

Two correlated assets (risikobehaftet)

$$r = E(R) = \begin{pmatrix} r_1 \\ r_2 \end{pmatrix} \quad r_1 < r_2$$

$$\Sigma = \text{Cov}(R) = \begin{pmatrix} \sigma_1^2 & \rho \sigma_1 \sigma_2 \\ \rho \sigma_1 \sigma_2 & \sigma_2^2 \end{pmatrix}, \quad \rho$$

$$\sigma_1^2 = \text{Var}(R_1) \quad \sigma_1 \neq 0$$

$$\sigma_2^2 = \text{Var}(R_2) \quad \sigma_2 \neq 0$$

$$\rho = \text{Cor}(R_1, R_2), \quad -1 < \rho < 1$$

zur Erinnerung:

$$\text{Cor}(X, Y) = \frac{\text{Cov}(X, Y)}{\sqrt{\text{Var}(X)} \sqrt{\text{Var}(Y)}}$$

Pareto-Menge ist parametrisiert

durch

$$x(\mu) = \begin{pmatrix} \frac{r_2 - \mu}{r_1 - r_1} \\ \frac{\mu - r_1}{r_2 - r_1} \end{pmatrix}, \quad (\mu \geq c/b)$$

Varianz für gegebenes μ :

$$\sigma^2(\mu) = \theta^2 \sigma_1^2 + (1-\theta)^2 \sigma_2^2 + 2\theta(1-\theta)\sigma_1\sigma_2\rho$$


mit $\theta := \frac{r_2 - \mu}{r_2 - r_1}$

$\theta = 0 \rightsquigarrow$ alles in Anlage 1

$\theta = 1 \rightsquigarrow$ alles in Anlage 2

$\theta < 0 \rightsquigarrow$ Leerverkauf von Anlage 1

$\theta > 1 \rightsquigarrow$ Leerverkauf von Anlage 2



Fall 1 kein Leerverkäufe erlaubt,
also $0 \leq \theta \leq 1$

$$\begin{aligned} \sigma^2(\mu) = & \theta^2 \sigma_1^2 + (1-\theta)^2 \sigma_2^2 \\ & + 2\theta(1-\theta)\sigma_1\sigma_2\rho \end{aligned}$$

$$\frac{\partial}{\partial \rho} \sigma^2(\mu) = \begin{array}{ccccccc} 2\theta(1-\theta) & & \sigma_1 & \sigma_2 & & & \geq 0 \\ \uparrow & \uparrow & \uparrow & \uparrow & & & \\ \geq 0 & \geq 0 & > 0 & > 0 & & & \end{array}$$

↳ Varianz für gegebenes μ steigt
mit steigendem ρ !

↳ Wenn man sich die beiden Anlagen aussuchen kann, dann sollte man Anlagen präferieren, die anti korrelieren ($\rho < 0$).

Tatsächlich:

$$\begin{aligned} \sigma^2(\mu) &\xrightarrow{s \rightarrow -1} \theta^2 \sigma_1^2 + (1-\theta)^2 \sigma_2^2 \\ &\quad + 2\theta(1-\theta)\sigma_1\sigma_2(-1) \\ &= [\dots] = (\theta\sigma_1 - (1-\theta)\sigma_2)^2 \end{aligned}$$

Das kann = 0 werden, falls

$$\theta = \frac{\sigma_2}{\sigma_1 + \sigma_2}.$$

Fall 2: Leerhäufe zugelassen,
dann ist $\theta < 0$ oder
 $\theta > 1$ zugelassen!

Falls $\theta < 0$

$$\frac{\partial}{\partial s} \sigma^2(\mu) = \underbrace{2\theta}_{<0} \underbrace{(1-\theta)}_{>0} \underbrace{\sigma_1}_{>0} \underbrace{\sigma_2}_{>0} < 0.$$

Falls $\theta > 1$

$$\frac{\partial}{\partial s} \sigma^2(\mu) = \underbrace{2\theta}_{>0} \underbrace{(1-\theta)}_{<0} \underbrace{\sigma_1}_{>0} \underbrace{\sigma_2}_{>0} < 0.$$

Das Risiko ist also geringer
je höher die Korrelation ist!

