

3 Previsão de Carga com Horizonte de Um Mês em Períodos de Racionamento

O racionamento de energia elétrica ocorrido entre maio de 2001 e fevereiro de 2002 afetou substancialmente as trajetórias das séries de carga elétrica em várias regiões brasileiras. Segundo Mendes (2002), eventos como esse alteram permanentemente a série temporal e são conhecidos como mudanças estruturais no processo gerador de dados.

Neste capítulo, mostra-se o desempenho dos modelos descritos anteriormente. São analisadas previsões de carga elétrica com horizonte de um mês, em seis séries diferentes, no período de janeiro de 2000 a dezembro de 2002. Visto que houve ineficiência das previsões de energia decorrentes do racionamento, são analisadas algumas alternativas no sentido de reduzir seu impacto nos erros de previsão.

Inicialmente, apresenta-se um dos sistemas oficiais de previsão de carga utilizado pelo Operador Nacional do Sistema Elétrico (ONS) formando a base de informação desta dissertação. São utilizados os modelos do capítulo 2, cujo produto final é a combinação linear dos dois melhores modelos, determinados segundo o histórico dos erros um passo à frente.

3.1. Sistema de Previsão de Carga

Um dos sistemas de previsão de carga elétrica utilizado pelo ONS chama-se PREVCAR (CEPEL, 2000). Esse realiza estimativa mensal com horizonte de doze meses de carga elétrica, demanda na ponta e demanda fora da ponta. Nesse sistema, são utilizados quatro modelos univariados diferentes: Box & Jenkins, Holt & Winters, Redes Neurais Artificiais e Lógica Fuzzy, tendo como entrada a série histórica mensal dos valores de carga observados. A previsão final é resultado da combinação linear dos dois melhores modelos, determinados segundo o histórico dos erros um passo à frente nos últimos 24 meses.

O sistema contempla peculiaridades do mercado brasileiro como os feriados regionais e nacionais e permite a desagregação da previsão final de energia em três patamares de carga (pesada, média e leve). Como a previsão é mensal, o sistema realiza a desagregação em dados semanais e diários para o primeiro mês de horizonte. O fluxograma da Figura 3.1 representa os procedimentos do sistema de previsão PREVCAR.

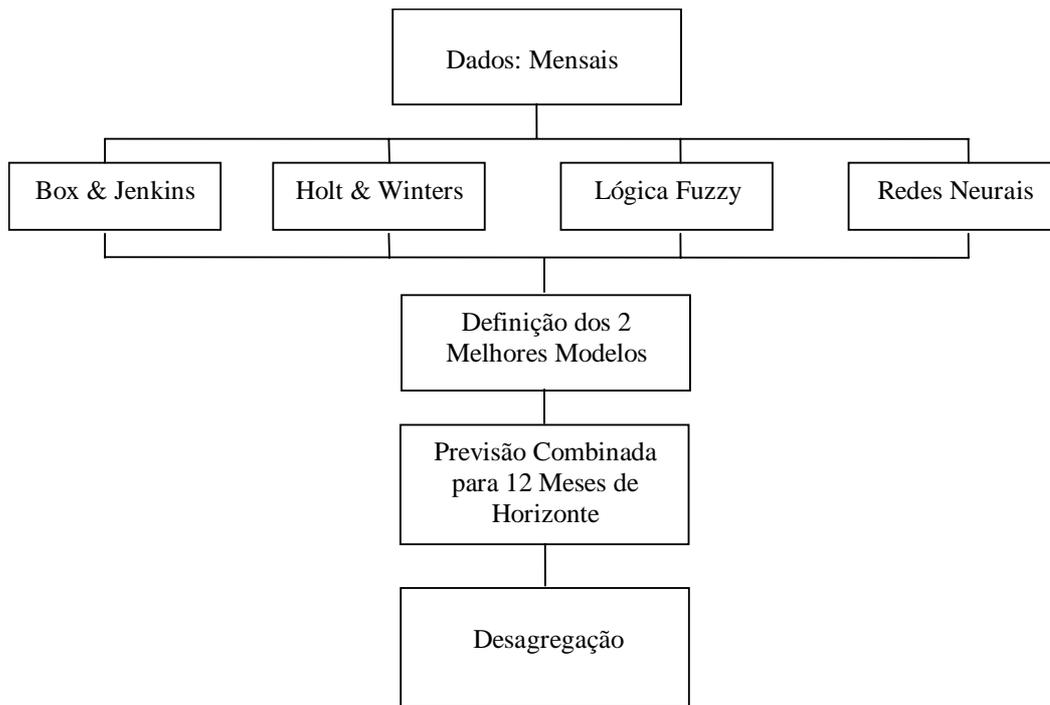


Figura 3.1 - Fluxograma do Sistema de Previsão PREVCAR

Nesse Sistema de Previsão, são considerados componentes sazonais, indicando modelos SARIMA, pois as séries de energia elétrica não são estacionárias e, muitas vezes, apresentam ocorrência de padrões cíclicos que se repetem no decorrer do tempo.

Nos modelos de alisamento exponencial, são considerados dois parâmetros: um de tendência e o outro de sazonalidade. Utiliza-se formulação multiplicativa para a previsão com horizonte de um mês, isto é:

$$3.1 \quad y_{t+1} = [a_1(t) + a_2(t)]\rho_t + \varepsilon_t$$

Nos modelos de RNA, são utilizadas redes do tipo *feedforward* com múltiplas camadas: uma camada de entrada, uma camada de neurônios ocultos e uma camada de saída. As redes neurais propostas possuem caminhos diretos, ou seja, os sinais de entrada produzem uma resposta na saída da rede, sem realimentação na rede. O algoritmo empregado no treinamento supervisionado das redes foi o *backpropagation*, cujos pesos são re-calculados, mensalmente, a cada nova observação.

Ainda em relação ao modelo RNA, um estudo realizado pelo CEPEL (2000) mostrou a correlação nas séries de energia, em que foi observado que os valores de maior auto-correlação seriam escolhidos para formar a camada de entrada. Com o objetivo de encontrar o menor erro, foram feitos vários testes e escolheu-se uma arquitetura de rede com um número específico de neurônios na camada intermediária (escondida) para cada concessionária. Todas as redes utilizaram a função de ativação sigmoideal na camada escondida e a função de ativação linear no neurônio da camada de saída.

O sistema de Lógica Fuzzy foi projetado a partir de conjuntos fuzzy definidos a partir da metodologia mostrada em Mendel (1992a), onde os conjuntos fuzzy são pré-definidos e as regras são geradas de maneira automática, utilizando a técnica de janelamento baseada no histórico da série temporal. O vetor de entrada contém três valores: valor da série verificado na origem, o valor da série 12 e 24 meses antes do mês a ser previsto.

