

VALOR EM RISCO

1. Introdução

- Interesse: calcular uma medida de um tipo particular de risco, o chamado risco de mercado. Tal medida é o VaR (valor em risco). O cálculo do VaR envolve o cálculo da volatilidade de um ativo financeiro ou de uma carteira de instrumentos financeiros.
- Abordagens: (i) RiskMetrics : EWMA + Normalidade
(ii) Econométrica: ARMA+GARCH
(iii) Quantis empíricos
(iv) Teoria dos Valores Extremos (TVE)
- VaR: medida de risco financeiro de mercado e que dá uma medida do grau de incerteza sobre retornos líquidos futuros.

2. Valor em Risco

- VaR: medida da variação potencial máxima do valor de um ativo (ou carteira de ativos), sobre um período pré-fixado, com dada probabilidade. Ou seja, quanto se pode perder, com probabilidade p , sobre um horizonte h fixado.

Do ponto de vista de uma empresa, o VaR é uma medida de perda associada a um evento extremo, sob condições normais de mercado.

- **Exemplo 1:** Suponha que exista uma chance de 95% de que a taxa de câmbio Real/USD não caia mais do que 1% em um dia. Suponha, ainda, que uma empresa tenha 100 milhões de reais aplicados num fundo cambial. Calculemos a perda potencial sobre este valor aplicado.

Uma série temporal do desvio padrão (volatilidade) σ_t dos retornos r_t da taxa de câmbio Real/USD pode dar uma indicação da variação da taxa. Admita normalidade dos retornos. Suponha que uma estimativa do desvio padrão hoje seja $\sigma_t = 0,46\%$. Então o VaR é calculado como

$$\text{VaR} = (1,65)(\sigma_t) = (1,65)(0,46) = 0,759\%.$$

Portanto, não se espera que a taxa de câmbio caia mais do que 0,759%, com 95% de probabilidade. O valor 1,65 é o (0,05)-quantil da $\mathcal{N}(0,1)$. Em reais, o VaR é o valor de mercado da posição multiplicado pelo valor obtido acima, ou seja,

$$\text{Risco} = 100 \text{ milhões} \times 0,759\% = 759.000,00 \text{ reais.}$$

A conclusão é que em 95% das vezes, não se perderá mais do que R\$ 759.000,00 em um dia.

- Uma posição financeira *comprada* (ou “long”) significa possuir determinado ativo (ou carteira de ativos). Uma posição financeira *vendida* (ou “short”) envolve vender um ativo que não se possui. Esta operação é realizada alugando-se o ativo. Em data futura, o vendedor é obrigado a comprar exatamente o mesmo número de cotas ou ações alugadas (e não o valor em moeda), para pagar o débito. Como o pagamento é em cotas ou ações, o vendedor ganha com a queda do preço do ativo.
- Suponha que no instante t estejamos interessados em calcular o risco de uma posição financeira para o horizonte $h > 0$. Seja

$$\Delta P(h) = P(t + h) - P(t)$$

a variação do valor do ativo entre os dois instantes. A quantidade $\Delta P(h)$ representa o lucro ou a perda (L & P) da posição sobre o horizonte h . Do ponto de vista prático, é o L & P obtido marcando-se a posição a mercado hoje e deixando-a sem mudanças até uma nova marcação h dias depois, digamos. Chamemos de $F_h(\cdot)$ a função de distribuição acumulada (f.d.a.) de $\Delta P(h)$.

- **Definição:** Definimos o VaR de uma posição comprada sobre o horizonte h , com probabilidade p , $0 < p < 1$, por meio de

$$p = P(\Delta P(h) \leq \text{VaR}) = F_h(\text{VaR}). \quad (1)$$

Observemos que o VaR depende de p e de h , ou seja, deveríamos escrever $\text{VaR}_{p,h}$. Além disso, o valor em risco

aumenta com p diminuindo ou com h aumentando.

