

Case II: F is unknown \Rightarrow Bootstrapping!

The empirical distribution function of X_i , $1 \leq i \leq n$, is given as

$$F_n(x) = \frac{1}{n} \sum_{i=1}^n I_{[x_i, \infty)}(x).$$

For n large $F_n \approx F$ holds.

Generate samples from F_n by choosing n elements in $\{x_1, x_2, \dots, x_n\}$ and putting every element back to the set immediately after its choice

Assume N such samples are generated: $x_1^{*(i)}, x_2^{*(i)}, \dots, x_n^{*(i)}$, $1 \leq i \leq N$.

Compute $\theta_i^* = \hat{\theta}(x_1^{*(i)}, x_2^{*(i)}, \dots, x_n^{*(i)})$.

The empirical distribution of θ_i^* is given as $F_N^{\theta^*}(x) = \frac{1}{N} \sum_{i=1}^N I_{[\theta_i^*, \infty)}(x)$;

it approximates the distribution function $F^{\hat{\theta}}$ of $\hat{\theta}(X_1, X_2, \dots, X_n)$ for $N \rightarrow \infty$.

A confidence interval (a, b) with confidence level p is given by

$$a = q_{(1-p)/2}(F_N^{\theta^*}), \quad b = q_{(1+p)/2}(F_N^{\theta^*}).$$

Thus $a = \theta_{[N(1+p)/2]+1, N}^*$, $b = \theta_{[N(1-p)/2]+1, N}^*$,

where $\theta_{1, N}^* \geq \theta_{2, N}^* \geq \dots \theta_{N, N}^*$ is obtained by sorting $\theta_1^*, \theta_2^*, \dots, \theta_N^*$.

Summary of the non-parametric bootstrapping approach to compute confidence intervals

Input: Sample x_1, x_2, \dots, x_n of the i.i.d. random variables X_1, X_2, \dots, X_n with distribution function F and an estimator $\hat{\theta}(x_1, x_2, \dots, x_n)$ of an unknown parameter $\theta(F)$, A confidence level $p \in (0, 1)$.

Output: A confidence interval I_p for θ with confidence level p .

- Generate N new Samples $x_1^{*(i)}, x_2^{*(i)}, \dots, x_n^{*(i)}$, $1 \leq i \leq N$, by choosing elements in $\{x_1, x_2, \dots, x_n\}$ and putting them back right after the choice.
- Compute $\theta_i^* = \hat{\theta}(x_1^{*(i)}, x_2^{*(i)}, \dots, x_n^{*(i)})$.
- Setz $I_p := \left(\theta_{[N(1+p)/2]+1, N}^*, \theta_{[N(1-p)/2]+1, N}^* \right)$, where $\theta_{1, N}^* \geq \theta_{2, N}^* \geq \dots \theta_{N, N}^*$ is obtained by sorting $\theta_1^*, \theta_2^*, \dots, \theta_N^*$.

An approximative solution without bootstrapping

Input: A sample x_1, x_2, \dots, x_n of the random variables X_i , $1 \leq i \leq n$, i.i.d. with unknown continuous distribution function F , a confidence level $p \in (0, 1)$

Output: A small $p' \in (0, 1)$, $p' \geq p$, and a confidence interval (a, b) for $q_\alpha(F)$, i.e. $a = a(x_1, x_2, \dots, x_n)$, $b = b(x_1, x_2, \dots, x_n)$, such that

$P(a < q_\alpha(F) < b) = p'$ and $P(a \geq q_\alpha(F)) = P(b \leq q_\alpha(F)) = (1-p)/2$ holds.

Determine $i > j$, $i, j \in \{1, 2, \dots, n\}$, and the smallest $p' > p$, such that

$$P(x_{i,n} < q_\alpha(F) < x_{j,n}) = p' \quad (*) \quad \text{and}$$

$$P(x_{i,n} \geq q_\alpha(F)) \leq (1-p)/2 \quad \text{and} \quad P(x_{j,n} \leq q_\alpha(F)) \leq (1-p)/2 (**),$$

where $x_{1,n} \geq x_{2,n} \geq \dots \geq x_{n,n}$ is obtained from x_1, x_2, \dots, x_n by sorting.

Let $Y_\alpha := \#\{x_k : x_k > q_\alpha(F)\}$

We get $P(x_{j,n} \leq q_\alpha(F)) \approx P(x_{j,n} < q_\alpha(F)) = P(Y_\alpha \leq j - 1)$

$P(x_{i,n} \geq q_\alpha(F)) \approx P(x_{i,n} > q_\alpha(F)) = 1 - P(Y_\alpha \leq i - 1)$

$Y_\alpha \sim \text{Bin}(n, 1 - \alpha)$ since $\text{Prob}(x_k \geq q_\alpha(F)) \approx 1 - \alpha$ for a sample point x_k .

