependente: MWH				
Método: MQO				
Amostra (ajustada): 2004M01 2010M07				
Observações incluídas: 79 após ajustes				
Variável	Coeficiente	Erro Padrão	Estatística-t	Prob.
IBC-BR	6027,329	779,3112	7,734176	0,0000
AR(12)	1,033631	0,003713	278,3788	0,0000
MA(1)	0,320091	0,110008	2,909692	0,0048
SMA(12)	-0,848775	0,039224	-21,63937	0,0000
R-quadrado	0,964276	Variável dependente média		1171934,
R-quadrado ajustado	0,962847	D.P. variável dependente		94565,30
E.P. da regressão	18227,49	Critério de Akaike		22,50856
Soma quadrados resid.	2,49E+10	Critério de Schwarz		22,62853
Log verossimilhança	-885,0879	Critério de Hannan-Quinn		22,55662
Estat. Durbin-Watson	1,964251			

Tabela 3-9 – Regressão da Carga com diferenciação

Variável Dependente: D(MWH)				
Método: MQO				
Amostra (ajustada): 2004M03 2010M07				
Observações incluídas: 77 após ajustes				
Variável	Coeficiente	Erro Padrão	Estatística-t	Prob.
AR(1)	-0,245617	0,112246	-2,188203	0,0318
SAR(12)	1,020926	0,029205	34,95768	0,0000
MA(12)	-0,873509	0,037247	-23,45204	0,0000
R-quadrado	0,853822	Variável dependente média		4859,442
R-quadrado ajustado	0,849871	D.P. variável dependente		58660,09
E.P. da regressão	22728,70	Critério de Akaike		22,93883
Soma quadrados resid.	3,82E+10	Critério de Schwarz		22,03014
Log verossimilhança	-880,1448	Critério de Hannan-Quinn		22,97535
Estat. Durbin-Watson	2,044250			

aos resultados observados, medidos na forma de **RMSE**, **MAE** e **MAPE** (raiz do erro médio quadrado, erro médio absoluto e erro médio absoluto percentual) podem ser vistos na Tabela 3-11.

Tabela 3-10 – Regressão da Carga com tendência

Variável Dependente: MWH				
Método: MQO				
Amostra (ajustada): 2004M02 2010M07				
Observações incluídas: 77 após ajustes				
Variável	Coefficiente	Erro Padrão	Estatística-t	Prob.
@TREND	9373,114	2036,553	4,602440	0,0000
AR(1)	0,705102	0,083607	8,433489	0,0000
SAR(12)	0,915474	0,041411	22,10702	0,0000
R-quadrado	0,906384	Variável dependente média		1173610,
R-quadrado ajustado	0,903888	D.P. variável dependente		93988,89
E.P. da regressão	29138,39	Critério de Akaike		23,43520
Soma quadrados resid.	6,37E+10	Critério de Schwarz		23,52585
Log verossimilhança	-910,9729	Critério de Hannan-Quinn		23,47149
Estat. Durbin-Watson	2,056554			

É importante notar que o objetivo a ser alcançado é o de estabelecer uma forma de comparar a eficácia de cada um dos modelos apresentados, em termos de previsão de longo prazo, uma vez que estes seriam todos apropriados para previsões de curto prazo, de acordo com a literatura. Em particular, uma previsão deveria ser estendida até no máximo $(p+q)$ períodos, de acordo com a regra de bolso mencionada anteriormente.

Tabela 3-11 – Erros de Regressão para Previsões de Carga

Tipo de regressão	RMSE	MAE	MAPE
ARMA por diferenciação	33.041,76	27.486,87	1,980295
ARMA com tendência	41.168,08	33.737,93	2,431476
ARMA + tendência + Temp	19.503,68	15.942,57	1,151037
ARMA + IBC-Br	43.313,80	35.648,23	2,530426
ARMA + Temp + IBC-Br	64.050,08	56.598,52	4,020712

3.3.4

Observação da Propagação do Erro

Como as previsões (estratégicas) desejadas pelas distribuidoras de energia no Brasil devem ter um mínimo de 5 anos à frente, de forma a poder capturar a participação em leilões de energia de longo prazo, era




Figura 3-1 – Previsão da Carga por Múltiplos Modelos

necessário que esta fosse estendida até, pelo menos, o final do ano de 2017.