- (i) O VaR é dado em unidades monetárias (u.m.), por exemplo, reais. Lembremos que os retornos simples, R_t , são dados em porcentagem e que os log-retornos r_t são aproximadamente iguais a R_t , logo podemos supor que os r_t medem, aproximadamente, variações percentuais. Assim sendo, usaremos log-retornos no que segue.
- (ii) A definição mostra que o VaR é o p -quantil da distribuição $F_h(\cdot)$. Na prática, teremos que estimar este quantil, usando por exemplo a distribuição empírica dos retornos.
- (iii) O VaR tem valor negativo, pois quem tem uma posição comprada sofre uma perda se $\Delta P(h) < 0$.

- (iv) A quantia em u.m. no cálculo do VaR é obtida como no exemplo ou seja, multiplicando o valor da posição financeira pelo VaR do log-retorno. A posição financeira em u.m. é usualmente o valor do ativo marcado pelo mercado (“mark-to-market”).
- No caso de uma posição vendida, há perda se $\Delta P(h) > 0$, ou seja, o preço do ativo aumenta. Neste caso o VaR é definido por

$$p = P(\Delta P(h) \geq \text{VaR}) = 1 - F_h(\text{VaR}), \quad (2)$$

que tipicamente é positivo para p pequeno. O sinal positivo aqui indica perda. As definições (1) e (2) implicam que o VaR é calculado usando a cauda esquerda da distribuição $F_h(\cdot)$, para uma

posição comprada e usando a cauda direita, para uma posição vendida. Também, a definição (6.1) aplica-se a uma posição vendida se usarmos a distribuição de $-\Delta P(h)$. Portanto, basta considerar o cálculo do VaR para uma dessas posições.

3. VaR **Usando a Distribuição Normal**

- RiskMetrics: suposição é que a distribuição condicional dos retornos, dada a informação passada, é normal com média zero e variância σ_t^2 , ou seja,

$$r_t | \mathcal{F}_{t-1} \sim \mathcal{N}(0, \sigma_t^2).$$

Além disso, para estimar a volatilidade σ_t^2 é usado o modelo EWMA (“exponentially weighted moving average”)

$$\sigma_t^2 = \lambda \sigma_{t-1}^2 + (1 - \lambda) r_{t-1}^2, \quad 0 < \lambda < 1. \quad (3)$$

- Maneira equivalente: abordagem de modelos GARCH, notando-se que (3) pode ser pensado como um modelo IGARCH(1,1).
O log-retorno de k períodos, $r_t[k]$, do instante $t + 1$ ao instante $t + k$, é dado por

$$r_t[k] = r_{t+1} + r_{t+2} + \dots + r_{t+k},$$

de modo que podemos escrever que

$$r_t[k] | \mathcal{F}_t \sim \mathcal{N}(0, \sigma_t^2[k]),$$

onde $\sigma_t^2[k]$, a volatilidade deste retorno, pode ser calculada usando resultados da modelagem GARCH.

•

$$\begin{aligned}\log P_t - \log P_{t-1} &= r_t = a_t, \\ a_t &= \sigma_t \varepsilon_t \sim \text{IGARCH}(1, 1), \\ \varepsilon_t &\sim \mathcal{N}(0, 1),\end{aligned}$$

segue-se que

$$\begin{aligned}\sigma_t^2[k] &= \text{Var}(r_t[k] | \mathcal{F}_t) = \text{Var}\left(\sum_{i=1}^k r_{t+i} | \mathcal{F}_t\right) = \\ &= \sum_{i=1}^k \text{Var}(a_{t+i} | \mathcal{F}_t),\end{aligned}$$

dado que os a_t são não-correlacionados. Como $a_{t-1} = r_{t-1} = \sigma_{t-1} \varepsilon_{t-1}$, obtemos de (3)

$$\sigma_t^2 = \lambda \sigma_{t-1}^2 + (1 - \lambda) \sigma_{t-1}^2 \varepsilon_{t-1}^2,$$

ou ainda,

$$\sigma_t^2 = \sigma_{t-1}^2 + (1 - \lambda)\sigma_{t-1}^2(\varepsilon_{t-1}^2 - 1).$$

