

6

Conclusão

Desde o início do trabalho, insistentemente, levantou-se a questão da interpretabilidade das saídas do modelo que está sendo usado. Pelo que foi explicado nos capítulos 2, 3 e 4, percebe-se que a interpretação das informações é mais óbvia a partir de modelagens univariadas, como as duas que foram discutidas: Holt-Winters e Box & Jenkins, do que em modelos complexos como o ANNSTLF que é uma rede neural, ou melhor dizendo, duas redes neurais. Esta última técnica é muito válida, principalmente, para ser empregada em problemas não lineares em que os modelos convencionais falham em sua tarefa para gerar boas previsões.

Especialmente no caso do ANNSTLF e do ONS, além da perda para o usuário da possibilidade de maiores interpretações das informações na saída da rede, há também um elevado custo financeiro pela permissão junto ao EPRI para o manuseio do software no país. Acrescenta-se a estes dois fatores, as desvantagens do programa apontadas nas considerações finais do capítulo 4. Logicamente, não se ignora as suas vantagens, entre as quais está o fato do MAPE do modelo ser baixo assumindo, na maioria das vezes, valores inferiores a 2%.

Por outro lado, quando se conhece bem as particularidades da série que se deseja prever, os modelos univariados, da forma comumente conhecidos, podem ser modificados e adaptados às necessidades específicas do usuário. Numa série de dados horários, como a do sudeste brasileiro no período de 2003, que serviu de base durante todo o estudo, identifica-se uma repetição periódica no comportamento da série ao longo de um dia e de uma semana. Portanto, se reconhece nesta situação a presença de dois ciclos: um diário e outro semanal.

Sabendo da existência destes duplo ciclos na série e do delineamento que a curva dos dados segue, pôde-se então definir qual a maneira correta de “estender” as formulações convencionais dos modelos BJ e HW para se adequarem aos dados utilizados. Pensando dessa forma, foram selecionadas para serem implementadas as três modelagens apresentadas no capítulo 2 e a técnica BJ adotando os dois padrões sazonais, diário e semanal, cujo modelo foi identificado no capítulo 3

quando também fez-se a explicação dos detalhes exigidos para a identificação de sua ordem e modelagem.

Embora tenha existido desde o começo a intenção de comparar os resultados destes dois métodos alternativos com as previsões vindas pelo ANNSTLF, a meta central do trabalho foi desenvolver uma pesquisa sobre modelos univariados “*benchmark*” aperfeiçoados. As estimativas do ANNSTLF são tomadas como uma referência comparativa por estarem sendo utilizadas para o planejamento energético do país e, por isso, foram consideradas como uma forma eficaz de avaliar os resultados obtidos pelos modelos aqui desenvolvidos. Partindo deste ponto de vista, o ANNSTLF é tido como um parâmetro para averiguar melhor a eficiência das modelagens alternativas desenvolvidas.

O objetivo essencial do trabalho não foi encontrar um modelo para superar e substituir o ANNSTLF em seu papel dentro do ONS. Mas sabe-se que se estes modelos univariados estendidos permitirem obter melhores previsões que as do programa citado, a possibilidade de substituí-lo poderá ser cogitada pelo órgão.

A implementação empírica pelo método Box & Jenkins não teve resultados suficientemente bons. O MAPE para as previsões 01 passo-à-frente *out-of-sample* é de 1,1 %, valor alto para um erro de modelagem. Para 24 passos-à-frente, na análise *out-of-sample*, o erro aumenta e chega a 2,2%. O erro *in-sample* é de 1,2%.

Vale ressaltar que a variável temperatura não foi incluída no procedimento BJ univariado realizado. A inclusão desta informação poderá proporcionar uma diminuição nos valores apresentados do MAPE. Há um tipo de modelo BJ que permite incorporar causalidades como a temperatura através de uma função de transferência. Entretanto esta categoria de modelo não foi verificada neste estudo. É importante não se esquecer que as estimativas fornecidas pelo ANNSTLF contam com os dados do tempo que as técnicas univariadas ignoram. Alíás, é bom enfatizar que sem os dados de temperatura o programa não funciona.

