

### 3 Modelo Proposto

A previsão de demanda de energia tem sido objeto de diversos estudos baseados em séries temporais, a maioria dos quais utilizam modelos de função de transferência para representar os dados.

A utilização de variáveis meteorológicas como fatores explicativos para estes modelos, por exemplo, é decorrente do efeito do clima sobre o comportamento do consumidor, o que influencia a demanda de eletricidade. Há diversos outros fatores que influenciam o comportamento do consumidor, dentre os quais podem ser citados a ocorrência de feriados, mudanças de cunho político, econômico, etc.

Estes fatores contribuem para a não estacionariedade do processo bem como para a multiplicidade de periodicidades e a presença de distúrbios repetidos, embora não-sistemáticos. Tais processos não podem se tornar estacionários pela simples aplicação das técnicas convencionais de diferenciação.

As observações exóticas não afetam os inter-relacionamentos que governam a dinâmica dos dados, porém desfiguram as ferramentas de identificação dos modelos como, por exemplo, as Funções de Autocorrelação e Autocorrelação Parcial.

Entre as abordagens clássicas de pré-processamento dos dados que lidam com este problema, pode-se citar a diferenciação linear e sazonal que apresenta resultados efetivos quando os dados são bem-comportados. Tal técnica, porém, não consegue tratar os distúrbios aperiódicos e as observações exóticas.

Outra técnica clássica, a análise de intervenção necessita de uma quantidade suficiente de observações ‘limpas’ para produzir bons resultados. O problema

inerente a este método é que pode haver super parametrização do modelo quando há muitos pontos exóticos e janelas de tempo a modelar.

O HPA, *Hierarchical Profiling Approach*, é uma técnica estatística de modelagem inovadora introduzida por Al-Madfai, Ameen & Ryley (2001), que proporciona uma estrutura generalizada de modelagem para eventos específicos. Além disso, o HPA proporciona um melhor entendimento do processo observado, pois modela as componentes da série explicitamente e é capaz de lidar com dados de múltiplas periodicidades.

A modelagem HPA é capaz de tratar observações atípicas únicas, periódicas ou não, bem como janelas de tempo atípicas enquanto, ao mesmo tempo, funciona como uma poderosa técnica de pré-branqueamento.

Diversos estudos já mostraram a habilidade preditiva do modelo. Al-Madfai, Ameen & Ryley (2001) mostram uma aplicação do HPA a dados diários de demanda de eletricidade do País de Gales. Outra aplicação em séries de energia pode ser encontrada em Al-Madfai, Ameen & Ryley (2004), onde os autores modelam, novamente, dados diários de demanda de energia e tratam as férias escolares e o feriado de Natal como observações exóticas.

Al-Madfai *et al.* (2009) aplicaram o HPA a dados de consumo de energia de meia em meia hora onde são estudados, separadamente, a Páscoa, o Natal, as férias escolares e o efeito das estações do ano, obtendo excelentes resultados.

Outras aplicações de sucesso do HPA estão relacionadas à previsão do número de crimes e assaltos no País de Gales. Entre elas, pode-se citar Al-Madfai (2005) e Al-Madfai *et al.* (2007). Nestes trabalhos, as previsões obtidas pela aplicação do modelo HPA são estudadas e distribuídas espacialmente.

Todos estes resultados apontam a adequabilidade desta nova técnica de modelagem, principalmente a dados de alta frequência, e servem como motivação para investigar o comportamento do modelo na modelagem de outras séries temporais.

Um dos principais conceitos da modelagem HPA é a definição de perfil. Segundo Al-Madfai, Ameen & Ryley (2001), um perfil pode ser definido como uma mudança típica do comportamento normal de uma série temporal, durante ou em resposta a um evento conhecido. Os perfis são hierárquicos e podem modelar eventos dentro do ano (eventos atípicos e janelas de tempo), ciclos anuais (sazonalidade) e ciclos maiores.

A criação dos perfis identifica e modela os eventos distintos periódicos e aperiódicos em séries de tempo e associa mudanças de nível nos dados a eventos salientes na série.