Segue-se que

$$\sigma_{t+i}^2 = \sigma_{t+i-1}^2 + (1 - \lambda)\sigma_{t+i-1}^2(\varepsilon_{t+i-1}^2 - 1),$$

$$i = 2, \dots, k.$$

Como $E(\varepsilon_{t+i-1}^2 - 1) = 0$, $i \geq 2$, obtemos

$$E(\sigma_{t+i}^2 | \mathcal{F}_t) = E(\sigma_{t+i-1}^2 | \mathcal{F}_t), \quad i = 2, \dots, k. \quad (4)$$

Para previsão a um passo da volatilidade, de (3) obtemos

$$\sigma_{t+1}^2 = \lambda\sigma_t^2 + (1 - \lambda)r_t^2,$$

e (4) mostra que

$$\text{Var}(r_{t+i}|\mathcal{F}_t) = \sigma_{t+1}^2, \quad i = 2, \dots, k,$$

ou seja,

$$\sigma_t^2[k] = k\sigma_{t+1}^2. \quad (5)$$

- Podemos escrever que

$$r_t[k]|\mathcal{F}_t \sim \mathcal{N}(0, k\sigma_{t+1}^2).$$

Portanto, sob o modelo adotado (3), a variância condicional dos log-retornos de k períodos é proporcional ao horizonte k e o desvio padrão condicional de $r_t[k]$ é dado por $\sqrt{k}\sigma_{t+1}$, expressão esta usualmente chamada “regra da raiz quadrada do tempo”.

- Por exemplo, se fixarmos em (1) a probabilidade $p = 5\%$, então o RiskMetrics usa $-1,65\sigma_{t+1}$ como VaR, que é o

0,05-quantil da normal com média zero e variância σ_t^2 . Normalmente o sinal negativo, que significa perda, é ignorado e

$$\text{VaR} = (\text{Valor da posição}) \times (1,65) \times (\sigma_{t+1}).$$

Esta expressão corresponde ao VaR de um período (um dia, por exemplo). O VaR de k períodos é dado por

$$\text{VaR}[k] = (\text{Valor da posição}) \times (1,65) \times \sqrt{k} \times \sigma_{t+1}.$$

- **Exemplo 1:** (continuação)

$$\text{VaR} = (100 \text{ milhões}) \times (1,65) \times (0,46\%)$$

$$= 759.000,00,$$

ao passo que o VaR de 30 dias é dado por

$$\begin{aligned}\text{VaR}[30] &= (100 \text{ milhões}) \times (1,65) \times \sqrt{30} \times (0,46\%) \\ &= 4.157.214,00.\end{aligned}$$

- **Exemplo 2:** posição comprada de 10 milhões de reais em ações da Petrobrás e queremos calcular o VaR de 1 e 15 dias.

log-retornos diários da Petrobrás, com $T = 1498$ observações

$$\sigma_t^2 = 0,81\sigma_{t-1}^2 + 0,19r_{t-1}^2.$$

Dos dados obtemos $r_{1498} = 0,011124$ e do modelo ajustado obtemos $\hat{\sigma}_{1498}^2 =$

0,000235. Logo a estimativa da volatilidade 1 passo a frente é dada por $\hat{\sigma}_{1498}^2(1) = 0,000214$. Se $p = 0,05$, o quantil da distribuição é $-1,65\sqrt{0,000214} = -0,02413$. O sinal negativo indica perda e o VaR de um dia será

$$\text{VaR} = 10.000.000,00 \times 0,02413$$

$$= 241.300,00,$$

ao passo que o VaR de 15 dias será

$$\text{VaR}[15] = \sqrt{15} \times 241.300,00 = 934.550,00.$$

- média da série não for zero, o modelo fica

$$r_t = \mu + a_t, \quad a_t = \sigma_t \varepsilon_t,$$

$$\sigma_t^2 \sim \text{IGARCH}(1, 1), \quad \varepsilon_t \sim \mathcal{N}(0, 1).$$

Neste caso o p -quantil é dado por $\mu + z_p \sigma_{t+1}$, onde z_p é o p -quantil da normal padrão; se $p = 0,05$, então $z_p = -1,65$.