Ist komisch, ist aber so...

Erklärung:

Bei Leerverkauf ist entweder $x_1 < 0$
oder $x_2 < 0$. Sagen $x_1 < 0$.
Was man dann bei Anlage 2 an
Verlust macht wird bei hoher
Korrelation in Anlage 1 wieder
wett gemacht.

In der Tat

$$\begin{aligned} \sigma^2(\mu) &\xrightarrow{\theta \rightarrow 1} \theta^2 \sigma_1^2 + (1-\theta)^2 \sigma_2^2 \\ &\quad + 2\theta(1-\theta)\sigma_1\sigma_2(+1) \\ &= (\theta\sigma_1 + (1-\theta)\sigma_2)^2 \end{aligned}$$

das wird $= 0$ für $\theta = \frac{\sigma_2}{\sigma_2 - \sigma_1}$

Viele korrelierte Anlagen

Zur Vereinfachung: n Anlagen mit

$$r = E(R) = \underline{1} \in \mathbb{R}^n,$$

$$\Sigma = \text{Cov}(R) = \begin{pmatrix} \sigma^2 & \rho\sigma^2 & \dots & \rho\sigma^2 \\ \rho\sigma^2 & \ddots & \ddots & \vdots \\ \vdots & \ddots & \ddots & \rho\sigma^2 \\ \rho\sigma^2 & \dots & \rho\sigma^2 & \sigma^2 \end{pmatrix},$$

$$\sigma > 0, \quad \rho \in]-1, 1[.$$

Wann ist Σ positiv-def. (\leadsto Einschränkung an σ und ρ)? Eigenwert:

$$\lambda_1 = (1 + (n-1)\rho) \sigma^2$$

$$\lambda_2, \dots, \lambda_n = (1 - \rho) \sigma^2,$$

Dafür Σ positiv definit ist, müssen alle Eigenwerte positiv sein,

$$\leadsto -\frac{1}{n-1} < \rho < 1$$

$$\Sigma^{-1} = \frac{1}{\sigma^2 (1-\rho)(1+(n-1)\rho)} \cdot A$$

$$A = \begin{pmatrix} 1+(n-2)\rho & -\rho & \dots & \dots & -\rho \\ -\rho & \ddots & \ddots & \ddots & \vdots \\ \vdots & \ddots & \ddots & \ddots & -\rho \\ -\rho & \dots & \dots & -\rho & 1+(n-2)\rho \end{pmatrix}$$

Haben ausgearbeiteten Fall: $\mathbb{1}$ und $r = \mathbb{1}$ sind linear abhängig. Da hatten wir gesehen, dass es genau ein optimales/effizientes Portfolio gibt, nämlich

$$x_{\text{opt}} = \frac{\Sigma^{-1} \cdot \mathbb{1}}{\mathbb{1}^T \Sigma^{-1} \mathbb{1}}$$

$\mathbb{1}^T \Sigma \mathbb{1}$ = Summe aller Beiträge

von Σ^{-1}

= Summe aller
Zeilen Summen von Σ^{-1}

$$= \frac{1}{\sigma^2 (1-\rho) (1+(n-1)\rho)} \cdot \text{Summe}$$

aller Zeilen Summen von A

$$= \frac{n \cancel{(1-\rho)} \quad 1-\rho}{\sigma^2 \cancel{(1-\rho)} (1+(n-1)\rho)}$$

Das was
das $c = \mathbb{1}^T \Sigma^{-1} \mathbb{1}$

Minimale Varianz

$$= \text{Var}(\beta^T \hat{x}_*) =$$

$$\frac{1}{c} = \frac{1}{\mathbb{1}^T \Sigma^{-1} \mathbb{1}}$$

$$= \{ \dots \} =$$

$$\frac{1+(n-1)\rho}{n} \cdot \sigma^2$$

Was passiert wenn die Korrelation

ρ gegen die kleinstmögliche
Korrelation geht? (D.h. wenn $\rho \rightarrow -\frac{1}{n-1}$)

$$\frac{1 + (n-1)\rho}{n} \cdot \sigma^2 \xrightarrow{\rho \rightarrow -\frac{1}{n-1}} \frac{1 + \cancel{(n-1)} \cdot \cancel{\left(-\frac{1}{n-1}\right)}}{n} \cdot \sigma^2$$

$$= \underline{\underline{0}}$$

Anderer Fall: alle Anlagen sind
komplett unkorreliert, d.h. $\rho = 0$

$$\text{Var}(R^{\text{Divers}}) \xrightarrow{\rho \rightarrow 0} = \frac{1 + \cancel{(n-1)\rho}}{n} \cdot \sigma^2 = \underline{\underline{\frac{1}{n} \sigma^2}}$$

