

## **2. Revisão Bibliográfica**

Antes de definir o modelo para previsão de carga elétrica, é necessário fazer um breve resumo dos mais tradicionais modelos de previsão de carga publicados nos principais periódicos da área.

Verificou-se através de pesquisa bibliográfica em previsão de carga elétrica, que quase nenhuma abordagem do assunto em questão emprega árvore de regressão (Huang, 1997). Por isso, decidiu-se, também, fazer uma lista dos principais modelos de árvore de regressão e avaliar a possibilidade e o desempenho de um desses na previsão de carga elétrica, já que este tipo de modelagem apresenta uma grande facilidade de interpretação dos resultados.

### **2.1. Modelos de Previsão de Carga Elétrica**

A maioria dos modelos usuais de previsão já foi experimentado na previsão de carga: modelos auto-regressivos multiplicativos (El-Keib et al, 1995), modelos dinâmicos lineares (Douglas et al, 1998), modelos não lineares (Sadownik e Barbosa, 1999) e métodos baseados no filtro de Kalman (Silva, 2001). Entre os modelos causais, nos quais a carga é modelada como função de alguma variável exógena, têm sido tentadas as funções de transferências de Box & Jenkins (Hagan e Behr, 1987), modelos ARMAX (Yang et al, 1996), técnicas de otimização (Yu, 1996) e modelos estruturais (Harvey e Koopman, 1993).

Apesar do grande número de alternativas, contudo, os modelos causais mais frequentes encontrados na literatura são os modelos lineares aditivos que decompõem a carga, geralmente, em um componente básico e um componente relacionado com o clima (Bunn, 1985). O componente básico deve refletir o comportamento normal da série de cargas, é equivalente ao valor esperado da carga, dados os valores passados da série, se não houver nenhuma circunstância anômala. O componente relacionado com o clima deve modelar a influência das variáveis meteorológicas na carga. É evidente que, parte desta influência já foi

explicada pelo componente básico, já que o efeito do clima tende a se inserir nos valores passados da série, no entanto, este componente em geral só é significativo quando ocorrem mudanças meteorológicas inesperadas. Estes métodos de decomposição são bastante úteis, porque é possível atribuir aos componentes uma interpretação física, o que permite aos operadores do sistema entenderem melhor o comportamento da série, e permite aos agentes do mercado entenderem melhor os mecanismos causadores da volatilidade.

Na década de 90, a grande presença dos sistemas especialistas é marcante. Os modelos são baseados em rede neural (Hsu e Yang, 1991; Hippert, 2001), lógica nebulosa (Hsu e Ho, 1992), sistemas neuro-nebulosos (El-Sharkawi, 1997) e modelagem estatística combinada com uma ou com algumas dessas técnicas (Lourenço, 1998).

Parte dos artigos investigados se interessava por previsões pontuais: da carga uma hora à frente, da carga de pico ou da energia total um dia à frente. A outra parte dos artigos tratava do problema mais complexo de previsão: a curva de carga horária para o dia seguinte.

Quatro abordagens diferentes foram mencionadas nos artigos, para possibilitar a previsão da curva de carga horária para o dia seguinte:

- Previsão Iterativa: consiste em prever um valor horário de cada vez e agregar este valor à série de entradas do modelo, de modo que, as previsões para os valores seguintes são baseadas nas previsões anteriores (incerteza crescerá);
- Previsão por meio de curva padrão: Consiste em criar um modelo para o perfil diário e explicar os desvios de carga em relação a este modelo como consequência do efeito de variáveis exógenas.
- Previsão por Modelos em Paralelo: Consiste em modelar perfil por meio de conjuntos de modelos similares em paralelo (um modelo para cada hora do dia). Uma desvantagem desta abordagem é a de que, por considerar cada hora em separado, os modelos não exploram suficientemente a autocorrelação entre as cargas em diferentes horas do perfil.
- Previsão por modelo único (saída multivariada): Consiste em usar um modelo único com 24 saídas, cada uma responsável pela previsão do perfil diário e as entradas do modelo em geral incluem todas as cargas do perfil

do dia antes da previsão. Esta última forma pode apresentar melhor desempenho, que um modelo para cada hora, já que leva em conta a dependência serial entre os dados.

## **2.2. Árvore de Regressão**

Essa classe de modelos inicia-se com o modelo TAR - “Threshold Autoregressive Model” - proposto por Tong em 1978 e discutido em detalhes por Tong (1983). No entanto, o modelo TAR não recebeu muita atenção, logo no início de seu aparecimento, principalmente, por dois fatores: dificuldade de identificar a variável decisória para quebra e determinar o valor para esta quebra. Em função destes obstáculos, Tsay (1989) desenvolveu alternativas para construir este tipo de modelo.

No trabalho de Tsay (1989), o “Teste F” é proposto para testar a não-linearidade (quebra da árvore) e especificar a variável decisória (ou seja, a variável de quebra da árvore). Além disso, algumas fontes gráficas (gráfico de dispersão de resíduos) são usadas para identificar o “ponto de quebra” da variável decisória.

Mais tarde, o modelo TAR tornou-se bastante popular para a análise de séries temporais não-lineares. A idéia central do modelo TAR é alterar os parâmetros do modelo auto-regressivo linear de acordo com o valor de uma variável observada, chamada de variável decisória ou variável limiar. Se esta variável for um valor defasado da própria série temporal, o modelo é chamado de auto-regressivo com limiar auto-excitado - SETAR - proposto por Tong e Lim (1980). Descrito em termo de representação de árvore de decisão, o modelo SETAR, originalmente, é limitado a uma única variável decisória.

Após o modelo SETAR, tem-se o modelo ASTAR - “Adaptative Smooth Threshold Regressive Models” (Lewis, Ray e Stevens, 1994). O modelo ASTAR é obtido pela aplicação do sistema MARS - “Multiple Adaptative Regression Splines” (Friedman, 1991).

Tanto o modelo SETAR quanto o modelo ASTAR são os modelos mais próximo relacionados com a família do modelo TAR. Ambos os procedimentos SETAR e ASTAR, assim como modelos TAR, são modelos lineares por parte.

O modelo ASTAR difere do modelo TAR em dois aspectos: o erro estimado para um modelo TAR pode diferir entre cada parte do modelo linear por parte e os modelos TAR permitem existir discontinuidade entre os modelos lineares por parte.

Outra abordagem para árvore de regressão é descrita por Chipman, George e McCulloch (2001). Neste modelo, a abordagem bayesiana usa a técnica Monte Carlo Cadeia de Markov para explorar o espaço de modelos alternativos.

Por fim, tem-se o procedimento TS-TARX (“Tree Structured - Threshold Structured with eXternal variables”) desenvolvido por Aranha e Veiga (2001). Este procedimento consiste numa busca em árvore binária calculando a estatística F para a seleção das variáveis decisórias e o critério de informação BIC (“Bayesian Information Criterion”) para seleção dos modelos. Este procedimento será detalhado no Capítulo 4, pois será empregado em uma das etapas da modelagem proposta.