

INTRODUÇÃO

A análise de séries temporais e suas aplicações vêm cada vez mais se tornando importantes em diversas áreas, como na indústria, no mercado de capitais, na engenharia, medicina, ciências sociais, política, entre outras. Com o avanço computacional das últimas décadas, tornou-se viável investir na pesquisa e aplicação de modelos cada vez mais complexos, que buscam levar em conta diversos aspectos relevantes para a estimação. Há séries heterocedásticas, como também séries bem comportadas; séries sazonais; séries que podem ser explicadas através de variáveis exógenas, do seu próprio passado ou de uma combinação de ambos; séries aonde a relação com suas variáveis regressoras é de natureza não-linear; séries com comportamento linear, polinomial, exponencial; séries com relação de causa e efeito mútua, etc.

É possível continuar descrevendo características das séries. Para estimá-las, existe uma γ enorme de modelos disponíveis, com diferentes níveis de complexidade, e com aplicabilidades diferentes. Modelos auto-regressivos, por exemplo, são simples de implementar, e possuem uma grande área de aplicação. O mesmo pode se dizer de regressões lineares simples e múltiplas. Modelos lineares de séries temporais são amplamente descritos em [6] e [11]. Modelos complexos normalmente se propõem a tratar casos específicos, muitos com motivação econômica relevante. Séries financeiras são um bom exemplo, pois em geral apresentam heterocedasticidade forte e impossibilidade de previsão e, devido a sua relevância, têm destaque nesta área de pesquisa.

Os objetivos da estimação de séries podem ser vários. Pode-se estar interessado na previsão de valores futuros, no entendimento do comportamento de uma série ao longo do tempo, na relação entre variáveis, no controle de séries ou no estudo de cenários baseados no comportamento de variáveis regressoras. Apesar de disponíveis há bastante tempo em softwares científicos ou em áreas técnicas da indústria, com a difusão de sistemas gerenciais de *Business Intelligence* nas empresas, o espaço para modelos de séries temporais nesta área é bastante promissor (assim como o de outros métodos de apoio a decisão). Boa parte das

soluções existentes atualmente enfatiza bastante em interatividade e na fácil manipulação e integração de dados. A análise de séries temporais se encaixa perfeitamente neste mercado, pois é bem razoável acreditar que um gerente, ao acompanhar seus indicadores de performance, fará bom uso da previsão, análise e criação de cenários para este tipo de informação. O mercado já está caminhando nesta direção, por exemplo, incluindo funções de *data mining* em bancos de dados de larga escala (como é o caso da Microsoft com o SQL Server e Analysis Services e da Oracle). Um desafio nesta área, porém, é o de tornar simples o uso de metodologias complicadas para um público sem conhecimento estatístico.

Esta dissertação é focada em uma classe de modelos, denominada STAR-Tree. Estes modelos unem conceitos de árvore de decisão, conceitos de lógica nebulosa, e modelos auto-regressivos, tornando possível a estimação de séries com comportamento não-linear através da combinação de modelos lineares. Sua estimação, porém, nem sempre é trivial. Fatores como o tamanho da série de dados, a diversidade presente nos dados, a predominância de alguns modelos lineares sobre outros, e a dificuldade de estimação dos parâmetros não-lineares dificultam a correta identificação dos modelos. Aplicações de modelos da classe STAR podem ser vistos em [12, 13, 14, 15].

No capítulo 2, a classe de modelos STAR-Tree é explicada em detalhes. O conceito de função de pertinência é introduzido, para logo em seguida ser detalhado um caso particular desta classe, o LSTAR. Em seguida, é ilustrado o conceito de árvores de decisão, para finalmente formular o modelo geral STAR-Tree. No capítulo 3, é detalhada a estratégia de estimação utilizada nestes modelos, e são introduzidos quatro métodos propostos para estimar seus parâmetros não-lineares. Por fim, é realizada uma simulação de Monte Carlo para avaliar a eficácia da estratégia de estimação escolhida, com cada um dos métodos, sob diversos cenários. Estes cenários envolvem árvores de tamanho diferente, diferentes configurações de parâmetros e de variáveis de transição. No capítulo 4, são introduzidos dois algoritmos de crescimento de árvore, e o modelo STAR-Tree é aplicado a uma série temporal de dados reais, sendo comparado a um modelo linear. No capítulo 5, é descrito o sistema que foi desenvolvido para realizar todas as estimações e simulações.