Cada variável teve seu domínio dividido em 5 regiões de mesma largura, cada uma associada a uma função de pertinência. O domínio da variável foi determinado a partir dos valores máximo e mínimo dos dados disponíveis para treinamento, com uma margem adicional de 10% em relação aos valores extremos encontrados no trecho utilizado para geração das regras.

A partir deste momento, foi utilizado o software PREVCAR, desenvolvido pelo CEPEL, para modelagem das séries de carga elétrica nesta dissertação.

3.2. Desempenho dos Modelos de Previsão

Para analisar o desempenho dos modelos nas previsões um passo à frente de carga elétrica, são utilizadas séries temporais que contemplam todas as informações do racionamento de energia como pode ser observado na série da Figura 3.2.

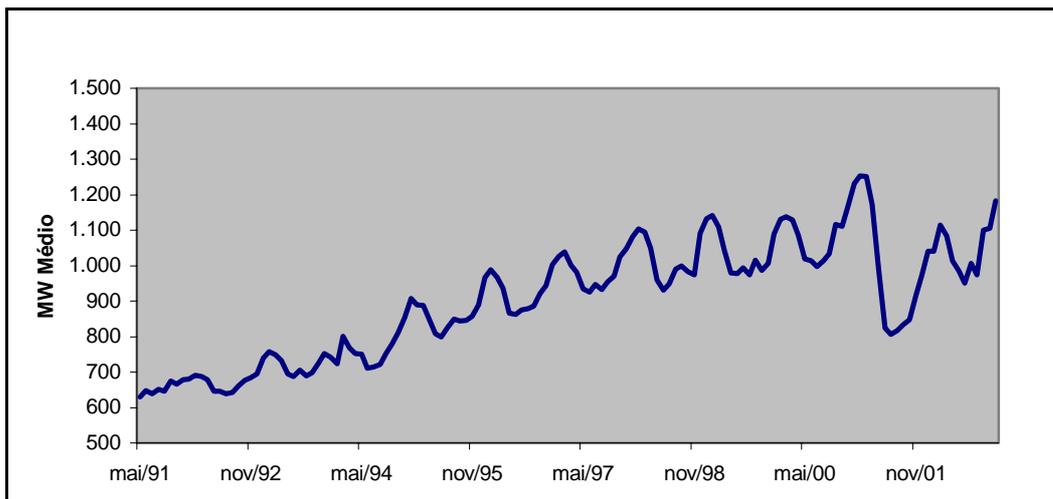


Figura 3.2 - Série de carga elétrica em período de racionamento

Os critérios de avaliação de um modelo podem ser simples ou avançados. Por exemplo, o leitor pode facilmente traçar o gráfico das previsões e os valores observados do processo, sendo, nesse caso, a previsão considerada satisfatória, se ambas as evoluções forem similares e os erros de previsão pequenos.

Uma medida de avaliação muito usada é o MAPE (Mean Absolute Percent Error), erro médio percentual absoluto. Esta estatística indica o erro percentual absoluto médio das previsões sobre todo o conjunto de teste:

$$3.2 \quad MAPE = 100 \times \frac{\sum_{t=1}^n \left(\left| \frac{\hat{y}_t - y_t}{y_t} \right| \right)}{n}$$

Onde \hat{y}_t é a previsão para o período t , y_t é o valor observado do processo e n é o número de observações para cálculo do MAPE.

Uma outra medida de desempenho é o APE (Absolute Percent Error) erro absoluto percentual. Este método leva em consideração os erros de uma única previsão, ou seja,

$$3.3 \quad APE = 100 \times \left| \frac{\hat{y}_t - y_t}{y_t} \right|$$

Essas duas métricas foram usadas na avaliação de desempenho dos modelos de previsão com horizonte de um mês.

Para uma série de carga elétrica, proveniente de uma companhia localizada na região sudeste do país, calculou-se previsões um período à frente pelos quatro modelos estudados nesta dissertação: Box & Jenkins, Holt & Winters, Lógica Fuzzy e Redes Neurais. O período analisado estende-se por 36 meses, englobando previsões anteriores à intervenção (janeiro de 2000 a maio de 2001) e posteriores ao racionamento (junho de 2001 a dezembro de 2002).

Pela Tabela 3.1, Tabela 3.2 e Tabela 3.3, pode-se perceber a precisão de cada modelo:

DATA	H.W.	B.J.	R.N.	L.F.
jan/00	1,38%	0,00%	0,92%	0,27%
fev/00	0,60%	0,70%	0,52%	0,53%
mar/00	2,20%	0,92%	0,29%	0,27%
abr/00	2,06%	0,18%	1,87%	0,83%
mai/00	1,16%	0,96%	2,62%	2,85%
jun/00	1,19%	0,39%	1,00%	3,25%
jul/00	3,02%	3,23%	1,46%	2,11%
ago/00	0,93%	0,35%	1,58%	1,18%
set/00	1,07%	0,35%	0,39%	4,74%
out/00	6,87%	7,27%	5,34%	8,33%
nov/00	1,52%	0,29%	3,13%	4,50%
dez/00	0,15%	0,34%	2,60%	0,09%
MAPE	1,85%	1,25%	1,81%	2,41%

Tabela 3.1 - Erros percentuais absoluto (APE) no ano de 2000

DATA	H.W.	B.J.	R.N.	L.F.
jan/01	2,44%	2,73%	1,41%	2,68%
fev/01	2,50%	1,84%	1,59%	1,76%
mar/01	3,63%	2,53%	2,08%	0,80%
abr/01	0,29%	1,89%	4,21%	5,03%
mai/01	10,90%	11,74%	13,49%	14,55%
jun/01	28,01%	22,23%	17,00%	17,11%
jul/01	17,56%	2,83%	27,51%	28,25%
ago/01	4,74%	0,50%	20,78%	11,61%
set/01	1,48%	0,61%	21,82%	10,67%
out/01	0,39%	1,19%	26,33%	18,42%
nov/01	7,38%	6,36%	15,94%	3,06%
dez/01	1,92%	0,52%	13,89%	2,98%
MAPE	6,77%	4,58%	13,84%	9,74%

Tabela 3.2 - Erros percentuais absoluto (APE) no ano de 2001

DATA	H.W.	B.J.	R.N.	L.F.
jan/02	4,14%	2,16%	13,46%	2,40%
fev/02	1,46%	1,50%	15,96%	4,52%
mar/02	9,22%	7,86%	9,24%	2,60%
abr/02	5,79%	1,77%	6,64%	7,20%
mai/02	2,51%	0,92%	2,96%	17,67%
jun/02	0,15%	1,67%	8,32%	15,43%
jul/02	4,11%	3,99%	7,47%	5,47%
ago/02	0,76%	4,82%	11,43%	9,54%
set/02	5,31%	5,23%	7,61%	2,26%
out/02	9,53%	9,88%	15,45%	12,36%
nov/02	0,99%	1,74%	12,12%	1,45%
dez/02	2,39%	2,20%	11,51%	3,05%
MAPE	3,86%	3,65%	10,18%	7,00%

Tabela 3.3 - Erros percentuais absoluto (APE) no ano de 2002

Esses resultados refletem o desempenho dos modelos para previsões de energia em períodos com intervenção e mostram que todos foram deficientes no período de racionamento.