Para isto foram escolhidos três modelos, dentre os avaliados anteriormente, com o objetivo de observar a propagação dos erros de suas previsões que deveriam ser afetados pelos erros de previsão dos seus elementos, uma vez que em alguns deles havia variáveis exógenas as quais, forçosamente, seriam estimadas.

A seguir, cada um desses modelos foi re-estimado para o intervalo de dados conhecidos, isto é, de Jan/2003 a Jul/2012, de forma a conseguir extrair a melhor informação dos dados disponíveis e, em sequência, foram feitas previsões estendidas até Dez/2012.

A única alteração significativa na estrutura dos modelos de regressão, observada para esta nova janela de estimação, foi a substituição do fator MA(12) por AR(1), ditado pela observação do novo correlograma para os resíduos da regressão.

Para cada uma das modelagens de previsão efetuadas foram feitas 10.000 simulações, sempre levando em consideração a incerteza de cada

coeficiente, de forma que se pudesse obter uma distribuição de dados capaz de permitir a observação dos erros de previsão e o cálculo do seu desvio padrão.

O resultado da comparação dessas previsões e seus erros, pode ser visto no gráfico apresentado na Figura 3-2, e a tabulação dos resultados, para datas específicas, está apresentada na Tabela 3-12.

3.4 Discussão dos Resultados

Através da observação da Figura 1 e Tabela 10 é possível inferir que o modelo que mais aproxima as observações reais, ao menos para o caso




Figura 3-2 – Extensão da Previsão da Carga

da presente escolha de divisão da amostra entre *in-sample* e *out-of-sample*, é o modelo em que a carga é regredida contra si própria, através de um modelo ARMA utilizando uma tendência para conseguir estacionaridade, e uma variável exógena, no caso a temperatura.

Surpreendentemente, a adição de uma variável que traduz a situação econômica a que a região está submetida, o PIB, embora a literatura cite que este artifício pode melhorar o valor preditivo de uma regressão, isto não ofereceu melhorias no caso em tela.

Isto pode ser explicado pela possível desaceleração da economia a partir do final de 2008, quando visualmente (embora não estatisticamente) a evolução do PIB passa a ser mais lenta.

Esta tendência pode ter feito com que a adição do IBC-Br tenha introduzido um efeito de frenagem no aumento do consumo de energia observado, maior do que realmente aconteceu.

Por outro lado, esta constatação serve para lembrar que as variáveis exógenas devem ser altamente correlacionadas com o fenômeno que se pretende observar, quando da sua adição a modelos de previsão. No caso específico, é possível que a ausência do cálculo de um PIB regional tenha permitido a introdução de uma distorção, possivelmente decorrente de eventuais diferenças regionais.

De qualquer forma, o exercício efetuado permite observar que, para as condições consideradas, ambos os modelos em que a variável associada ao PIB, o IBC-Br, foi introduzida apresentaram desempenho inferior aos demais, mesmo aquele unicamente auto-regressivo e de média móvel.

