

- akcii ... p_j ... máh. výnosnost za období

$$E p = \mu$$

$$\text{var } p = V$$

x_j ... váha investice do j -té akcie ... $\sum_{j=1}^n x_j = 1$

kladná váha: na začátku akcii koupím, na konci prodám.

záporná -1: -1 - prodám -1 - koupím.

- výnos portfolia s váhami x : $r(x) = \sum r_j \cdot x_j = r^T x = E(p^T x)$

riziko portfolia s váhami x : $\sigma^2(x) = \text{var}(p^T x) = x^T V x$

- náš cíl: najít portfolio x , tak, že $r(x) \rightarrow \max$ a $\sigma^2(x) \rightarrow \min$

⇒ EFFICIENTNÍ PORTFOLIO - Def:

Portfolio s váhami x^* je eficientní vzhledem ke střední hodnotě a rozptylu (mean-efficient - variance) jestliže neexistuje žádné jiné x takové, že $\sum x_j = 1$, pro které je výnos $r(x) \geq r(x^*)$ a $\sigma^2(x) \leq \sigma^2(x^*)$ a aspoň jedna z nerovností je ostrá. (žádné lepší portfolio)

- jak najít eficientní portfolio?

$$\max_{x \in X} \lambda r^T x - \frac{1}{2} x^T V x, \quad \text{zde } X = \{x : 1^T x = 1\}, \lambda \geq 0$$

↑ parametr
↑ není kompaktní (neomezená)

$\lambda \geq 0$: má výnos minimalizace rozptylu

• $\lambda = 0$: investora nezajímá výnos, pouze minimalizuje riziko

• $\lambda \rightarrow \infty$: investora nezajímá riziko, chce maximalizovat výnos

• problém s nastavením λ (leviční, kdo má jake)

• souhrnný přístup: # kritérií, dohromady

$\min_{x \in X} x^T V x$ - úloha kvadratického programování

za podmínek $1^T x \geq \mu$

• když s $\mu \rightarrow$ dostáváme různá eficientní portfolio (kdožná s přístupem 1)

- vyhoda: jasně nastavitelné μ
- pokud X kompaktní $\rightarrow \mu$ je z ~~intervalu~~ intervalu

$\max_{x \in X} w^T x$
 za podmínky: $x^T V x \leq w$

w ... daná mez (regulátor, EU, ...)

- řešení: $\min x^T V x$ kvadratická fce
 za podmínek: $\mathbb{1}^T x = 1$ lineární fce
 $w^T x \geq \mu$

• Lagrangova fce:

$L(x, \lambda_1, \lambda_2) = x^T V x + \lambda_1 (\mathbb{1}^T x - 1) + \lambda_2 (\mu - w^T x)$
Ducpocová, Hurc, 344 p. 9.2.6.

- předpoklady: žádné bezrizikové aktivum (pozadí) investujeme do ní \rightarrow rizikové
 \rightarrow w není stejný pro všechny akcie \rightarrow vybereme akcie s d varem a
- $\rightarrow V$ je regulární nedobře replikovat 1 akcii pomocí jiných akcií

• a) portfolio s minimálním rozptylem: $\min_{x \in X} x^T V x$

$\rightarrow L(x, \lambda) = x^T V x + \lambda (1 - \mathbb{1}^T x)$

$\partial L(x, \lambda) = 2Vx + \lambda \cdot \mathbb{1} = 0$

$\partial_x \quad \lambda \mathbb{1} = -2Vx$

$x = V^{-1} \cdot \lambda \cdot \mathbb{1}$

$\mathbb{1}^T x = 1$
 dosadit $\mathbb{1}^T V^{-1} \lambda \mathbb{1} = 1$ číslo

$\lambda = \frac{1}{\mathbb{1}^T V^{-1} \mathbb{1}} \Rightarrow x^* = \frac{V^{-1} \mathbb{1}}{\mathbb{1}^T V^{-1} \mathbb{1}}$

$\sigma^2(x^*) = x^{*T} V x^* = \frac{\mathbb{1}^T V^{-1} V V^{-1} \mathbb{1}}{(\mathbb{1}^T V^{-1} \mathbb{1})^2} = \frac{1}{(\mathbb{1}^T V^{-1} \mathbb{1})}$

$w(x^*) = w^T x^* = \frac{w^T V^{-1} \mathbb{1}}{\mathbb{1}^T V^{-1} \mathbb{1}}$

• b) zisk & celé číslo

$\partial L = 2Vx - \lambda_1 \cdot \mathbb{1} - \lambda_2 \cdot w = 0$

∂_x

$$x^* = \lambda_1 \cdot V^{-1} \cdot \mathbf{1} + \lambda_2 \cdot V^{-1} \cdot \mathbf{w}$$