Nos dois primeiros meses de intervenção, os erros percentuais absolutos (APE) das estimativas da energia consumida alcançam patamares na ordem de 25% (conforme redução de consumo de energia de 20% exigida pelo Governo Federal). Em relação aos erros de previsão cometidos nos meses do ano 2000, os erros no terceiro mês de racionamento (agosto de 2001) ainda atingem valores altos. Porém, a partir dessa data, os modelos Holt & Winters e Box & Jenkins absorvem as informações do evento e passam gerar previsões com APE inferiores a 5%, com exceção de novembro de 2001, março e outubro de 2002.

Já os modelos de Lógica Fuzzy e RNA mostram ter pouca adaptabilidade nas mudanças estruturais, apresentando erros de previsão, na maioria das vezes, maiores que em meses anteriores.

Os modelos foram testados para outras cinco séries de carga elétrica com as mesmas características. Em todas as cinco séries, os erros de previsão tiveram comportamento semelhante. Esses resultados podem ser encontrados no apêndice 7.1.

Devido aos resultados apresentados no período de intervenção, serão discutidas algumas propostas para tentar melhorar as previsões dos modelos considerados.

3.3. Melhoria da Previsão no Primeiro Mês de Racionamento

Para a previsão de energia elétrica no primeiro mês após o início da intervenção, supõe-se heurísticamente reduzir a previsão combinada na mesma proporção das metas de redução de carga elétrica impostas pelo Governo Federal (Cardoso, 2001).

Assim, a previsão proposta para o primeiro mês de racionamento (junho de 2001) deve ser calculada pela expressão:

$$3.4 \quad \hat{y}'_{t+1|t} = \hat{y}_{t+1|t} \times (1 - X \%)$$

Onde t refere-se a maio de 2001, $\hat{y}_{t+1|t}$ é a previsão calculada por procedimentos convencionais e X o índice de redução imposto.

Para atestar o efeito desse procedimento, foram calculados os erros de previsão de junho de 2001, em seis séries nomeadas de Série 1 a Série 6. Após a aplicação da redução da previsão em 20%, feita pelo modelo de Box & Jenkins, os erros absoluto percentuais foram:

Série	Box-Jenkins Original	Box-Jenkins com Redução
1	25,04%	0,03%
2	25,78%	0,55%
3	26,18%	0,94%
4	22,23%	2,21%
5	25,25%	0,20%
6	28,21%	2,57%

Tabela 3.4 - Comparação dos erros de Previsão

A previsão para o primeiro mês de racionamento é difícil de computar, uma vez que se trata de um evento extraordinário na trajetória da série. Porém, pela Tabela 3.4, pode-se perceber que os resultados obtidos com a aplicação do procedimento proposto foram bons no que tange à medida de previsão APE. Analisando essa tabela, os erros das previsões feitas com os modelos originais estão ao redor 25% enquanto que após a aplicação do procedimento proposto, os erros passam ser inferiores a 3%.

Com os resultados alcançados, pode-se concluir que esse procedimento poderá ser utilizado para previsão um passo à frente em futuros racionamentos.

Nas próximas seções, serão analisadas outras propostas para tentar melhorar as previsões um passo à frente para os modelos do capítulo 2, a partir do segundo mês de racionamento.

3.4. Melhoria das Previsões de Carga pelo Modelo de Holt & Winters

O primeiro modelo a ser estudado é o método de alisamento exponencial de Holt & Winters. Observa-se, na Tabela 3.2, que os erros de previsão são altos nos primeiros dois meses após o início do racionamento. Contudo, a partir de agosto de 2001, o método absorve o impacto do evento e passa gerar previsões com níveis de erros iguais aos anteriores ao racionamento. São apresentadas duas propostas para melhorar o poder de predição desse modelo para o segundo mês de racionamento.

3.4.1. Alteração do Hiperparâmetro do Nível

O modelo de Holt & Winters supõe que o processo gerador da série temporal é formado pelos seguintes componentes estruturais: Nível, Tendência e Efeitos Sazonais. O nível de uma série temporal é um valor suave, lentamente alterado com o tempo e um processo não-sazonal. Deve-se ter uma preocupação na medida do nível, uma vez que esse pode ser dissimulado pela sazonalidade ou por eventos promocionais e irregularidades caracterizadas por ruídos.

A vantagem na metodologia de amortecimento exponencial é não atribuir o mesmo peso às informações, dependendo, portanto, de suas respectivas idades. As constantes de amortecimento, também conhecidas como hiperparâmetros, controlam o número de realizações passadas da série temporal que influenciam as previsões. Valores pequenos concedem pesos significativos a observações mais antigas e resultam em resposta lenta do sistema de previsão às mudanças nos parâmetros do modelo da série temporal. Por outro lado, valores altos para as constantes de amortecimento atribuem pesos significativos somente às observações mais recentes e tornam a resposta do sistema de previsão mais rápida aos deslocamentos dos parâmetros. Entretanto, uma constante de amortecimento muito grande pode fazer com que o sistema responda às

variações aleatórias na série, quando realmente os parâmetros do modelo não mudaram.

Os hiperparâmetros podem ser estimados por diversas formas. Nesta dissertação, utilizou-se um procedimento específico para estimar as constantes de amortecimento α do nível, β da tendência e γ dos fatores sazonais, que consiste em uma otimização não-linear de gradiente reduzido genérico conhecido como Generalised Reduced Gradient Method (Lasdon, 1998), encontrado no programa computacional Microsoft Excel 2000. Esse método busca encontrar os hiperparâmetros que minimizem uma função de erro pré-definida, por exemplo o MSE (Erro Quadrático Médio).

A proposta inicial para melhorar as previsões no início do racionamento é modificar o hiperparâmetro do nível para a unidade após a estimação das três constantes de amortecimento. Esse procedimento atribui uma importância maior para as informações mais recentes no que se refere ao nível do processo gerador de dados.

Como a série temporal sofreu uma mudança estrutural devido à queda abrupta que alterou substancialmente seu nível, a previsão de energia deve considerar maior importância ao primeiro nível do período de racionamento. Ao adotar α igual a um, os níveis anteriores ao racionamento passam a não exercer influência nas estimativas do nível futuro da série, considerando apenas o período mais recente (primeiro mês de racionamento).

Assim, para os meses que sucederam ao racionamento, a primeira proposta de melhoria para os modelos de alisamento exponencial é descrita na Figura 3.3.

