

4 Modelo STAR-Tree Heterocedástico

4.1. Introdução

Um dos tópicos mais estudado em econometria financeira é a modelagem e previsão da variância condicional, ou volatilidade, de séries temporais de finanças, pois desempenham um importante papel na avaliação dos ativos financeiros. A volatilidade prevista é usada, por exemplo, em seleção de portfólio, controle de risco, apreçamento de derivativos, etc.

Alguns modelos não-lineares surgiram para modelar a variância da série ao invés do nível. Os mais populares, o ARCH (Autoregressive Conditional Heteroskedasticity), proposto por Engle (1982) e o GARCH (Generalized Autoregressive Conditional Heteroskedasticity), apresentado por Bollerslev (1986), estão, hoje, completamente incorporados nas práticas econométricas de finanças.

O modelo STAR-Tree, proposto por Rosa, Veiga e Medeiros (2008) é um modelo para a média de séries homocedásticas, mas para a aplicação em séries financeiras, essa hipótese não é real, uma vez que as séries de retorno não apresentam variância constante. Neste capítulo apresentaremos uma metodologia para a estimação de séries temporais heterocedásticas usando a modelagem STAR-Tree apresentada no Capítulo (3).

4.2. Volatilidade Realizada

Com o rápido crescimento do mercado financeiro, e a dificuldade em se modelar e prever retornos diários de ativos financeiros, especialmente de ações, há uma crescente necessidade de conhecimento teórico e empírico sobre a volatilidade nas séries financeiras. Como a volatilidade dos retornos apresenta correlação, é mais fácil de prever do que a série de retornos em si. Por esses motivos, a econometria financeira, em particular a modelagem da volatilidade

financeira, vem representando um importante papel nas teorias de apreçamento e controle de risco.

No entanto, o uso desses modelos para a volatilidade apresenta um problema inerente, a volatilidade é latente, e não diretamente observável. A volatilidade pode ser estimada por modelos de variância, como mencionado na seção anterior, mas a maioria dos modelos de volatilidade latente falha em descrever, de maneira satisfatória, diversos fatos estilizados observados nas séries de finanças.

Alguns fatos estilizados da volatilidade são bastante estudados, como autocorrelações fortemente persistentes, documentado inicialmente por Taylor (1986) para valores absolutos de retornos de ações, e assimetria na resposta da variância condicional das séries a choques (notícias inesperadas). Black (1976) observou que o mercado se torna mais volátil em resposta a choques negativos (más notícias) do que a choques positivos (boas notícias).

A busca por um arcabouço adequado para a estimação e previsão da variância condicional de retornos de ativos financeiros, levou a uma análise de dados intra-diários de alta frequência. Merton (1980) notou que a variância de um intervalo fixo pode ser estimada arbitrariamente, porém de maneira acurada, como a soma dos quadrados das realizações disponíveis em uma base de dados de alta frequência. A partir deste momento, as técnicas na literatura para medir a volatilidade de séries financeiras em dados intra-diários se multiplicaram. Com isso, a volatilidade de séries financeiras de realizações passadas se torna, essencialmente, “observável”.

Ao se tornar “observável”, a volatilidade pode ser modelada diretamente, e não mais ser tratada como uma variável latente. Baseados nestes resultados, diversos estudos recentes documentaram as propriedades de volatilidades realizadas construídas a partir de dados de alta frequência. A volatilidade realizada herdou todos os fatos estilizados que foram estabelecidos para a volatilidade nas especificações de variável latente. Recentemente, Andersen et al. (2001) estabeleceu o conceito de memória longa, ou dependência de longo prazo, como essencial para o estudo da variância de ativos financeiros.

Alguns problemas na estimação da volatilidade diária, como efeitos de microestrutura, são discutidos na literatura e soluções são propostas, mas não faz parte do escopo deste trabalho.

Supondo que, em um dado dia de transação t , os preços são observados em certa frequência, suficientemente alta², onde n_t é o número total de observações no dia t , a variância realizada é definida como a soma de todos os retornos quadráticos intra-diários de alta frequência disponíveis da seguinte forma:

$$RV_t^{(all)} = \sum_{i=0}^{n_t} r_{t,i}^2 \quad (4.1)$$

onde $r_{t,i}^2$ é o quadrado do retorno da observação i do dia t , $i = 1, \dots, n_t$.