Para k períodos, o p -quantil é $k\mu + z_p \sqrt{k} \sigma_{t+1}$; se $p = 0,05$, este ficará $k\mu - 1,65 \sqrt{k} \sigma_{t+1} = \sqrt{k}(\sqrt{k}\mu - 1,65 \sigma_{t+1})$, que não é igual a $\sqrt{k} \text{VaR}$.

- Suponha que se tenha agora uma carteira com m posições financeiras e sejam r_{1t}, \dots, r_{mt} os respectivos retornos.

$$\rho_{ij} = \text{Corr}(r_{it}, r_{jt}) = \frac{\gamma_{ij,t}}{\sigma_{ii,t} \sigma_{jj,t}},$$

para $i < j = 1, \dots, m$: correlações entre os retornos.

Então as covariâncias $\gamma_{ij,t}$ são estimadas usando, no lugar de (3), o modelo

$$\gamma_{ij,t} = \lambda\gamma_{ij,t-1} + (1 - \lambda)r_{i,t-1}r_{j,t-1}. \quad (6)$$

Desta maneira é fácil ver que o VaR da carteira é dado por

$$\text{VaR} = \sqrt{\sum_{i=1}^m \text{VaR}_i^2 + 2 \sum_{i < j} \rho_{ij} \text{VaR}_i \text{VaR}_j}, \quad (7)$$

onde VaR_i é o valor em risco para o retorno r_{it} . O S+FinMetrics calcula as correlações por meio da função EWMA.

- **Exemplo 3:** carteira com dois ativos, sendo uma posição de 10 milhões de reais em ações da Petrobrás e outra de 5 milhões de reais em ações do Banespa.

exemplo anterior: $VaR_1 = -0,02413$;

VaR para a segunda posição : suponha que $\lambda = 0,85$.

Obtemos $\hat{\sigma}_{2,1498}(1) = 0,000315$;

$VaR_2 = -1,65\sqrt{0,000315} = -0,02929$.

Em reais, este VaR é de

$5.000.000,00 \times 0,2929 = 146.450,00$.

A seguir, usaremos (7) para estimar a covariância prevista no instante $t = 1498$.

Usando $\lambda = 0,90$ para a carteira, temos que

$$\hat{\gamma}_{12,1498}(1) = 0,90\gamma_{12,1498} + 0,10r_{1,1498}r_{2,1498},$$

$$r_{1,1498} = 0,011124, r_{2,1498} = -0,00982,$$

$$\gamma_{12,1498} = 0,0000706.$$

Obtemos, então,

$$\hat{\gamma}_{12,1498}(1) = 0,000052616.$$

Segue-se que a correlação ρ_{12} entre os dois ativos é estimada por

$$\begin{aligned}\hat{\rho}_{12,1498}(1) &= (0,000052616)/(0,0146 \times 0,0177) \\ &= 0,175.\end{aligned}$$

Logo, o VaR de um dia da carteira é, usando (7),

$$\text{VaR} = 0,04108.$$

4. VaR Usando Modelos ARIMA e GARCH

- Estratégia: modelar a média da série de retornos r_t por meio de um modelo ARMA e depois modelar os resíduos a_t deste modelo por um membro da família ARCH. Por exemplo, se escolhermos um modelo GARCH(r,s) para usar, teremos o modelo ARMA(p,q)-GARCH(r,s):

$$r_t = \phi_0 + \sum_{i=1}^p \phi_i r_{t-i} + a_t - \sum_{j=1}^q \theta_j a_{t-j}, \quad (8)$$

$$a_t = \sigma_t \varepsilon_t, \quad (9)$$

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^r \alpha_i a_{t-i}^2 + \sum_{j=1}^s \beta_j \sigma_{t-j}^2. \quad (10)$$

- ε_t : normal, t ou distribuição de erro generalizada.