Compute $P(x_{j,n} \leq q_\alpha(F))$ and $P(x_{i,n} \geq q_\alpha(F))$ for different i and j as long as $i, j \in \{1, 2, \dots, n\}$, $i > j$, which fulfill (*) and (**) are found.

Historische Simulation

Seien x_{m-n+1}, \dots, x_m historische Beobachtungen der Veränderungen der Risikofaktoren X_{m-n+1}, \dots, X_m .

Annahme: Die historischen Verluste sind i.i.d.

Die historischen Verlustwerte $l_k = l_{[m]}(x_{m-k+1})$, $k = 1, 2, \dots, n$, stellen eine Stichprobe der Verlustverteilung dar.

Empirischer VaR: $\widehat{VaR} = q_\alpha(\widehat{F}_n^L) = l_{[n(1-\alpha)]+1, n}$

Empirischer CVaR: $\widehat{CVaR} = \frac{\sum_{i=1}^{[n(1-\alpha)]+1} l_{i, n}}{[n(1-\alpha)]+1}$,

wobei $l_{1, n} \geq l_{2, n} \geq \dots \geq l_{n, n}$ durch die Sortierung von l_i , $1 \leq i \leq n$, entsteht.

VaR und CVaR des aggregierten Verlustes über mehrere Tage, zB. 10 Tage, kann mit Hilfe der Verlustwerte

$$l_k^{(10)} = l_{[m]} \left(\sum_{j=1}^{10} x_{m-n+10(k-1)+j} \right) \quad k = 1, \dots, [n/10]$$

geschätzt werden.

Historische Simulation - Folgerung

Vorteile:

- einfache Implementierung
- berücksichtigt die Abhängigkeitsstruktur zwischen den Komponenten des Vektors der Veränderungen der Risikofaktoren $X_{m-k} = (X_{m-k,1}, \dots, X_{m-k,d})$.

Nachteile:

- sehr viele historische Daten notwendig um zuverlässige Schätzer zu bekommen
- Schätzung impliziert, dass der geschätzte Verlust nicht größer als bereits historisch realisierte Verluste sein kann.

Varianz-Kovarianz Methode

Grundidee: Verwendung der linearisierten Verlustfunktion.

$$L_{m+1}^\Delta = l_m^\Delta(X_{m+1}) = -V \sum_{i=1}^d w_i X_{m+1,i} = -V w^T X_{m+1}$$

wobei $V := V_m$, $w_i := w_{m,i}$, $w = (w_1, \dots, w_d)^T$,
 $X_{m+1} = (X_{m+1,1}, X_{m+1,2}, \dots, X_{m+1,d})^T$.

Annahme: $X_{m+1} \sim N_d(\mu, \Sigma)$

Daraus folgt: $-V w^T X_{m+1} \sim N(-V w^T \mu, V^2 w^T \Sigma w)$

Seien x_{m-n+1}, \dots, x_m historische Beobachtung der Veränderungen der Risikofaktoren.

Annahme: x_{m-n+1}, \dots, x_m sind i.i.d.

Schätzer für μ_i : $\hat{\mu}_i = \frac{1}{n} \sum_{k=1}^n x_{m-k+1,i}$, $i = 1, 2, \dots, d$

Schätzer $\hat{\Sigma} = (\hat{\sigma}_{ij})$ für $\Sigma = (\sigma_{ij})$:

$$\hat{\sigma}_{ij} = \frac{1}{n-1} \sum_{k=1}^n (x_{m-k+1,i} - \mu_i)(x_{m-k+1,j} - \mu_j) \quad i, j = 1, 2, \dots, d$$

Schätzer für VaR: $\widehat{VaR}(L_{m+1}) = -V w^T \hat{\mu} + V \sqrt{w^T \hat{\Sigma} w} \phi^{-1}(\alpha)$ (siehe Bsp. (8)) .

Varianz-Kovarianz Methode - Folgerung

Vorteile:

- analytische Lösung
- einfache Implementierung
- keine Simulationen notwendig

Nachteile:

- Linearisierung nicht immer adäquat, nur für einen kurzen Zeithorizont gerechtfertigt (siehe Übung (2)).
- Annahme der Normalverteilung könnte zur Unterschätzung des Risikos führen und sollte begründet werden (zB. anhand von historischen Daten).