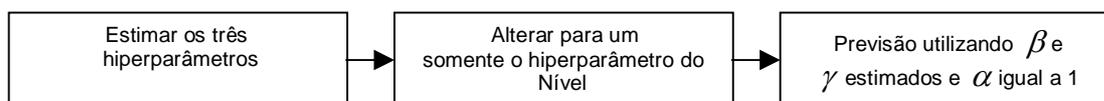


Figura 3.3 - Procedimento para alteração do hiperparâmetro do nível

Para testar a primeira proposta de melhoria das previsões feitas pelo modelo de Holt & Winters, foram utilizadas as seis séries de carga elétrica da seção anterior. Esse último será nomeado de método usual para diferenciar do primeiro método proposto. Os erros de previsão analisados nas tabelas abaixo referem-se ao segundo mês do racionamento, julho de 2001.

Série	Alfa	Beta	Gama	APE
1	0,786	0,004	0,741	10,05%
2	0,540	0,006	0,292	15,15%
3	0,875	0,001	0,858	5,99%
4	0,443	0,008	0,665	17,56%
5	0,845	0,002	0,833	5,38%
6	0,247	0,009	0,296	26,74%

Tabela 3.5 - Erros de previsão usando o método usual

Série	Alfa	Beta	Gama	APE
1	1,000	0,004	0,741	4,78%
2	1,000	0,006	0,292	3,94%
3	1,000	0,001	0,858	3,05%
4	1,000	0,008	0,665	2,68%
5	1,000	0,002	0,833	1,78%
6	1,000	0,009	0,296	3,48%

Tabela 3.6 - Erros de previsão do primeiro método proposto

As tabelas acima mostram os erros de previsão e os hiperparâmetros dos modelos estimados pelo método de Lasdon (1998) para cada série de carga elétrica. Podem-se perceber as dificuldades do método usual em encontrar o modelo mais apropriado nas previsões em períodos iniciais ao racionamento, enquanto que a proposta de alteração do hiperparâmetro do nível apresentou erros significativamente menores, em relação ao APE.

Na próxima seção discute-se outra possibilidade para melhorar o desempenho de predição nos modelos de Holt & Winters: o acréscimo de uma variável de intervenção no modelo de previsão.

3.4.2. Análise de Intervenção

Mendes (2002) avaliou e testou o acréscimo de uma variável de intervenção I_t ao modelo usual de Holt & Winters, como a seguir:

$$3.5 \quad y_t = (a_1 + a_2 t) \rho_t I_t + \varepsilon_t$$

Onde a_1 e a_2 referem-se às componente do nível e tendência respectivamente. O número de fatores sazonais ρ_t depende do período sazonal S da série. Já I_t é definida como uma variável de intervenção e ε_t é o erro aleatório, suposto i.i.d.

O modelo de intervenção, quando aplicado durante o período do racionamento, estima a queda de energia na série temporal. As variáveis de intervenção são, em geral, descritas pelas seguintes formas:

a) Variável Pulso (Pulse Variable)

$$3.6 \quad I_t = P_t^T = \begin{cases} 1 & \text{para } t = T \\ 0 & \text{para } t \neq T \end{cases}$$

b) Variável Degrau (Step Variable)

$$3.7 \quad I_t = S_t^T = \begin{cases} 1 & \text{para } t \geq T \\ 0 & \text{para } t < T \end{cases}$$

Onde T é o instante de tempo em que ocorre o evento gerador da intervenção.

Para exemplificar, o modelo com intervenção foi aplicado nas seis séries testadas na seção 3.4.1 e os parâmetros estimados pelo programa computacional FPW 3.5.

Conforme as características do racionamento de quebra estrutural, foi escolhida uma variável degrau com tempo T em junho de 2001.

$$I_t = S_t^T = \begin{cases} 1 & \text{para } t \geq \text{Junho de 2001} \\ 0 & \text{para } t < \text{Junho de 2001} \end{cases}$$

A tabela a seguir mostra os desempenhos através dos erros percentuais APE.

Série	Holt & Winters Usual	Holt & Winters com intervenção
1	10,05%	4,78%
2	15,15%	3,89%
3	5,99%	3,20%
4	17,56%	2,42%
5	5,38%	1,91%
6	26,74%	3,81%

Tabela 3.7 - Erros de previsão usando mo segundo método proposto e o usual

A Tabela 3.7 evidencia dois pontos: a introdução da variável de intervenção no modelo leva a resultados muito melhores que o método usual. E segundo, tanto essa proposta quanto a alteração do hiperparâmetro de nível apresentaram performances semelhantes nos erros de previsão nas seis séries de energia.

Devido à simplicidade de implantação computacional, será indicada a adoção da primeira proposta na previsão do segundo mês de intervenção.

É bom lembrar ainda, que este procedimento serve apenas para o segundo mês de racionamento, uma vez que no terceiro mês em diante, esse método passa a gerar previsões cujos erros são da mesma magnitude que os erros de previsão anteriores ao racionamento.

3.5. Melhoria das Previsões de Carga pelo Modelo de Box & Jenkins

Os modelos ARIMA de Box & Jenkins podem ser ajustados por variáveis de intervenção quando ocorrem mudanças estruturais nas trajetórias das séries temporais, como ocorrido no último racionamento de energia no Brasil. Em Sartoris et al. (2000), a inclusão dessas informações nos modelos acontece por intermédio de variáveis *dummy*.

As variáveis de intervenção devem ser incluídas de maneira explícita nos modelos de Box & Jenkins. Seja uma variável de intervenção I_t para um modelo expresso por:

$$3.8 \quad y_t = \frac{\omega(B)}{\delta(B)} B^b I_t + N_t$$

Onde:

$\omega(B)$ e $\delta(B)$ são polinômios de ordem s e r , respectivamente;

b é o tempo necessário para a intervenção começar a ter efeito;

N_t é um ruído descrito por um processo ARIMA (p,d,q) .

A escolha de r , s e b depende basicamente de duas características da intervenção:

- a) Início abrupto ou gradual de seu efeito;
- b) Duração permanente ou temporária de seu impacto. Efeitos permanentes sobre a série temporal são representados por variável *dummy*, que pode assumir valor 1 a partir do início da ocorrência da intervenção e valor 0 nos instantes anteriores (variável degrau). Se o impacto for temporário, a *dummy* assumirá valor 1 apenas no momento de ocorrência da intervenção (variável pulso).

Uma vez definidos os valores r , s e b , os parâmetros de $\omega(B)$ e $\delta(B)$ podem ser estimados por mínimos quadrados ou por máxima verossimilhança e a identificação do ruído N_t pode ser feita com base nos resíduos da estimação (\hat{N}_t).

Finalmente, estimam-se conjuntamente todos os parâmetros do modelo de análise de intervenção, resultando da eq. 3.8 a seguinte expressão:

$$3.9 \quad (1-B)^d y_t = \frac{\omega(B)}{\delta(B)} B^b (1-B)^d I_t + \frac{\theta(B)}{\phi(B)} \varepsilon_t$$

Onde $\theta(B)$ e $\phi(B)$ são polinômios de ordem q e p , respectivamente e o ruído ε_t é i.i.d. com média nula e variância constante.