(i) $\varepsilon_t \sim \mathcal{N}(0, 1) \rightarrow$

$$r_{t+1} | \mathcal{F}_t \sim \mathcal{N}(\hat{r}_t(1), \hat{\sigma}_t^2(1)),$$

onde $\hat{r}_t(1)$ e $\hat{\sigma}_t^2(1)$ são as previsões a um passo da média e variância usando (9) e (11), respectivamente.

Supondo-se, por exemplo, $p = 0,05$,

$$\text{VaR} = \hat{r}_t(1) - 1,65\hat{\sigma}_t(1). \quad (11)$$

(ii) $\varepsilon_t \sim t_\nu$, o p -quantil é dado por $\hat{r}_t(1) - t_\nu^*(p)\hat{\sigma}_t(1)$, onde $t_\nu^*(p)$ é o p -quantil da distribuição t_ν padronizada.

Chamando de $Q(p)$ o p -quantil de t_ν , então temos

$$\begin{aligned} p &= P(t_\nu \leq Q(p)) = \\ &= P\left(\frac{t_\nu}{\sqrt{\nu/(\nu-2)}} \leq \frac{Q(p)}{\sqrt{\nu/(\nu-2)}}\right) = \\ &= P(t_\nu^* \leq Q^*(p)), \quad \nu > 2, \end{aligned}$$

ou seja, $Q^*(p)$ é p -quantil da distribuição t_ν padronizada. Logo,

$$\text{VaR} = \hat{r}_t(1) - \frac{t_\nu(p)\hat{\sigma}_t(1)}{\sqrt{\nu/(\nu-2)}}. \quad (12)$$

- **Exemplo 2:** (continuação) Modelo adequado: AR(1) – GARCH(1,1) gaussiano, que estimado usando o S+FinMetrics resulta ser

$$r_t = 0,00223 + 0,12394r_{t-1} + a_t, \quad a_t = \sigma_t \varepsilon_t,$$

$$\varepsilon_t \sim \mathcal{N}(0, 1),$$

$$\sigma_t^2 = 0,00003 + 0,1432a_{t-1}^2 + 0,8318\sigma_{t-1}^2.$$

Dos dados: $r_{1498} = 0,011124$, $r_{1497} = -0,006689$,

de modo que a previsão da série um passo à frente é dada por

$$\hat{r}_{1498}(1) = 0,00223 + 0,12394r_{1498} = 0,003609.$$

A previsão da volatilidade um passo à frente é

$$\hat{\sigma}_{1498}^2(1) = 0,00003 + 0,1432a_{1498}^2 + 0,8318\sigma_{1498}^2.$$

Agora,

$$a_{1498} = r_{1498} - 0,00223 - 0,12394r_{1497} = 0,009723,$$

$$\sigma_{1498}^2 = 0,000459 \text{ (modelo GARCH ajustado),}$$

de modo que

$$\hat{\sigma}_{1498}^2(1) = 0,00003 - (0,1432)(0,009723)^2 +$$

$$+(0,8318)(0,000459) = 0,000402.$$

○ 0,05-quantil será, então,

$$\hat{r}_{1498}(1) - 1,65\hat{\sigma}_{1498}(1)$$

$$= 0,003609 - 1,65(0,02004) = -0,0295.$$

Finalmente, o valor em risco de um dia é dado por

$$\text{VaR} = 10.000.000,00 \times 0,0295$$

$$= 295.0000,00.$$

- Para se obter o VaR de k períodos, temos que obter $r_t[k]$ como antes. Estando na origem T ,

$$r_T[k] = r_{T+1} + \dots + r_{T+k},$$

e usando (9) e (11) podemos obter a média e variância condicionais de $r_T[k]$ dada a informação \mathcal{F}_T até o instante T .

- **Proposição 1.** (a) A previsão da média do retorno r_t no período k é dada por

$$\hat{r}_T[k] = \hat{r}_T(1) + \dots + \hat{r}_T(k), \quad (13)$$

onde $\hat{r}_T(h)$ é a previsão de origem T e horizonte h usando (6.9).