Monte-Carlo Verfahren

- (1) Historische Beobachtungen der Veränderungen der Risikofaktoren X_{m-n+1}, \dots, X_m .
- (2) Annahme über ein parametrisches Modell für die Verteilungsfunktion der X_k , $m - n + 1 \leq k \leq m$;
zB. gemeinsame Verteilungsfunktion F und Unabhängigkeit.
- (3) Schätzung der Parameter von F .
- (4) Erzeugung von N Stichproben $\tilde{x}_1, \tilde{x}_2, \dots, \tilde{x}_N$ aus F ($N \gg 1$).
Berechnung der Verlustwerte $l_k = l_{[m]}(\tilde{x}_k)$, $1 \leq k \leq N$
- (5) Ermittlung der empirischen Verteilungsfunktion der Verlustfunktion L_{m+1} :

$$\hat{F}_N^{L_{m+1}}(x) = \frac{1}{N} \sum_{k=1}^N I_{[l_k, \infty)}(x).$$

- (5) Ermittlung der Schätzer für VaR und CVAR der Verlustfunktion:

$$\widehat{VaR}(L_{m+1}) = q_\alpha(\hat{F}_N^{L_{m+1}}) = l_{[N(1-\alpha)]+1, N}$$

$$\widehat{CVaR}(L_{m+1}) = \frac{\sum_{k=1}^{[N(1-\alpha)]+1} l_{k,N}}{[N(1-\alpha)] + 1}$$

wobei die Verlustwerte sortiert werden:

$$l_{1,N} \geq l_{2,N} \geq \dots \geq l_{N,N}.$$

Monte-Carlo Verfahren - Folgerung

Vorteile:

- Sehr flexibel; für F kann jedes Modell verwendet werden, aus dem simuliert werden kann
- Berücksichtigung von zeitlichen Abhängigkeiten zwischen den Veränderungen der Risikofaktoren möglich etwa durch Verwendung von Zeitreihen

Nachteile:

- Rechenintensiv; große Anzahl von Simulationen notwendig um gute Schätzwerte zu bekommen.

Monte-Carlo Verfahren - Folgerung

Example 11 *PF besteht aus einem Stück der Aktie S mit Preis $= S_t$ zum Zeitpunkt t . Die Veränderungen der Risikofaktoren*

$$X_{k+1} = \ln(S_{t_{k+1}}) - \ln(S_{t_k}),$$

sind i.i.d. mit Verteilungsfunktion F_θ , wobei θ ein unbekannter Parameter ist.

θ kann mit Hilfe von historischen Daten geschätzt werden (zB. ML Verfahren)

Sei der heutige Preis $S_{t_k} = S$

Wir zeigen: VaR des PF über $[t_k, t_{k+1}]$ ist folgendermaßen gegeben

$$VaR_\alpha(L_{t_{k+1}}) = S(1 - \exp\{F_\theta^{\leftarrow}(1 - \alpha)\}).$$

Wenn F_θ kompliziert, dann kann die analytische Berechnung von CVaR schwierig sein. Alternative: Monte-Carlo Simulation.

Monte-Carlo Verfahren - Folgerung

Example 12 Sei das PF und die Veränderungen der Risikofaktoren X_{k+1} wie im obigen Beispiel.

Ein populäres Modell für die log. Rendite einer Aktie: GARCH(1,1)
(siehe zB. Alexander 2002):

$$X_{k+1} = \sigma_{k+1} Z_{k+1} \quad (1)$$

$$\sigma_{k+1}^2 = a_0 + a_1 X_k^2 + b_1 \sigma_k^2 \quad (2)$$

wobei $Z_k, k \in \mathbb{N}$, sind i.i.d. und standard normalverteilt a_0, a_1 und b_1 sind Parameter, die geschätzt werden.

Es ist einfach aus diesem Modell zu simulieren.

Analytische Berechnung der VaR bzw. CVaR für ein Zeitintervall bestehend aus mehreren Perioden sind hingegen schwierig!
Ausprobieren!

3. Kapitel: Extremwerttheorie

Notation:

- Wir verwenden oft dieselbe Notation für die Verteilung einer ZV und ihre Verteilungsfunktion!
- $f(x) \sim g(x)$ für $x \rightarrow \infty$ bedeutet $\lim_{x \rightarrow \infty} f(x)/g(x) = 1$
- $\bar{F} := 1 - F$ (*rechter Rand* “*right Tail*” einer univariaten Verteilungsfunktion F).

Bezeichnungskonvention: Man sagt eine ZV X hat “fat Tails” oder ist “heavy tailed” (h.t.) wenn $\lim_{x \rightarrow \infty} \frac{\bar{F}(x)}{e^{-\lambda x}} = \infty, \forall \lambda > 0$.