A volatilidade realizada é a raiz quadrada da variância realizada.

4.3. Metodologia

Como foi falado no Capítulo (3), Seção (3.4), a estimação do modelo STAR-Tree leva em conta a hipótese de que o erro do modelo é homocedástico, apresenta variância constante.

Para modelarmos séries com heterocedasticidade, variância não constante, definimos o seguinte modelo:

$$y_t = H_{\mathbb{T}}(x_t; \psi) + \varepsilon_t = \sum_{i \in \mathbb{T}} \beta'_i \tilde{z}_t B_{\mathbb{J}i}(x_t; \theta_i) + \varepsilon_t \quad (4.2)$$

tal que,

$$\varepsilon_t = h_t^{1/2} \eta_t$$

onde $\eta_t \sim \text{NID}(0,1)$ e $h_t^{1/2}$ é a volatilidade da série. Os parâmetros de $H_{\mathbb{T}}$ foram definidos previamente no Capítulo (3). As funções de pertinência $B_{\mathbb{J}i}$ são definidas pelas equações (3.4) e (3.5).

Define-se \mathfrak{F}_{t-1} como o conjunto das variáveis explicativas em $t-1$ e parâmetros do modelo, ou seja $\mathfrak{F}_{t-1} = (x_t; \psi)$, onde x_t pode conter lags de y_t funções de lags de y_t , variáveis exógenas e tendências lineares. Deste modo, calcula-se o valor esperado e a variância condicionais da variável y_t como

² Andersen e Bollerslev (1998) sugerem a frequência de 5 minutos para uma boa medida, por exemplo.

$$E\left[y_t/\mathfrak{F}_{t-1}\right] = H_{\mathbb{J}\mathbb{T}}(\mathfrak{F}_{t-1}) \quad (4.3)$$

$$\text{VAR}\left[y_t/\mathfrak{F}_{t-1}\right] = E\left[h_t\eta_t^2/\mathfrak{F}_{t-1}\right] = E\left[h_t/\mathfrak{F}_{t-1}\right] \quad (4.4)$$

Observa-se que para o cálculo da variância condicional da série modelada é necessário calcular o valor esperado condicional de h_t . Como $h_t^{1/2}$ é a volatilidade diária de y_t , podemos tratar h_t como a variância realizada da série.

Para modelar e estimar a volatilidade realizada, Scharth, M. e Medeiros, M. (2006) propuseram um modelo STAR-Tree com a forma

$$\log(h_t^{1/2}) = H_{\mathbb{J}\mathbb{T}}(x_t, w_t; \psi) + \xi_t = \alpha'w_t + \sum_{i \in \mathbb{T}} \beta'_i \tilde{z}_t B_{\mathbb{J}i}(x_t; \theta_i) + \xi_t \quad (4.5)$$

onde $\log(h_t^{1/2})$ é o logaritmo da volatilidade realizada diária, $w_t \in \mathbb{R}^d$ é um vetor de regressores lineares, tal que $w_t \not\subseteq x_t$, e $\xi_t \sim \text{NID}(0, \sigma_\xi^2)$. O resto dos parâmetros segue as definições da Seção (3.2) e as funções $B_{\mathbb{J}i}$ são definidas pelas equações (3.4) e (3.5). A partir da equação (4.5), obtém-se

$$h_t^{1/2} = \exp(H_{\mathbb{J}\mathbb{T}}(x_t, w_t; \psi) + \xi_t) \quad (4.6)$$

Assim, temos a equação para a modelagem da variância realizada:

$$h_t = \exp(2H_{\mathbb{J}\mathbb{T}}(x_t, w_t; \psi) + 2\xi_t) = e^{2H_{\mathbb{J}\mathbb{T}}(x_t, w_t; \psi)} e^{2\xi_t} \quad (4.7)$$