- (b) O erro de previsão é dado por

$$e_T[k] = a_{T+k} + (1 + \psi_1)a_{T+k-1} + \dots + \left(\sum_{i=0}^{k-1} \psi_i\right)a_{T+1}, \quad (14)$$

onde os ψ_i são os pesos da representação do processo como uma média móvel infinita.

- (c) A previsão da volatilidade do retorno no período k é dada por

$$\begin{aligned} \text{Var}(e_T[k]|\mathcal{F}_T) &= \hat{\sigma}_T^2(k) + (1 + \psi_1)^2 \hat{\sigma}_T^2(k-1) + \dots + \\ &+ \left(\sum_{i=0}^{k-1} \psi_i \right)^2 \hat{\sigma}_T^2(1). \end{aligned} \quad (15)$$

onde $\hat{\sigma}_T^2(h)$ é a previsão h passos a frente da volatilidade usando (11).

- **Exemplo 2:** (continuação). Calculemos o VaR de 5 dias para o exemplo anterior. Para um modelo AR(1)

$$r_t = \phi_0 + \phi_1 r_{t-1} + a_t,$$

sabemos que $\psi_j = \phi_1^j$, $j \geq 1$. A previsão de origem T e horizonte h é dada por

$$\hat{r}_T(h) = \phi_0 + \phi_1 \hat{r}_T(h-1),$$

sendo que para $h = 1$, $\hat{r}_T(0) = r_T$. É fácil ver que obtemos $\hat{r}_{1498}(5) = 0,002546$. Lembremos que estas previsões convergem para $E(r_t) = 0,00255$, quando $h \rightarrow \infty$.

Por outro lado, para o modelo GARCH(1,1) temos que

$$\hat{\sigma}_T^2(h) = \alpha_0 + (\alpha_1 + \beta_1)\hat{\sigma}_T^2(h-1), \quad h \geq 2,$$

sendo que para $h = 1$ a previsão é $\alpha_0 + \alpha_1 a_T^2 + \beta_1 \sigma_T^2$. Usando os valores obtidos antes podemos calcular as previsões da volatilidade para $h = 1, 2, \dots, 5$. Finalmente, usando (15) obtemos a previsão da volatilidade do retorno de 5 dias, ou seja,

$$\sigma_T^2[5] = \hat{\sigma}_T^2(5) + \dots + (1 + \psi_1 + \dots + \psi_4)^2 \hat{\sigma}_T^2(1),$$

cujo valor resulta $\sigma_T^2[5] = 0,0028415$. O valor em risco de 5 dias é, então, com $p = 0,05$,

$$\begin{aligned} \text{VaR}[5] &= 0,002546 - 1,65\sqrt{0,0028415} \\ &= -0,08541. \end{aligned}$$

Em u.m. obtemos o valor R\$854.100,00.

5. VaR Usando Quantis Empíricos

- r_1, \dots, r_T : retornos observados

$r_{(1)} \leq r_{(2)} \leq \dots \leq r_{(T)}$: estatísticas de ordem

$Q(p)$: p -quantil da distribuição (desconhecida) dos retornos

estimador consistente: p -quantil empírico, definido por

$$q_p = \begin{cases} r_{(i)}, & \text{se } p = p_i = (i - 0,5)/T, \\ (1 - f_i)r_{(i)} + f_i r_{(i+1)}, & \text{se } p_i < p < p_{i+1} \\ r_{(1)}, & \text{se } p < p_1 \\ r_{(T)}, & \text{se } p > p_T, \end{cases} \quad (15)$$

onde $f_i = (p - p_i)/(p_{i+1} - p_i)$.

Uma suposição aqui adotada é que a distribuição dos retornos continue válida para o período de previsão, o que pode não ser razoável.