Tabela 3-12 - Previsão Estendida da Carga (MWh)

		jul/12	dez/12	dez/13	dez/14	dez/15	dez/16	dez/17
ARMA + diferenciação	média + 2 EP		1.536.133	1.672.712	1.799.765	1.931.226	2.062.458	2.198.353
	média	1.433.131	1.448.166	1.507.153	1.567.267	1.628.750	1.692.444	1.757.090
	média - 2 EP		1.360.199	1.341.594	1.334.769	1.326.274	1.322.429	1.315.827
ARMA + tendência + temperatura	média + 2 EP		1.566.960	1.669.313	1.768.851	1.870.564	1.973.239	2.075.700
	média	1.433.131	1.490.785	1.561.280	1.631.623	1.704.681	1.779.695	1.855.019
	média - 2 EP		1.414.611	1.453.247	1.494.394	1.538.797	1.586.151	1.634.337
ARMA + IBC-Br + temperatura	média + 2 EP		1.548.483	1.606.661	1.661.164	1.716.131	1.773.151	1.833.018
	média	1.433.131	1.469.243	1.502.556	1.537.113	1.574.503	1.613.575	1.654.560
	média - 2 EP		1.390.003	1.398.451	1.413.063	1.432.874	1.453.999	1.476.103

O problema com tal modelagem é que pressupõe a disponibilidade de dados futuros de temperatura que sejam precisos, o que pode ser difícil considerando que isto requer uma antecipação do futuro. Adicionalmente, a modelagem da temperatura também requer um tratamento específico e uma arte própria.

Por outro lado, é muito importante ressaltar que a melhor previsão apresentada pelo modelo que incorpora apenas a temperatura, não só está em total conformidade com a enorme importância atribuída à temperatura como um fator na previsão da demanda de eletricidade, como também este é o modelo de previsão que apresenta o menor erro padrão de simulação, conforme observaremos adiante.

Um menor erro padrão numa distribuição probabilística de resultados resulta em um menor “espalhamento” das previsões, o que implica em uma melhor previsão do ponto de vista de manipulação dos dados obtidos.

A seguir, é interessante observar a evolução do erro padrão (EP) para as séries de carga simuladas, na previsão estendida até dez/2017.

Embora a análise da literatura não permita que se espere um grande desempenho preditivo de modelagens do tipo ARMA com vistas ao longo prazo, na média, as estimativas feitas para dez/2017 pelos três modelos escolhidos - todos ARMA, mas com diferentes formas de provocar estacionaridade – situam-se em uma faixa de valores relativamente bem comportada, com diferenças máximas da ordem de 5,7% (da ordem de 100.000 MWh).

Entretanto, a preocupação advém do erro padrão para as 10.000 simulações feitas para cada um dos modelos, que, para a previsão da carga em dez/2017, variou de um mínimo de 89.229 MWh a um máximo de 220.632 MWh.

Essa dispersão, se comparada aos valores médios obtidos, efetivamente permite que, utilizando um intervalo de confiança de 2 erros padrão - no caso de distribuição normal associado a um intervalo de confiança de 95% - todas as projeções médias estejam dentro dos intervalos umas das outras.

Isto equivale a dizer que, dado um intervalo de confiança de 95%, não há razão para preferir uma projeção sofisticada, com variáveis exógenas, a outra apenas a partir de valores passados da evolução da própria carga, ou seja, puramente ARMA.

Por outro lado, no caso da disponibilidade de dados previstos da evolução climática, em particular da temperatura, o modelo utilizando a variável exógena temperatura é de particular utilidade, não induzindo o aumento do erro de previsão, uma vez que a própria série de valores de temperatura é estacionária, e a modelagem da carga utiliza uma tendência para induzir estacionaridade, o que favorece a obtenção de um erro de previsão mais bem comportado.

3.5 Conclusão

Tendo em vista os resultados obtidos no presente trabalho, pode-se afirmar que as previsões de carga, de longo prazo feitas com modelos do tipo ARMA não necessitam de maiores aperfeiçoamentos, como a adição de variáveis exógenas.

Além disso, é importante notar que as próprias variáveis exógenas estão sujeitas a erros de previsão, uma vez que seus valores também não são disponíveis para pontos no tempo à frente do momento atual.

Por outro lado, modelos mais simples permitem que exercícios do tipo *what-if* sejam feitos com mais tranquilidade e frequência, ajudando na avaliação de alternativas futuras, para um mesmo nível de incerteza.