A proposta levantada neste trabalho para o modelo BJ alternativo de maneira nenhuma se restringe aos resultados que foram mostrados. Novas pesquisas devem ser executadas observando o problema sob outros prismas. Pode-se pensar em outros processos e rotinas computacionais para a otimização de seus parâmetros que talvez permitam melhorar as previsões e reduzir o erro, ou mesmo

avaliá-los em séries de natureza distinta a que foi estudada ou para outras regiões brasileiras, pois só os dados sudeste foram explorados. Porém, estes modelos sempre estarão limitados pelo fato de seus parâmetros, uma vez estimados, se manterem constantes no tempo.

Quanto a implementação HW nas suas três formas alternativas, em razão dessa técnica ser muito adaptativa, pois os parâmetros do modelo são ajustados a cada nova observação, os resultados obtidos foram melhores do que os registrados para o modelo BJ. Para HW assumindo apenas a presença de duplo ciclos, o MAPE *in-sample* foi (0,3434%). A avaliação *out-of-sample* também mostrou uma modelagem boa: MAPE 01 passo-à-frente (0,53 %) e MAPE 24 passos-à-frente (1,60%). Estes valores são baixos quando contrastados com o desempenho do modelo BJ.

Foi observado que a presença da constante de amortecimento no modelo não implica em uma modelagem mais robusta. As previsões realizadas para 24 passos-à-frente permanecem inalteradas em relação a estrutura sem *damped trend*. Para a terceira formulação implementada, modelo HW com dois ciclos e autocorrelação dos erros como um AR(1), há uma melhora no desempenho do método em relação a forma com apenas dois ciclos. O MAPE *in-sample* (0,3%) e o MAPE *out-of-sample* para 01 e 24 passos-à-frente apresenta uma diminuição quando comparados com os respectivos MAPE da primeira forma HW estendida. Para 01 passo, o MaAPE se reduz de 0,53% para 0,47% e para 24 passos, a queda é de 1,6% para 1,53%.

Estas formulações estendidas HW já foram efetuadas em trabalhos anteriores e obtiveram excelentes resultados. Cita-se, por exemplo, a pesquisa de Taylor & Menezes & Mcsharry (2004) [17] que ao comparar quatro métodos, entre os quais uma rede neural e o HW com dois ciclos, HW foi aquele com melhor desempenho. Também Esteves (2004) [7] em sua implementação empírica com modelos HW estendidos para os dados da concessionária Escelsa/ES chegou a um MAPE de 0,5%, valor bastante inferior aos do ANNSTLF em todas as situações retratadas nas tabelas do capítulo V.

É bom frisar que de certa forma, indiretamente, a técnica HW leva em conta a variável temperatura, pois os novos dados que chegam vêm corrompidos dessa informação e são esses mesmos dados que vão ajustando e adaptando o modelo

para representar corretamente o ambiente. Esta argumentação pode ajudar a compreender o porquê dos resultados pela técnica HW terem sido tão melhores que aqueles obtidos pela metodologia BJ.

Sendo assim, as perspectivas com respeito aos resultados das modelagens descritas no capítulo 2 são promissoras e devem continuar sendo investigadas levando em conta séries de todo o país, e não apenas a região sudeste, e se possível, para um período mais longo de dados. Por exemplo, Esteves (2004) [7] usou uma série de dois anos de dados. Já Taylor & Menezes & Mcsharry (2004) [17] restringiram a sua avaliação somente a cidade do Rio de Janeiro e para um curto período de cinco meses. Estes fatos podem influenciar os resultados encontrados.

Assim, recomenda-se que os estudos continuem no sentido de uma avaliação mais consistente a respeito do desempenho de modelos univariados aperfeiçoados como os que foram detalhados aqui.

Tendo em vista os argumentos desta conclusão, acredita-se que este estudo é um estímulo para novos trabalhos seguindo essa mesma linha de pesquisa e servirão para tornar mais evidente ao ONS o quanto eficiente é o software que vem sendo utilizado. Assim, o órgão poderá avaliar com respaldos mais concretos a relação custo/benefício do uso do ANNSTLF no Brasil.