- **Exemplo 4:** Considere os mesmos dados do exemplo 2 e calculemos o VaR de um dia usando os quantis empíricos. Por (16) temos

$p_{74} = 0,0490654$, $p_{75} = 0,0500667$ e $f_{74} = 0,93$ de onde

$$q(0,05) = (0,07)r_{(74)} + (0,93)r_{(75)} = -0,4816.$$

Segue-se que o valor em risco de um dia da posição é $\text{VaR} = 481.600,00$ reais.

6. VaR Usando Valores Extremos

- Obtidas as estatísticas de ordem $r_{(1)} \leq \dots \leq r_{(T)}$, vamos nos fixar em:

$$r_{(1)} = \min\{r_1, \dots, r_T\},$$

$$r_{(T)} = \max\{r_1, \dots, r_T\}.$$

mínimo: relevante para posições compradas

máximo: relevante para posições vendidas.

Basta considerar um dos casos, devido ao fato que $r_{(1)} = -\max\{s_1, \dots, s_T\}$, onde $s_t = -r_t$, $t = 1, \dots, T$.

- A teoria de valores extremos (TVE) clássica estuda o comportamento de máximos, mínimos e outras estatísticas de ordem, para seqüências de variáveis aleatórias independentes e identicamente distribuídas (i.i.d.). Extensões para o caso de séries estacionárias com dependência fraca e séries não-estacionárias foram consideradas na literatura. Veja Coles (2001)

para detalhes. Mesmo que a série seja dependente, considerando-se os máximos de blocos, como veremos a seguir, a suposição de que estes máximos sejam independentes parece ser razoável na prática.

- A TVE procura obter a distribuição limite (aproximada) para o máximo normalizado

$$r_T^* = \frac{r_{(T)} - b_T}{a_T}, \quad (16)$$

para seqüências de constantes $\{a_T > 0\}$ e $\{b_T\}$, que são escolhidas de modo a estabilizar a posição e escala do máximo, quando $T \rightarrow \infty$.

- supondo-se os retornos independentes com distribuição F , se existirem seqüências como acima tais que a distribuição de

(6.18) converge para a distribuição não-degenerada $G(z)$, então G pertence a uma de três famílias, que podem ser conjuntamente colocadas na forma

$$G(z) = \exp\left\{-\left[1 + \xi\left(\frac{z - \mu}{\sigma}\right)\right]^{-1/\xi}\right\}, \quad (17)$$

definida sobre $\{z : 1 + \xi(z - \mu)/\sigma > 0\}$, para $-\infty < \mu < \infty$, $-\infty < \xi < \infty$, $\sigma > 0$.

- A família (17) é chamada *distribuição generalizada de valores extremos (GVE)*, sendo μ o *parâmetro de posição*, σ o *parâmetro de escala* e ξ o *parâmetro de forma*. Como visto no apêndice, esta família é determinada pelo parâmetro ξ , de modo que se $\xi = 0$ obtemos a família tipo I de Gumbel, se $\xi > 0$ obtemos a família tipo II de Fréchet e se $\xi < 0$ a família tipo III de Weibull.

- Para aplicar a TVE a séries de retornos, procedemos como segue:
 - (a) dividimos a série observada de retornos r_1, \dots, r_T em m blocos de tamanho n ;
 - (b) obtemos o máximo de cada bloco, $r_{n,i}, i = 1, \dots, m$, aos quais a TVE pode ser aplicada, ou seja, ajustamos uma distribuição GVE a esses máximos;
 - (c) estimamos os quantis desta distribuição, a partir do qual podemos obter o VaR de uma posição vendida. Note-se que

$$r_{n,i} = \max_{1 \leq j \leq n} \{r_{(i-1)n+j}\}, \quad i = 1, \dots, m. \quad (18)$$