4 Wie kommt man an die Zahlen ran?

Schätzung aus empirischen Daten

Annahmen: wir haben Tageschlusspreise
für Aktie i am Tag n : $S_i^{(n)}$

$S_i^{(0)}, S_i^{(1)}, \dots, S_i^{(N)}$

Für N Tage in der Vergangenheit
kennen wir diese Daten.

wollen Aussagen treffen über die
nächsten M Tage (weil wir z.B.
unser Portfolio für die nächsten Tage
optimieren wollen),

$M \approx 750 - 1000$ für 3-4 Jahre

N wird ungefähr in der gleichen
Größenordnung liegen.

Zukünftige Kurse

$$S_i^{(N+1)}, S_i^{(N+2)}, \dots, S_i^{(N+M)}$$

sind unbekannt,

$$\zeta_i^{(n)} := \frac{S_i^{(n)}}{S_i^{(n-1)}} \approx 1.$$

In der Börsen nachrichten liest man

$$100 (\zeta_i^{(n)} - 1) \%$$

$\zeta_i^{(n)}$ = realisierte relative Gewinn der Aktie i am Tag (n) .

Für den Zeitraum $N+1, \dots, N+M$ interessieren wir uns für

$$Q_i = \zeta_i^{(N+1)} \cdot \zeta_i^{(N+2)} \cdot \dots \cdot \zeta_i^{(N+M)}$$



Realisierung der Zufallsvariablen R_i .

Machen folgende Annahmen:

1.) $\xi_i^{(n)}$ ist Realisierung einer Zufallsvariablen $X_i^{(n)}: \Omega \rightarrow]0, \infty[$

2.) Für jede Anlage i sind die Zufallsvariablen $X_i^{(1)}, X_i^{(2)}, \dots, X_i^{(N)}, X_i^{(N+1)}, \dots, X_i^{(N+M)}$

identisch verteilt, d.h. es

gibt eine ZV $X_i: \Omega \rightarrow]0, \infty[$

s.d. $X_i^{(n)} \sim X_i$.

"Die Zukunft sieht in etwa so aus wie die Vergangenheit."

3.) Zufällige relative Gewinne an verschiedenen Tagen

sind unabhängig voneinander, d.h.,
 $X_i^{(n)}, X_j^{(m)}$ unabh. für $n \neq m$
und beliebige
 i und j .

(Das ist leider eine sehr, sehr
starke Annahme! Die brauchen
wir zum rechnen.)

Die Zufallsvariablen für unser
Portfoliooptimierungsproblem sind

$$R_i = \text{relative Gewinn im} \\ \text{Zeitraum von Tag } N+1 \\ \text{bis Tag } N+M \\ = X_i^{(N+1)} \cdot \dots \cdot X_i^{(N+M)}$$

Was wir schätzen wollen sind

$$E(R_i) = r_i \quad \text{und} \quad \text{Cov}(R_i, R_j) = \Sigma_{ij}$$

Wenn man zwei ~~unabh.~~ ZV U und V hat, dann gilt:

$$\begin{aligned} \text{Cov}(U, V) &= E((U - E(U))(V - E(V))) \\ &= E(U \cdot V) - E(U) \cdot E(V). \end{aligned}$$

D.h. wenn U und V unabh. sind gilt:

$$0 = E(U \cdot V) - E(U) \cdot E(V)$$

$$\leadsto E(U \cdot V) = E(U) \cdot E(V),$$

$$\leadsto E(R_i) = E\left(X_i^{(N+1)} \cdot X_i^{(N+2)} \cdot \dots \cdot X_i^{(N+M)}\right)$$