Auch eine ZV X für die $\exists k \in \mathbb{N}$, sodass $E(X^k) = \infty$, wird oft *heavy tailed* genannt.

Reguläre Variation

Definition 9 Eine messbare Funktion $h: (0, +\infty) \rightarrow (0, +\infty)$ besitzt eine reguläre Variation mit Index $\rho \in \mathbb{R}$ um $+\infty$ wenn

$$\lim_{t \rightarrow +\infty} \frac{h(tx)}{h(t)} = x^\rho, \quad \forall x > 0 \quad (3)$$

Bezeichnung: $h \in RV_\rho$.

Wenn $\rho = 0$, dann heißt es h variiert langsam um ∞ .

Wenn $h \in RV_\rho$ dann $h(x)/x^\rho \in RV_0$.

Falls $h \in RV_\rho$, dann $\exists L \in RV_0$ sodass $h(x) = L(x)x^\rho$ ($L(x) = h(x)/x^\rho$).

Falls $\rho < 0$, dann ist die Konvergenz in (3) gleichmäßig in jedem Intervall $(b, +\infty)$ für $b > 0$.

Example 13 Zeigen Sie, dass für die untenstehenden Funktionen L , $L \in RV_0$ gilt.

(a) $\lim_{x \rightarrow +\infty} L(x) = c \in (0, +\infty)$

(b) $L(x) = \ln(1 + x)$

(c) $L(x) = \ln(1 + \ln(1 + x))$

Example 14 Gilt es $f \in RV_0$ für $f(x) = 3 + \sin x$, $f(x) = \ln(e + x) + \sin x$?

Eine Funktion $L \in RV_0$ kann unendlich stark variieren um $+\infty$:

$$\liminf_{x \rightarrow \infty} L(x) = 0 \text{ and } \limsup_{x \rightarrow \infty} L(x) = \infty$$

Ein Beispiel dafür ist $L(x) = \exp\{(\ln(1 + x))^2 \cos((\ln(1 + x))^{1/2})\}$.

Definition 10 Sei $X > 0$ eine ZV mit Verteilungsfunktion F . Man sagt X besitzt eine reguläre Variation um $+\infty$, wenn $\bar{F} \in RV_{-\alpha}$ für ein $\alpha > 0$.

Example 15 Pareto Verteilung: Sei $F(x) = 1 - x^{-\alpha}$, für $x > 1$ und $\alpha > 0$. Dann gilt $\bar{F}(tx)/\bar{F}(x) = x^{-\alpha}$ für $t > 0$. D.h. $\bar{F} \in RV_{-\alpha}$.

Example 16 Fréchet-Verteilung: Sei $F(x) = \exp\{-x^{-\alpha}\}$ für $x > 0$ und $F(0) = 0$, $\alpha > 0$. Es gilt $\lim_{x \rightarrow \infty} \bar{F}(x)/x^{-\alpha} = 1$. Daraus folgt $\bar{F} \in RV_{-\alpha}$.

Proposition 1 (ohne Beweis)

Sei $X > 0$ eine ZV mit Verteilungsfnk. F , sodass $\bar{F} \in RV_{-\alpha}$ für ein $\alpha > 0$. Es gilt dann $E(X^\beta) < \infty$ für $\beta < \alpha$ und $E(X^\beta) = \infty$ für $\beta > \alpha$.

Die Umkehrung gilt nicht!

Example 17 Seien X_1 und X_2 zwei nichtnegative i.i.d. ZV mit Verteilungsfunktion $F, \bar{F} \in RV_{-\alpha}$ für ein $\alpha > 0$.

Annahmen:

- X_1 (X_2) gibt den Verlust eines Portfolios bestehend aus 1 Stück der Aktie A_1 (A_2) an.
- Die Preise von A_1 und A_2 identisch und deren logarithmierten Rendite i.i.d. sind.

Ein Investor hat 2 Stück der Aktie A_1 gekauft. Kann der Investor die Verlustwahrscheinlichkeit verringern in dem er auf ein diversifiziertes Portfolio bestehend aus einem Stück der Aktie A_1 und einem Stück der Aktie A_2 wechselt?

Example 18 Seien $X, Y \geq 0$ zwei ZV, die die Verluste zweier Geschäftslinien einer Versicherungsgesellschaft darstellen (zB. Brand- bzw. Autoversicherung).

Annahmen:

- $\bar{F} \in RV_{-\alpha}$, für ein $\alpha > 0$, wobei F Verteilungsfunktion von X ist.
- $E(Y^k) < \infty, \forall k > 0$.

Die Versicherungsgesellschaft möchte $\lim_{x \rightarrow \infty} P(X > x | X + Y > x)$ ermitteln.