- A coleção de máximos (18) pode ser usada para estimar os parâmetros do modelo GVE. Usualmente os blocos são escolhidos de modo a corresponder a um

ano de observações, se tivermos por exemplo dados mensais. No caso de retornos diários, os valores usados são $n = 21$ (um mês), $n = 63$ (um trimestre) e $n = 252$ (um ano). Podemos obter os EMV, supondo

$$z_{n,i} = \frac{r_{n,i} - b_n}{a_n}. \quad (19)$$

Estimadores dos quantis da distribuição dos máximos de grupos são obtidos invertendo-se a equação (17). Se $0 < p^* < 1$, o $(1 - p^*)$ -quantil é dado por

$$z_{p^*} = \begin{cases} \mu - \frac{\sigma}{\xi} [1 - \{-\log(1 - p^*)\}^{-\xi}], & \text{se } \xi \neq 0 \\ \mu - \sigma \log[-\log(1 - p^*)], & \text{se } \xi = 0, \end{cases} \quad (20)$$

com $G(z_{p^*}) = 1 - p^*$. Este quantil é, às vezes, chamado de *nível de retorno*, associado ao *período de retorno* $1/p^*$.

- Para obter o VaR da série de retornos original r_t temos que relacionar quantis desta série com os quantis da série dos máximos. Temos

$$p^* = P(r_{n,i} \geq z_{p^*}) = 1 - P(r_{n,i} \leq z_{p^*}) = 1 - [P(r_t \leq z_{p^*})]^n,$$

do que segue

$$1 - p^* = [1 - P(r_t \geq z_{p^*})]^n. \quad (21)$$

Para a série original de retornos, r_t , fixado p , o $(1 - p)$ -ésimo quantil de r_t é z_{p^*} se a probabilidade p^* for escolhida de (21) com $p = P(r_t \geq z_{p^*})$, logo devemos ter

$$1 - p^* = (1 - p)^n.$$

- VaR de uma posição vendida:

$$\text{VaR} = \begin{cases} \mu_n - \frac{\sigma_n}{\xi_n} \{1 - [-n \log(1 - p)]^{-\xi_n}\}, & \text{se } \xi_n \neq 0 \\ \mu_n - \sigma_n \log[-n \log(1 - p)], & \text{se } \xi_n = 0 \end{cases} \quad (22)$$

Para posições compradas vale um raciocínio análogo, trabalhando com $r_{(1)}$ e a definição (1).

- Resumindo, o procedimento para calcular o VaR no caso de uma posição financeira vendida, usando a TVE, é:
 - (a) Selecione n e obtenha os máximos dos blocos, $\{r_{n,i}\}$.
 - (b) Obtenha os EMV de μ, σ, ξ , para o valor fixado de n .
 - (c) Se o modelo ajustado for adequado, use (22) para calcular o VaR.

- **Exemplo 5.** Considere a situação em que um fundo mantém uma posição vendida de 10 milhões de reais em ações do Banespa. Consideremos os $T = 1470$ últimos log-retornos, deprezando-se os primeiros 28 dados, para podermos obter $m = 70$ blocos de $n = 21$ dias, ou seja, estamos usando máximos mensais. Aos 70 máximos de blocos assim obtidos ajustamos uma distribuição GVE. Utilizamos aqui o software desenvolvido por Coles (2001), que pode ser obtido do site do autor. Os estimadores obtidos são:

$$\hat{\mu} = 0,0671(0,00489), \hat{\sigma} = 0,0357(0,00394) \\ \text{e } \hat{\xi} = 0,2242(0,10543),$$

onde colocamos entre parênteses os respectivos desvios padrões. O valor da log-verossimilhança resultante é $-113,9054$, que poderia ser usado para comparar diversos ajustes, por exemplo, para $n = 63$.

A função gev do S+FinMetrics/EVIS também pode ser utilizada e aplicada neste caso produz os mesmos resultados. Substituindo estes valores em (22), com $p = 0,05$ obtemos

$$\begin{aligned} \text{VaR} &= 0,0671 - \frac{0,0357}{0,2242} \{1 - [-21 \log(0,95)]^{-0,2242}\} \\ &= 0,0645. \end{aligned}$$

Segue-se que o VaR de um dia da posição é de $(10\text{milhões}) \times 0,0645 = 645.000,00$.