Ann. 3.

$$\begin{aligned} &\stackrel{\text{Ans. 3.}}{=} E\left(X_i^{(N+1)}\right) \cdot E\left(X_i^{(N+2)} \cdot \dots \cdot X_i^{(N+M)}\right) \\ &\stackrel{\text{Ans. 3.}}{=} E\left(X_i^{(N+1)}\right) \cdot \dots \cdot E\left(X_i^{(N+M)}\right) \end{aligned}$$

Ann. 2

$$\begin{aligned} &\rightarrow E(\tilde{X}_i) \cdot \dots \cdot E(\tilde{X}_i) \\ &= \left(E(\tilde{X}_i)\right)^M \end{aligned}$$

$E(\tilde{X}_i)$ würde man ja aus der
Vergangenheit $\{z_i^{(1)}, \dots, z_i^{(N)}\}$ schätzen!

$$E(\tilde{X}_i) \approx \bar{z}_i = \frac{1}{N} \sum_{n=1}^N z_i^{(n)}$$

Jetzt würde man auf diese
Idee kommen, das folgendes
ein guter Schätzer wäre für

$$E(R_i) = E(\tilde{X}_i)^\mu;$$

$$E(R_i) \approx \left(\frac{1}{N} \sum_{n=1}^N z_i^{(n)} \right)^\mu.$$

Das ist aber ein ganz schlechter
Schätzer!

Typischerweise gilt für absoluten Fehler:

$$\left| E(\tilde{X}_i) - \frac{1}{N} \sum_{n=1}^N z_i^{(n)} \right| \sim \frac{1}{\sqrt{N}}$$

Relativer Fehler:

$$\frac{|E(\tilde{x}_i) - \bar{z}_i|}{|E(\tilde{x}_i)|} =: \varepsilon \sim \frac{1}{\sqrt{N}}$$

Angenommen, wir überschätzen $E(\tilde{x}_i)$

$$\bar{z}_i = \underbrace{(1 + \varepsilon)}_{> 1} E(\tilde{x}_i)$$

rel. Fehler (\bar{z}_i^M für $E(R_i)$)

$$= \frac{|\bar{z}_i^M - E(R_i)|}{|E(R_i)|}$$

$$= \frac{|(1 + \varepsilon)^M \cancel{E(\tilde{x}_i)^M} - \cancel{E(\tilde{x}_i)^M}|}{|\cancel{E(\tilde{x}_i)^M}|}$$

$$= \frac{(1 + \varepsilon)^M - 1}{1} = (1 + \varepsilon)^M - 1.$$

Falls $\varepsilon = \frac{1}{\sqrt{N}}$.

rel. Fehler unseres Schätzer

$$= \left(1 + \frac{1}{\sqrt{N}}\right)^M = \left(1 + \frac{\sqrt{N}}{N}\right)^M - 1$$

Angenommen M und N sind
in etwa gleich groß, setzen

$$N = C \cdot M, \text{ mit } C > 0.$$

$$C \approx 1.$$

$$\left(1 + \frac{\sqrt{N}}{N}\right)^M = \left(1 + \frac{\sqrt{CM}}{C \cdot M}\right)^M$$

$$= \left(1 + \frac{\sqrt{M/C}}{M}\right)^M.$$

Analysis 1 / Mathe 1 für WiWi.

$$\left(1 + \frac{t}{n}\right)^n \xrightarrow{n \rightarrow \infty} e^t$$

$$\left(1 + \frac{\sqrt{M/d}}{n}\right)^M \sim e^{\sqrt{M/d}}$$

(Das kann man math. rigoros zeigen!)

Konkretes Beispiel: $M = 250$
 $\approx 1 \text{ Sek.}$

und $C = 5$.

$$\text{relativer Fehler: } \left(1 + \frac{1}{\sqrt{5 \cdot 250}}\right)^{250} - 1$$
$$\approx 1066,33.$$

Selbst wenn der relative Fehler

$$|E(\tilde{x}_i) - \bar{x}_i| \sim \frac{1}{n} \text{ wäre, dann}$$

habe noch immer so was wie $e^{1/d}$
heraus! Also möglicherweise mehr
als 100 %