

## 6 Conclusão

Nesta dissertação foi proposta uma metodologia de aplicação do modelo STAR-Tree (Smooth Transition AutoRegression Tree), para séries heterocedásticas de finanças.

O modelo combina aspectos do modelo STAR (Smooth Transition AutoRegression) e do algoritmo CART (Classification and Regression Tree), resultando em um modelo estruturado em árvore, com transição suave entre os regimes. Cada regime é um modelo auto-regressivo com variáveis exógenas.

A construção do modelo é baseada em uma sequência de testes Multiplicadores de Lagrange, que indicam o nó a ser dividido (se houver) e a variável de transição correspondente. A estimação dos parâmetros é feita por mínimos quadrados não lineares.

Os resultados empíricos foram obtidos através da aplicação do modelo a séries temporais do mercado acionário americano. O modelo foi especificado para a média e volatilidade realizada das séries.

O desempenho do modelo para o retorno foi comparado com o modelo Média, o método Naive, modelos lineares ARX e Redes Neurais, através de medidas estatísticas e financeiras.

Nos resultados estatísticos obtidos no período *in-sample*, o modelo STAR-Tree-RC teve desempenho superior aos outros em praticamente quase todas as ações. No período *out-of-sample* os resultados estatísticos de todos os modelos foram praticamente equivalentes. O modelo STAR-Tree, assim como as redes neurais, tem uma tendência ao sobreajuste dos dados (*overfit*) devido ao alto número de parâmetros, por isso, apesar de ter o poder explicativo mais alto *in-sample* na maioria das séries, pode não ter a melhor validação externa, ou seja, o melhor ajuste *out-of-sample*.

No período de teste (*out-of-sample*), o modelo STAR-Tree Heterocedástico e o modelo Média apresentaram desempenho financeiro superior para o mesmo número de séries.

Olhando para as 23 ações, calculou-se a média dos retornos anualizado e acumulado das ações no período *out-of-sample* (544 dias). Nessa abordagem o STAR-Tree-RC apresenta o maior retorno entre os modelos comparados, seguido do modelo Média.

Também foi realizado o teste de Harvey, Leybourne e Newbold (1997), que é uma modificação do teste de Diebold e Mariano (1995) de igualdade de precisão preditiva. Os modelos STAR-Tree, nas suas 3 versões (RC, MM e ARC), foram comparados com os modelos Média, Naive e ARX com relação ao erro absoluto, erro quadrático e retorno acumulado das previsões no período *out-of-sample*.

Com relação às medidas estatísticas de previsão, os modelos STAR-Tree foram estatisticamente superiores ao método Naive e ao modelo ARX em grande parte das ações, porém não a hipótese nula de igualdade dos erros não foi rejeitada em nenhuma das séries ao comparar os STAR-Tree com a Média. Com relação às medidas financeiras, os STAR-Tree apresentaram resultados significativamente melhores do que o Naive em 5 séries (AIG, BA, HD, JNJ e PG), melhores do que a Média em 4 séries (AA, AIG, KO e WMT) e melhores do que o ARX em 3 séries (AA, AIG e KO).

Fica claro que o modelo STAR-Tree é muito sensível aos dados, e seu desempenho pode variar muito para cada séries modelada.

Foi ainda realizada uma análise de alavancagem de capital utilizando a previsão da volatilidade realizada. Espera-se que os modelos não lineares sejam mais úteis quando o que importa é a densidade preditiva (exemplo, apreçamento de opções, alavancagem). Porém essa possibilidade não provocou aumento significativo nos retornos acumulados dos modelos STAR-Tree-RC e STAR-Tree-MM. No caso do STAR-Tree-ARC, a possibilidade de alavancagem de capital gerou ganhos positivos em aproximadamente 57% das séries testadas.

Nota-se que o desempenho estatístico apresentado pelo modelo STAR-Tree para a volatilidade realizada é muito superior ao apresentado pelos modelos para o retorno.

É importante ressaltar que os dados dos retornos apresentam problemas que dificultam a sua previsão. A base de dados não filtra o “efeito *split*” que é quando uma ação é dividida em várias partes, dividindo o seu preço. Isso aparece na base de dados como grandes quedas do retorno. Mesmo com o tratamento de dados realizado neste trabalho, ainda não foi suficiente para filtrar por completo esse

efeito. Isso pode estar resultando em um desempenho abaixo do esperado. Outro problema encontrado foi e variância das séries  $y_t^*$  serem maiores que 1, como mostrado na tabela (5.3), o que não era esperado, uma vez que são as séries do retorno dividido pela sua volatilidade realizada. Deste modo o modelo utilizado pode não ter sido o mais adequado aos dados, já que tinha como premissa a homocedasticidade das séries. Para estudos futuros, recomenda-se a aplicação do modelo a séries de retornos sem os problemas apresentados por essa base de dados.

Comparando os resultados obtidos com a aplicação dos modelos em negociação automática e o rendimento real de cada ação no período testado (*Buy & Hold*), não podemos garantir que vale a pena fazer negociação automática com base na previsão destes modelos.

Além disso, não foram considerados aqui os custos de transação, que diminuiriam ainda mais os ganhos a partir dos modelos de previsão.

Para um estudo posterior, recomenda-se a retirada destes valores espúrios, gerados pelo “efeito *split*” da base de dados e a reestimação dos modelos.

Outra análise interessante é o estudo das variáveis de transição escolhidas nos modelos STAR-Tree para cada ação, indicando onde está a não linearidade das séries. Desta forma, pode-se determinar, ou explicar, padrões de comportamento e fatos estilizados das séries de finanças.