

6 Conclusões

Tendo em vista o modelo vigente no setor elétrico brasileiro, a previsão de demanda de carga elétrica para dados de alta frequência tem um papel fundamental na distribuição de energia, sendo, por isso, necessários aprimoramentos para tornar tais previsões cada vez mais precisas.

Neste trabalho, foi utilizada uma técnica inovadora para modelar dados de alta frequência: o modelo *Hierarchical Profiling Approach* (HPA). Com este, calculou-se a previsão para uma semana, ou seja, 672 passos à frente, para os dados de demanda de energia elétrica, observados a cada 15 minutos, provenientes de uma concessionária de energia do Sudeste brasileiro.

Em um primeiro momento, o HPA tratou a componente determinística da série, modelando perfis que capturaram a sazonalidade dentro do dia (perfil nível 1), o comportamento de observações atípicas como os feriados (perfil nível 2) e as demais periodicidades contidas na série (perfil nível 3). Através da aplicação do Periodograma, foram identificadas periodicidades correspondentes a oito horas, um dia, seis meses e um ano. Estas componentes foram modeladas por uma Regressão Harmônica com tendência polinomial. A componente determinística foi criada pela adição dos perfis encontrados.

O resíduo gerado pela diferença entre a série original e a componente determinística gerou a componente estocástica que foi modelada utilizando um modelo ARMA(2,2).

As previsões foram compostas pela agregação das previsões das componentes determinística e estocástica e comparadas às previsões do Modelo Naïve. A série prevista pelo HPA gerou um MAPE de 5,46% e, o Método Ingênuo, 15,08%.

O coeficiente U de Theil também foi calculado para verificar a qualidade das previsões fornecidas pelo modelo estudado. Como resultado, obteve-se o valor 0,3616 o qual indica que o erro de previsão do HPA é menor do que o do Método Ingênuo de previsão.

Com base nos resultados apresentados, pode-se afirmar que o modelo HPA fornece uma análise lúcida e poderosa da série estudada. A aplicação do modelo pode ser estendida para uma variedade de dados da vida real onde há dificuldade em obter a estacionariedade utilizando os métodos estatísticos convencionais.

A aplicação do HPA proporciona um melhor entendimento da dinâmica subjacente aos dados, visto que as componentes da série são estudadas a fundo e, ao mesmo tempo, serve como uma técnica de pré-branqueamento dado que separa as componentes até obter a parcela estocástica presente na série.

Esta metodologia pode, ainda, ser usada para prever em massa e tem a vantagem de poder ser implementada em softwares já existentes. O modelo pode, ainda, ser visto como uma abordagem quantitativa para incorporar a opinião de especialistas na análise de séries temporais estocásticas.

6.1. Sugestões

A inclusão de variáveis explicativas no modelo pode contribuir para captar padrões que não foram detectados pelo modelo estimado. Poder-se-ia estudar a inclusão de variáveis como temperatura, luminosidade, chuvas, população atendida, etc, além do efeito das estações do ano. O grande problema para tal melhoria consiste na obtenção destas variáveis. Por isto, caso o acesso a esses dados torne-se viável, pode ser feita uma nova análise, aprimorando a que foi aqui apresentada.

A inclusão de opiniões mais detalhadas provenientes de especialistas da área energética também poderia trazer ganhos significativos para o poder explicativo do modelo.

Para a base de feriados, caso também esteja disponível um histórico maior, pode-se analisar o seu impacto de acordo com a condição meteorológica do dia a ser previsto. Poderiam ser analisados separadamente os feriados de verão e os de inverno, por exemplo, o que não pôde ser feito aqui devido à pouca quantidade de dados. Assim, poder-se-ia classificar um dia de feriado a ser previsto como dia quente, frio ou intermediário e analisar o comportamento da demanda de energia.

Com relação ao modelo proposto, uma sugestão é testar técnicas diferentes para modelar a componente estocástica, como o Método Holt, Holt-Winters, Redes Neurais Artificiais, etc. e verificar qual técnica produz o modelo mais aderente. Além disso, pode-se estudar a possibilidade de gerar intervalos de confiança para as previsões.