Esta dissertação não teve como foco testar os modelos de Box & Jenkins com variáveis de intervenção, visto que já existem resultados comprovados e

testados para séries de carga de energia no período de racionamento. Em Mendes (2002), estudaram-se duas possibilidades diferentes de variáveis de intervenção:

- A primeira intervenção aplicada à série temporal de carga elétrica tinha como objetivo simplesmente estimar o nível do racionamento. O modelo utilizado foi:

$$3.10 \quad (1 - B)(1 - B^{12})y_t = w_0 I_t + \frac{(1 - \theta B)(1 - \Theta B^{12})a_t}{(1 - \phi B)}$$

Analisando os erros nesse modelo, percebe-se que os valores percentuais ainda eram bastante altos no mês de junho de 2001, caracterizando ineficiência para reduzir de forma significativa os erros do modelo no início do racionamento.

- Já a segunda variável de intervenção testada foi introduzida no modelo por:

$$3.11 \quad (1 - B)(1 - B^{12})y_t = \frac{w_0}{(1 - \delta B)} I_t + \frac{(1 - \theta B)(1 - \Theta B^{12})a_t}{(1 - \phi B)}.$$

Nesse, esperava-se capturar uma mudança gradual no nível da série. Em relação ao modelo anterior, este apresentou redução nos erros durante o primeiro mês do racionamento e também uma redução na variância dos resíduos. Porém, os valores das previsões continuavam inferiores aos dos respectivos meses no período do racionamento. Em outras palavras, a correção foi excessiva, conduzindo a previsões inferiores aos valores observados.

Apesar das intervenções inseridas nos modelos de Box & Jenkins, as previsões não atenderam às expectativas para os cenários de carga elétrica no período de racionamento, indicando que esse método não deverá ser indicado para previsões em futuros racionamentos. Como ilustração, o leitor encontrará

no apêndice 7.2 a aplicação desses modelos para duas séries de energia, estimados pelo programa AUTOBOX 5.0.

Percebe-se que com a introdução das variáveis de intervenção nos modelos de Box & Jenkins, os erros de previsão foram ainda maiores que nos modelos sem variáveis de intervenção. Outro fato relevante é a superioridade dos modelos de Holt & Winters sobre os de Box & Jenkins.

Para uma análise completa dessa aplicação em séries de energia, recomenda-se a leitura de Mendes (2002).

3.6. Melhoria das Previsões de Carga pelos Modelos RNA e Lógica Fuzzy

Como visto na Tabela 3.2 e Tabela 3.3, esses modelos não absorvem adequadamente as informações do racionamento ao longo do tempo. Mesmo com o re-treinamento a cada nova observação, a estrutura da RNA não adquire o aprendizado necessário para realizar previsões precisas. A RNA apresenta a cada momento uma nova situação não contemplada anteriormente, fazendo com que a rede não seja treinada adequadamente para esta situação. Já para o modelo de Lógica Fuzzy, a ocorrência do racionamento afeta a combinação das regras, privilegiando as variáveis anteriores no cálculo das mais recentes.

Sartoris et al. (2000) afirma que a presença de tendência nas séries temporais compromete a aplicação de grande parte dos instrumentos econométricos. Podem-se citar os modelos ARMA, por exemplo, que se aplicam somente a séries estacionárias, o que não ocorre na maior parte das séries de carga elétrica.

As séries de carga mensal possuem uma tendência de crescimento, pois refletem a evolução da série de carga elétrica ao longo dos anos (Teixeira, 1999). Além disso, o racionamento trouxe uma mudança estrutural devido à queda abrupta da carga que alterou seu nível de maneira possivelmente permanente.

A proposta para o melhoramento das previsões desses modelos é realizar transformações nas séries temporais a fim de facilitar o aprendizado pela Rede Neural Artificial e minimizar as diferenças na construção do banco de regras na modelagem de Lógica Fuzzy. Deve-se realizar um pré-tratamento para eliminar a influência da mudança repentina do nível e o crescimento da série de forma que

a RNA não precise aprender essas particularidades, podendo-se concentrar no aprendizado de outras características.

A transformação mais comum é aquela de diferenciação, isto é, subtraindo o valor passado da variável pelo seu valor atual. Por exemplo, pode-se remover o efeito da tendência linear de uma série temporal executando uma diferença simples. Neste caso, usando a variável transformada $\Delta x_t = x_t - x_{t-1}$ é suficiente para remover sua tendência linear (Cromwell, 1994).

A Figura 3.4 mostra uma série y_t como a entrada de um sistema não-linear de previsão (possibilidade de ser RNA ou Lógica Fuzzy), e y_{t+n} a saída.

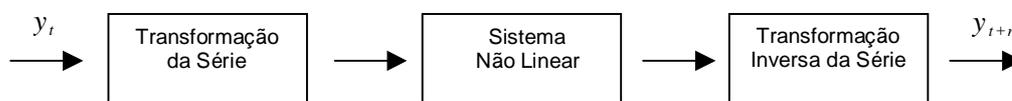


Figura 3.4 - Procedimento para previsão em RNA e L.F

Todavia, após aplicar essas transformações nas séries de carga em estudo, notou-se a presença de um valor discrepante na sua trajetória. A série de carga elétrica transformada da Figura 3.5 foi diferenciada uma única vez, isto é $\Delta y_t = y_t - y_{t-1}$. Observa-se um valor bem abaixo da média referente a junho de 2001, ou seja, o primeiro mês de racionamento.

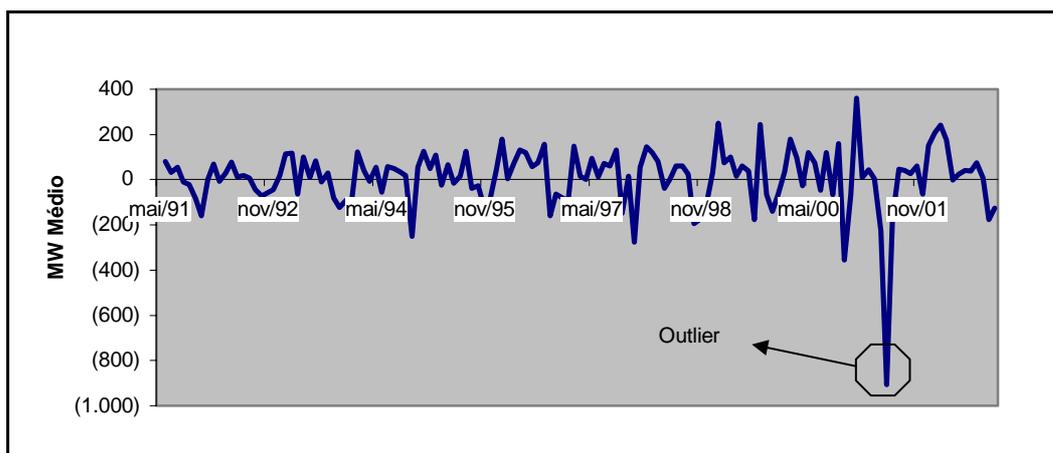


Figura 3.5 – Serie temporal transformada

Os modelos de RNA e Lógica Fuzzy empregam esse valor para obter previsões posteriores a essa data. Neste trabalho, a substituição deste será feita

pela previsão combinada um passo à frente, feita no instante anterior. Assim, o valor da y_{junho}^* passa a ter o valor da previsão \hat{y}_{maio}^* (1) da série transformada.