A metodologia HPA se baseia na criação e identificação de perfis pré-existentes nos dados para gerar previsões ou simplesmente explicar a dinâmica que rege seu comportamento. O HPA combina, hierarquicamente, diferentes níveis de perfis em sua aplicação.

A metodologia decompõe a variabilidade da série temporal em componentes de caráter determinístico, estocástico e ruído para identificar os padrões e modelar os dados.

Os perfis identificados são tipicamente modelados utilizando funções contínuas de tempo cuidadosamente selecionadas e acumuladas aditivamente na componente determinística, porém outras abordagens alternativas podem ser utilizadas.

A componente estocástica, resultado do ajuste da componente determinística, pode ser modelada utilizando uma abordagem adequada, geralmente um modelo ARIMA. O ruído é suposto aleatório.

A forma geral do modelo HPA é:

$$y_t = f(t) + Z_t \quad (3.1)$$

onde  $y_t$  é a série observada,  $f(t)$  é a componente determinística que modela os perfis e  $Z_t$  é a componente estocástica a ser modelada.

A componente determinística visa, via procedimentos iterativos, perfilar os eventos atípicos em conjunto com as outras componentes, incluindo tendência, sazonalidade e ciclos que a série possa conter. Tal componente contém os perfis da série e pode ser identificada através de análises quantitativas e qualitativas ou através da opinião de especialistas.

Os perfis identificados são acumulados aditivamente de forma a capturar o máximo de informação determinística proveniente da série. Há diversas metodologias que podem modelar a componente determinística; a principal delas é a modelagem via Mínimos Quadrados Ordinários.

Após a modelagem da componente determinística, a componente estocástica é criada iterativamente a cada correção da série, ou seja,  $Z_t$  é o perfil corrigido remanescente a cada nível.

O HPA combina, assim, diferentes níveis de perfis.

- O primeiro nível modela e corrige as variações dentro do ano;
- O segundo nível trata os comportamentos atípicos, tais como feriados e mudanças provocadas pelas estações do ano;
- O nível seguinte trata o comportamento geral da série durante o ano, incluindo tendência, sazonalidade e ciclos, etc.

O último perfil pode ser modelado através da aplicação de Regressão Harmônica com tendência polinomial conforme a equação (2.39). Dado o ajuste do perfil final, os perfis podem ser combinados.

O perfil geral é, então, composto pela agregação de todos os subperfis mencionados anteriormente:

$$f(t) = \sum f_i(t) \quad (3.2)$$

onde  $f_i(t)$  corresponde a cada perfil ajustado nas etapas anteriores.

Os desvios entre a série original e o perfil geral são dados por:

$$y_t - f(t) = Z_t \quad (3.3)$$

onde  $Z_t$  é a componente estocástica resultante da modelagem dos perfis.

O último passo do HPA tem por objetivo a construção de um modelo de Box & Jenkins (1976) que consiste em ajustar modelos auto-regressivos integrados de médias móveis, ARIMA (p,d,q). Além do modelo ARIMA, outras abordagens como Modelo de Espaço de Estados, Redes Neurais Artificiais, Método Holt, Método Holt-Winters, Amortecimento Exponencial e Passeio Aleatório podem ser usados para modelar a componente estocástica.

Cabe salientar que na modelagem HPA tanto a quantidade de perfis, quanto a metodologia que trata cada perfil variam de acordo com a análise do profissional.

Somente uma análise profunda e cuidadosa dos dados pode definir a forma de tratar a componente determinística do modelo. Após a modelagem desta componente é possível proceder à estimação de um modelo de previsão para a componente estocástica e, finalmente, para a série como um todo.

Dadas as previsões para a componente estocástica, as previsões para a série original são obtidas pela agregação destas com as previsões da componente determinística construída a partir dos perfis. A equação de previsão  $k$  passos a frente é:

$$y_t(k) = f(t+k) + Z_t(k) \tag{3.4}$$

A Figura 3.1 apresenta o fluxograma que resume a modelagem HPA.