Sabendo que

$$2\xi_t \sim \text{NID}(0, 4\sigma_\xi^2),$$

e utilizando o valor esperado da distribuição log normal temos que,

$$E[e^{2\xi_t}] = e^{2\sigma_\xi^2}, \quad (4.8)$$

logo,

$$E\left[h_t/\mathfrak{F}_{t-1}\right] = e^{2H_{\mathbb{J}\mathbb{T}}(\mathfrak{F}_{t-1})} e^{2\sigma_\xi^2} = e^{2H_{\mathbb{J}\mathbb{T}}(\mathfrak{F}_{t-1}) + 2\sigma_\xi^2}, \quad (4.9)$$

Substituindo a equação (4.9) na equação (4.4), chegamos à expressão da variância condicional de y_t :

$$\text{VAR} \left[y_t / \mathfrak{F}_{t-1} \right] = e^{2H_{\mathbb{J}\mathbb{T}}(\mathfrak{F}_{t-1})} e^{2\sigma_{\xi}^2} \quad (4.10)$$

Nota-se que a variância condicional de y_t não é constante, o que era o nosso objetivo inicial, para desta forma, propor uma metodologia para modelar séries com heterocedasticidade.

Com a disponibilidade de dados de volatilidade realizada diária em séries financeiras, utilizamos o artifício de dividir a equação (4.2) pela volatilidade realizada $h_t^{1/2}$ dos dois lados da igualdade, obtendo

$$\frac{y_t}{h_t^{1/2}} = \frac{H_{\mathbb{J}\mathbb{T}}(\mathbf{x}_t; \psi)}{h_t^{1/2}} + \frac{\varepsilon_t}{h_t^{1/2}} = \sum_{i \in \mathbb{T}} \beta'_i \frac{\tilde{z}_t}{h_t^{1/2}} B_{\mathbb{J}i}(\mathbf{x}_t; \theta_i) + \frac{\varepsilon_t}{h_t^{1/2}}, \quad (4.11)$$

Pode-se escrever a equação (4.11) da seguinte forma:

$$y_t^* = H_{\mathbb{J}\mathbb{T}}^*(\mathbf{x}_t; \psi) + \eta_t = \sum_{i \in \mathbb{T}} \beta'_i \tilde{z}_t^* B_{\mathbb{J}i}(\mathbf{x}_t; \theta_i) + \eta_t \quad (4.12)$$

Desta maneira, temos um modelo homocedástico para a série y_t^* , pois $\eta_t \sim \text{NID}(0,1)$, e para ajustá-lo, podemos aplicar a metodologia do STAR-Tree apresentada no Capítulo (3), que tinha como hipótese para os testes estatísticos e estimação dos parâmetros, a variância constante dos resíduos.

Ao estimar y_t^* , obtemos

$$\hat{y}_t^* = H_{\mathbb{J}\mathbb{T}}^*(\mathbf{x}_t; \hat{\psi}) = \sum_{i \in \mathbb{T}} \hat{\beta}'_i \tilde{z}_t^* B_{\mathbb{J}i}(\mathbf{x}_t; \hat{\theta}_i) \quad (4.13)$$

Se multiplicarmos os dois lados da equação (4.13) por $h_t^{1/2}$, temos

$$\hat{y}_t = H_{\mathbb{J}\mathbb{T}}(\mathbf{x}_t; \hat{\psi}) = \sum_{i \in \mathbb{T}} \hat{\beta}'_i \tilde{z}_t B_{\mathbb{J}i}(\mathbf{x}_t; \hat{\theta}_i)$$

Ou seja, depois de estimado o modelo da equação (4.13), basta aplicar a estimativa dos parâmetros, estimados utilizando o artifício descrito, nos dados originais, para obter a estimativa da série y_t original.

De maneira genérica, é possível definir um modelo STAR-Tree bi-variado para a média e a variância de uma variável dependente y_t , da seguinte forma:

$$\begin{pmatrix} y_t \\ h_t \end{pmatrix} = \begin{pmatrix} H_{\mathbb{J}\mathbb{T}}(\mathbf{x}_{yt}, \mathbf{w}_{yt}; \psi_y) \\ H_{\mathbb{J}\mathbb{T}}(\mathbf{x}_{ht}, \mathbf{w}_{ht}; \psi_h) \end{pmatrix} + \begin{pmatrix} \varepsilon_t \\ \xi_t \end{pmatrix} \quad (4.14)$$