Para constatar a eficiência das transformações nas séries de carga elétrica para as previsões com modelos de RNA e Lógica Fuzzy, foram feitos testes com a série temporal da Figura 3.2. Os resultados apresentados na Figura 3.6 representam a previsão um passo à frente utilizando RNA após uma diferenciação na série original. Nos oito meses de racionamento, este método atinge um MAPE de 2,87%, contra 19,46% nas previsões sem transformação na série temporal.

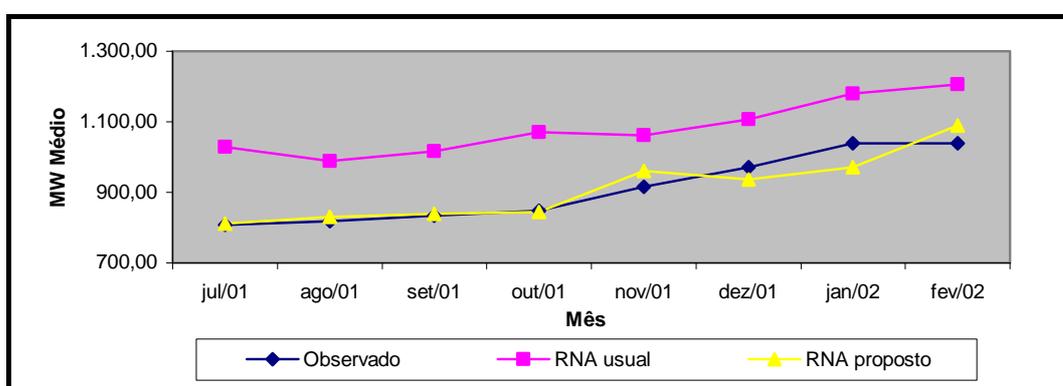


Figura 3.6 – Previsão de carga utilizando RNA

Com o método de previsão por Lógica Fuzzy, os resultados também são significativos. Pela Tabela 3.8, pode-se perceber que os APE de todos os meses diminuíram, alcançando uma MAPE de 3,49% contra 10,24% nas previsões sem transformação na série temporal.

Mês	LF Usual	LF Proposto
Jul-01	28,25%	10,90%
ago-01	11,61%	2,69%
set-01	10,67%	0,48%
out-01	18,42%	0,12%
nov-01	3,06%	4,48%
dez-01	2,98%	4,53%
jan-02	2,40%	2,60%
fev-02	4,52%	2,12%
MAPE	10,24%	3,49%

Tabela 3.8 – Erro de Previsão de carga utilizando Lógica Fuzzy

Através desse simples experimento, pode-se compensar as deficiências dos procedimentos utilizados na modelagem com RNA e Lógica Fuzzy, resultando em erros de previsão até vinte cinco vezes menores, como observado na tabela 3.8 na previsão de julho de 2001. Assim, sugere-se a utilização desse procedimento para estimar as previsões de carga em futuros racionamentos.

Além dessa série temporal, foram realizados testes para outras cinco séries de carga elétrica. Em todas elas foram encontrados resultados semelhantes, vide apêndice 7.3.

3.7. Melhoria da Combinação de Previsões

Segundo Granger (1980), na geração das previsões combinadas um passo à frente com dois modelos f_i e g_i as variâncias são estimadas a partir dos últimos m erros (eq. 2.26). Um valor sugerido por Granger para m seria 12 para dados mensais. Já no sistema de previsão PREVCAR, os dois melhores modelos são determinados segundo o histórico dos últimos 24 erros um passo à frente. Embora essa seja uma escolha arbitrária, não existem regras específicas para determinação do valor de m .

3.7.1. Variação do número de erros m usados na combinação

Como não existe nenhuma regra na escolha de quantos erros passados devem ser usados no cálculo dos pesos, realizou-se um experimento para outros valores de m . Como os erros nos primeiros meses de racionamento apresentaram níveis elevados, testou-se reduzir o número de erros de previsão para 18, 12, 6 e 3, após as propostas sugeridas para os modelos de Holt & Winters, Lógica Fuzzy e RNA. Foram realizadas previsões combinadas para três séries de carga elétrica.

Nessa parte do estudo, o objetivo é verificar qual o benefício da alteração do número de erros de previsão no cálculo do peso k para as previsões. Pela Tabela 3.9, este procedimento indica que conforme diminuimos o número de meses, as previsões combinadas divergem dos valores verdadeiros. Já nas Tabela 3.10 e Tabela 3.11, os MAPE's para previsões combinadas com m igual a 12 apontam uma ligeira melhora com redução de 0,07% e 0,16% para as séries 2 e 3, respectivamente.

Mês	24	18	12	6	3
Jul-01	4.92%	4.92%	4.92%	5.38%	4.93%
Aug-01	0.54%	0.54%	0.54%	1.07%	1.08%
Sep-01	0.32%	0.31%	0.31%	3.82%	4.32%
Oct-01	1.08%	1.07%	1.06%	1.10%	1.09%
Nov-01	2.81%	2.82%	2.76%	2.86%	2.31%
Dec-01	0.69%	0.70%	0.72%	0.92%	1.53%
Jan-02	2.20%	2.20%	1.72%	1.79%	1.84%
Feb-02	2.64%	2.65%	5.92%	2.78%	6.57%
Mar-02	4.28%	4.28%	4.28%	4.35%	4.01%
Apr-02	3.97%	3.98%	3.96%	3.98%	2.94%
May-02	0.18%	0.17%	0.19%	0.20%	0.80%
Jun-02	2.22%	2.22%	2.23%	1.10%	0.95%
MAPE	2.15%	2.15%	2.38%	2.45%	2.70%