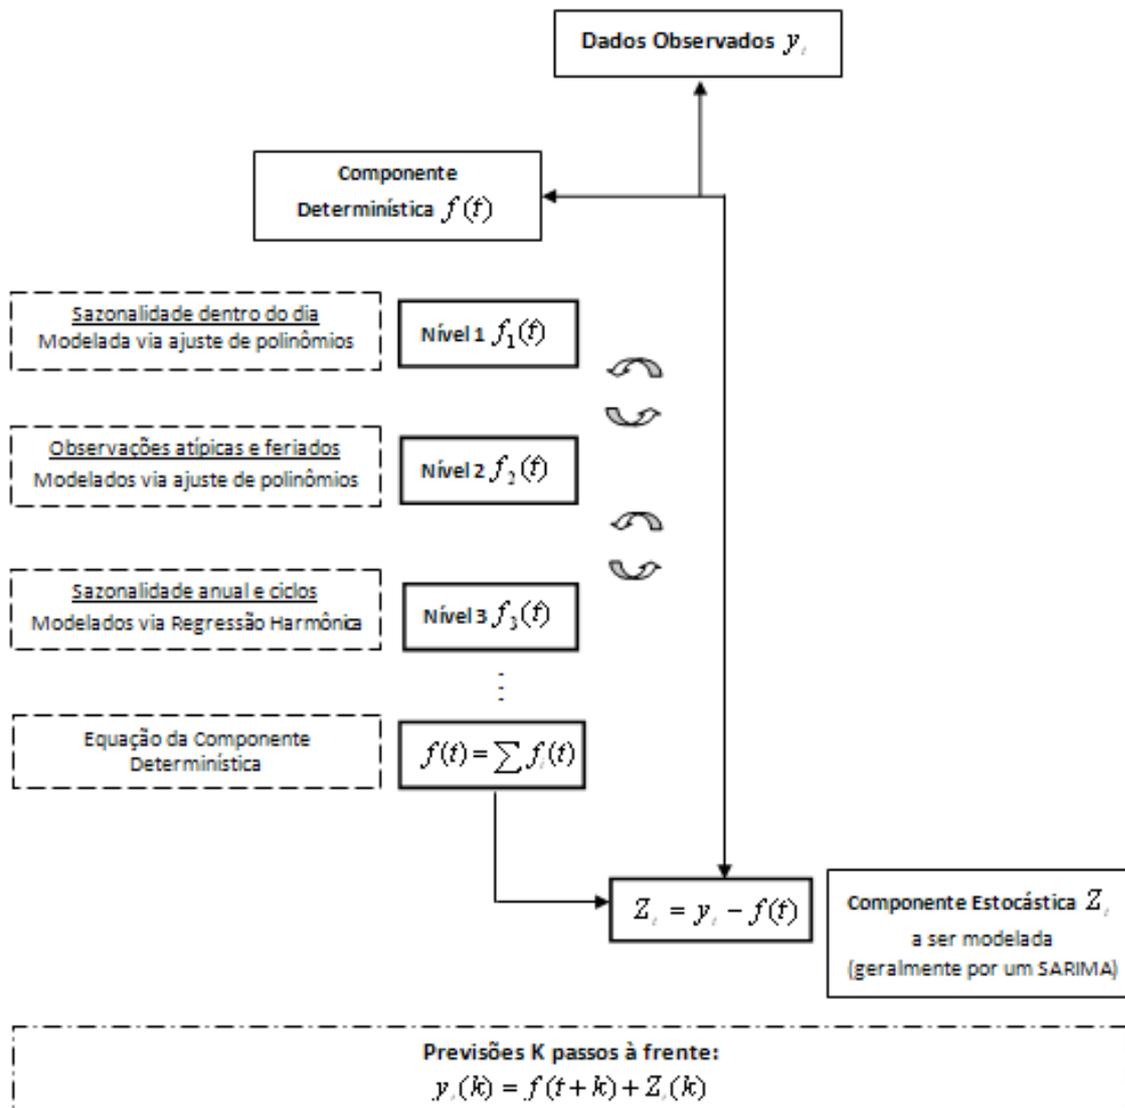


Figura 3.1 Fluxograma da modelagem HPA

A seguir, todas as etapas da modelagem serão mais detalhadas e o processo de modelagem será descrito conforme a aplicação em um conjunto de dados reais.