Tabela 3.9 - Erros de previsão alterando o valor de m para a Série 1

MAPE	24	18	12	6	3
Jul-01	6.62%	6.45%	6.34%	6.45%	6.27%
Aug-01	1.57%	1.57%	1.57%	1.57%	1.57%
Sep-01	3.93%	3.92%	3.92%	3.93%	3.95%
Oct-01	1.34%	1.35%	1.35%	1.33%	1.40%
Nov-01	3.85%	3.87%	3.86%	3.82%	4.02%
Dec-01	2.10%	2.09%	2.10%	2.14%	2.21%
Jan-02	0.12%	0.15%	0.07%	0.89%	0.16%
Feb-02	3.69%	3.69%	3.63%	4.52%	4.45%
Mar-02	6.74%	6.72%	6.55%	6.32%	5.95%
Apr-02	4.26%	4.25%	4.02%	2.10%	3.21%
May-02	3.16%	3.19%	3.25%	5.23%	5.12%
Jun-02	6.26%	6.24%	6.17%	6.56%	6.51%
MAPE	3.64%	3.62%	3.57%	3.74%	3.74%

Tabela 3.10 - Erros de previsão alterando o valor m para Série 2

Mês	24	18	12	6	3
Jul-01	3.59%	3.64%	3.67%	3.68%	3.73%
Aug-01	4.92%	4.96%	4.95%	4.97%	4.99%
Sep-01	0.32%	0.74%	0.74%	0.77%	0.74%
Oct-01	3.88%	3.21%	3.21%	3.23%	3.42%
Nov-01	2.35%	2.33%	2.32%	2.30%	2.36%
Dec-01	3.47%	3.56%	3.56%	3.54%	2.95%
Jan-02	2.92%	2.93%	2.93%	2.08%	2.04%
Feb-02	1.48%	1.48%	1.48%	1.10%	1.09%
Mar-02	6.25%	6.25%	6.29%	4.27%	4.27%
Apr-02	2.75%	2.77%	2.83%	2.18%	2.16%
May-02	6.55%	6.54%	6.51%	6.64%	6.93%
Jun-02	1.99%	0.03%	0.00%	0.27%	1.32%
MAPE	3.37%	3.20%	3.21%	2.92%	3.00%

Tabela 3.11 - Erros de previsão alterando o valor m para Série 3

A partir dos resultados encontrados, percebe-se que não há ganho significativo no poder de predição do método de combinação de previsões ao trocar o número de erros de previsão para o cálculo do peso k . Portanto, conclui-se que a escolha do valor de m deverá ser feito por outro critério, como por exemplo, eficiência computacional.

3.7.2. Valor de m Variável

Como a intervenção do racionamento alterou permanentemente a evolução das séries de carga elétrica, o processo gerador da série deve ser analisado com cautela no que se refere aos efeitos na variância incondicional da série. Analisando os erros de previsão da série da Figura 3.7, no período de dezembro de 1999 a abril de 2001 e julho de 2001 a dezembro de 2002, encontrou-se um aumento no desvio padrão dos erros de 88,48 para 139,76 Mw Médio.

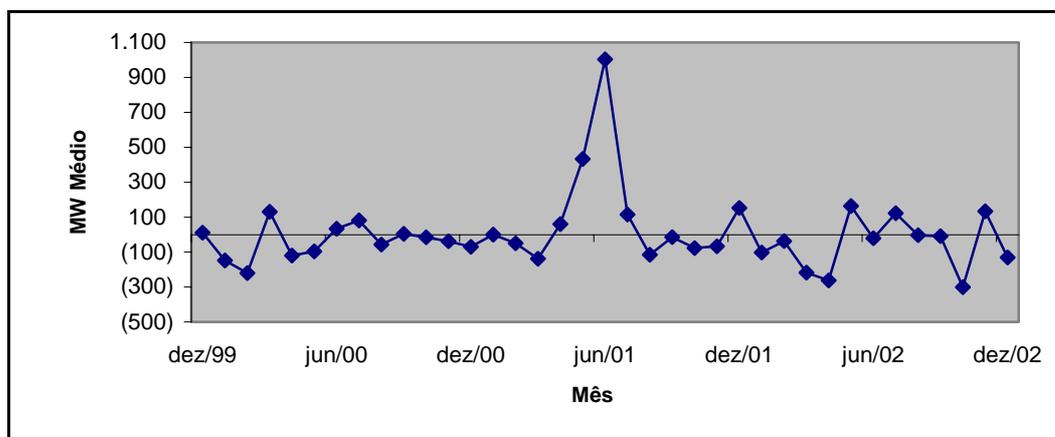


Figura 3.7 – Evolução dos erros de previsão um passo à frente

O método proposto é encontrar o peso k através da variância utilizando somente os erros de previsão a partir do início do racionamento. A idéia é analisar a série de carga elétrica somente a partir de junho de 2001, ignorando os dados passados. Dessa maneira, o valor de m varia conforme a evolução no tempo ($m = 1, 2, 3, \dots, m_{máx}$). A proposta apresentada resulta em:

$$3.12 \quad k_m = \frac{\sum_{t=n-m}^{n-1} (eg_i)^2}{\sum_{t=n-m}^{n-1} [(eg_i)^2 + (ef_i)^2]} \quad m = 1, 2, \dots, m_{m\acute{a}x}$$

Onde o $m_{m\acute{a}x}$ é o limite do valor variável de m . O valor utilizado para $m_{m\acute{a}x}$ poderia ser 24, o mesmo usado no PREVCAR.

Tendo sido definida a metodologia para alterar a combinação de previsões, realizou-se um estudo utilizando seis séries temporais. Os resultados desse experimento foram comparados com as previsões utilizando o valor m fixo, igual a 24 e estão na Tabela 3.12.

Mesmo pequeno, o erro médio absoluto para os seis experimentos foi inferior na maioria das séries. Embora a proposta não tenha tido sucesso direto nas séries 1 e 6, com aumento de MAPE, a combinação com m variável nas outras séries alcançou reduções na ordem de 10% a 20%.

Outro aspecto a ser destacado nos testes realizados com o número de erros de previsão variável refere-se à convergência dos resultados entre previsão combinada com m fixo em 24 e m variável. Nas avaliações das seis séries mostradas na Tabela 3.12, os APE tornam-se praticamente iguais a partir de abril de 2002, como por exemplo, a série 5 que apresenta APE de 7,06% em ambos os métodos.

Portanto, devido às reduções alcançadas na maioria das séries estudadas, recomenda-se a utilização desse procedimento para o cálculo dos pesos na combinação de previsões em períodos de racionamento.

Série 1	m = 24	m variável	Série 2	m = 24	m variável
jul/01	4,92%	5,07%	jul/01	6,62%	4,20%
ago/01	0,54%	1,11%	ago/01	1,57%	1,57%
set/01	0,32%	4,32%	set/01	3,93%	3,95%
out/01	1,08%	1,10%	out/01	1,34%	1,33%
nov/01	2,81%	2,80%	nov/01	3,85%	3,80%
dez/01	0,69%	0,92%	dez/01	2,10%	2,14%
jan/02	2,20%	2,22%	jan/02	0,12%	0,07%
fev/02	2,64%	2,69%	fev/02	3,69%	3,61%
mar/02	4,28%	4,31%	mar/02	6,74%	6,40%
abr/02	3,97%	3,97%	abr/02	4,26%	3,95%
mai/02	0,18%	0,19%	mai/02	3,16%	3,27%
jun/02	2,22%	2,23%	jun/02	6,26%	6,17%
MAPE	2,15%	2,58%	MAPE	3,64%	3,37%
Série 3	m = 24	m variável	Série 4	m = 24	m variável
jul/01	3,59%	1,59%	jul/01	2,62%	2,64%
ago/01	4,92%	3,30%	ago/01	1,29%	0,97%
set/01	0,32%	0,53%	set/01	0,46%	0,53%
out/01	3,88%	3,40%	out/01	1,87%	1,57%
nov/01	2,35%	2,59%	nov/01	5,28%	5,78%
dez/01	3,47%	2,13%	dez/01	0,71%	0,77%
jan/02	2,92%	2,78%	jan/02	2,99%	2,95%
fev/02	1,48%	0,72%	fev/02	1,21%	1,24%
mar/02	6,25%	4,28%	mar/02	7,71%	7,72%
abr/02	2,75%	2,31%	abr/02	1,92%	1,92%
mai/02	6,55%	6,54%	mai/02	0,56%	0,56%
jun/02	1,99%	1,99%	jun/02	1,89%	1,89%
MAPE	3,37%	2,68%	MAPE	2,38%	2,38%
Série 5	m = 24	m variável	Série 6	m = 24	m variável
jul/01	1,77%	1,83%	jul/01	6,11%	5,71%
ago/01	4,00%	3,34%	ago/01	1,85%	2,50%
set/01	2,51%	2,81%	set/01	2,24%	2,57%
out/01	3,65%	3,87%	out/01	0,24%	0,24%
nov/01	9,34%	8,28%	nov/01	2,87%	2,25%
dez/01	3,83%	3,83%	dez/01	0,03%	0,33%
jan/02	2,45%	2,48%	jan/02	0,55%	1,12%
fev/02	0,26%	0,25%	fev/02	2,68%	2,70%
mar/02	5,82%	5,81%	mar/02	12,25%	12,36%
abr/02	7,06%	7,06%	abr/02	1,72%	1,19%
mai/02	1,36%	1,37%	mai/02	4,23%	4,35%
jun/02	2,09%	2,09%	jun/02	0,33%	0,43%
MAPE	3,68%	3,59%	MAPE	2,93%	2,98%

Tabela 3.12 - Comparação dos MAPE com m variável para seis séries de carga elétrica

As Tabela 3.13 até Tabela 3.18 apresentam quais os modelos que foram selecionados para composição da previsão combinada nas previsões de julho de 2001 a junho de 2002.

Série 1	m = 24				m variável			
	B.J.	H.W.	L.F.	R.N.	B.J.	H.W.	L.F.	R.N.
jul-01	X	X			X	X		
ago-01	X	X				X	X	
set-01	X	X				X	X	
out-01	X	X			X	X		
nov-01	X	X			X	X		
dez-01	X	X			X	X		
jan-02	X	X			X	X		
fev-02	X	X			X	X		
mar-02	X	X			X	X		
abr-02	X	X			X	X		
mai-02	X	X			X	X		
jun-02	X	X			X	X		

Tabela 3.13 – Modelos utilizados na previsão combinada da série 1

Série 2	m igual a 24				m Variável			
	B.J.	H.W.	L.F.	R.N.	B.J.	H.W.	L.F.	R.N.
jul-01	X	X				X		X
ago-01		X		X		X		X
set-01		X		X		X		X
out-01		X		X		X		X
nov-01		X		X		X		X
dez-01		X		X		X		X
jan-02		X		X		X		X
fev-02		X		X		X		X
mar-02		X		X		X		X
abr-02		X		X		X		X
mai-02		X		X		X		X
jun-02		X		X		X		X

Tabela 3.14 – Modelos utilizados na previsão combinada da série 2

Série 3	m igual a 24				m Variável			
	B.J.	H.W.	L.F.	R.N.	B.J.	H.W.	L.F.	R.N.
jul-01			X	X	X			X
ago-01			X	X	X			X
set-01	X		X		X			X
out-01	X		X		X			X
nov-01			X	X	X	X		
dez-01			X	X	X		X	
jan-02			X	X	X		X	
fev-02			X	X	X			X
mar-02			X	X	X			X
abr-02			X	X	X			X
mai-02			X	X	X		X	
jun-02	X		X		X	X		

Tabela 3.15 – Modelos utilizados na previsão combinada da série 3

Série 4	m igual a 24				m Variável			
	B.J.	H.W.	L.F.	R.N.	B.J.	H.W.	L.F.	R.N.
jul-01	X	X			X	X		
ago-01	X			X	X			X
set-01	X			X	X			X
out-01	X			X	X			X
nov-01	X			X	X			X
dez-01	X			X	X			X
jan-02	X			X	X			X
fev-02	X			X	X			X
mar-02	X			X	X			X
abr-02	X			X	X			X
mai-02	X			X	X			X
jun-02	X			X	X			X

Tabela 3.16 – Modelos utilizados na previsão combinada da série 4

Série 5	m igual a 24				m Variável			
	B.J.	H.W.	L.F.	R.N.	B.J.	H.W.	L.F.	R.N.
jul-01	X	X			X	X		
ago-01	X	X			X			X
set-01	X	X			X			X
out-01	X	X			X			X
nov-01	X	X			X			X
dez-01	X			X	X			X
jan-02	X			X	X			X
fev-02	X			X	X			X
mar-02	X			X	X			X
abr-02	X			X	X			X
mai-02	X			X	X			X
jun-02	X			X	X			X

Tabela 3.17 – Modelos utilizados na previsão combinada da série 5

Série 6	m igual a 24				m Variável			
	B.J.	H.W.	L.F.	R.N.	B.J.	H.W.	L.F.	R.N.
jul-01	X	X			X		X	
ago-01	X			X	X			X
set-01	X			X	X			X
out-01	X			X	X			X
nov-01	X			X	X			X
dez-01	X			X	X			X
jan-02	X			X	X			X
fev-02	X			X	X			X
mar-02	X			X	X			X
abr-02	X			X	X			X
mai-02	X			X	X			X
jun-02	X			X	X			X

Tabela 3.18 – Modelos utilizados na previsão combinada da série 6

Pode-se perceber que não houve necessariamente repetição dos modelos devido à alteração do número de erros para o cálculo do peso k . Logo, o sucesso dos resultados encontrados depende unicamente da escolha dos modelos feita pela própria metodologia de combinação de previsões.

No próximo capítulo, serão estudados valores previstos de carga elétrica para maiores horizontes de previsão. E, em seguida, apresenta-se uma proposta para a melhoria dessas previsões em médio prazo, com horizonte de doze meses à frente.