• zavedeme značení: $A = \mathbf{1}^T V^{-1} \mathbf{1} > 0$

$$B = \mathbf{w}^T V^{-1} \mathbf{1}$$

$$C = \mathbf{w}^T V^{-1} \mathbf{w} > 0$$

$$\Delta = AC - B^2 > 0 \text{ (Schwarzova nerovnost)}$$

• $\mathbf{1}^T \lambda_1 V^{-1} \mathbf{1} + \mathbf{1}^T \lambda_2 V^{-1} \mathbf{w} = 1$ dosazení do $\mathbf{1}^T x = 1$

$$A \cdot \lambda_1 + B \lambda_2 = 1$$

$\mathbf{w}^T \lambda_1 V^{-1} \mathbf{1} + \mathbf{w}^T \lambda_2 V^{-1} \mathbf{w} = \mu$ dosazení do $\mathbf{w}^T x = \mu$ musí být rovnost
Lagrangeho
na hranici

$$B \cdot \lambda_1 + C \cdot \lambda_2 = \mu$$

$$\lambda_1 = \frac{C - \mu B}{\Delta} \quad \lambda_2 = \frac{\mu A - B}{\Delta}$$

1) když $B=0$: $\lambda_1 = \frac{C}{A} = \frac{C}{A} = \frac{1}{\mathbf{1}^T V^{-1} \mathbf{1}}$

$$\lambda_2 = \frac{\mu \cdot A}{A \cdot C} = \frac{\mu}{C} = \frac{\mu}{\mathbf{w}^T V^{-1} \mathbf{w}}$$

$$\Rightarrow x^* = \frac{V^{-1} \mathbf{1}}{\mathbf{1}^T V^{-1} \mathbf{1}} + \frac{V^{-1} \mathbf{w} \cdot \mu}{\mathbf{w}^T V^{-1} \mathbf{w}}$$

bezrizikové
s minimálním
rizikem

korekce čtení ● -

$$\mathbf{w}^T x^* = \frac{B}{A} + \mu \cdot \frac{C}{C} \quad B=0 \Rightarrow E\mathcal{R} = \mu$$

2) když $B \neq 0$: $x^* = \frac{C - \mu B}{\Delta} \cdot A \cdot \frac{V^{-1} \mathbf{1}}{\mathbf{1}^T V^{-1} \mathbf{1}} + \frac{\mu A - B}{\Delta} \cdot B \cdot \frac{V^{-1} \mathbf{w}}{\mathbf{w}^T V^{-1} \mathbf{w}}$

$\delta_1(\mu)$ $\delta_2(\mu)$


• $\delta_1(\mu) + \delta_2(\mu) = \frac{C - \mu B}{\Delta} \cdot A + \frac{\mu A - B}{\Delta} \cdot B = 1$

• Věta o dvou fondech^u

$$x^* = \delta_1(\mu) \cdot x_1^* + \delta_2(\mu) \cdot x_2^*$$

$$\begin{aligned} \cdot r(x^*) &= \frac{\sigma_1(\mu) \cdot B}{A} + \frac{\sigma_2(\mu) \cdot C}{B} - \frac{e \cdot \mu \cdot B}{A} \cdot \frac{A-B}{A} + \\ &+ \frac{\mu A - B}{A} \cdot \frac{B \cdot e}{B} = -\frac{\mu B^2 + \mu AC}{A} - \frac{\mu}{A} (AC - B^2 = A) \end{aligned}$$

$$\begin{aligned} \cdot G^2(x^*) &= x^* \cdot V x^* = (\lambda_1 V^{-1} \mathbb{1} + \lambda_2 V^{-1} \kappa)^T \cdot V \cdot (\lambda_1 V^{-1} \mathbb{1} + \lambda_2 V^{-1} \kappa) = \\ &= \lambda_1^2 \mathbb{1}^T V^{-1} \mathbb{1} + 2 \cdot \lambda_1 \lambda_2 \cdot V^{-1} \kappa + \lambda_2^2 \kappa^T V^{-1} \kappa = \lambda_1^2 A + 2 \cdot \lambda_1 \lambda_2 B + \lambda_2^2 C = \\ &= \lambda_1 (\lambda_1 A + \lambda_2 B) + \lambda_2 (\lambda_1 B + \lambda_2 C) = \lambda_1 + \lambda_2 \mu = \\ &= \frac{C - \mu B}{A} + \frac{\mu A - B}{A} \mu = \frac{1}{A} (A \mu^2 - 2B\mu + C) \end{aligned}$$



• eficientní portfolio $x^* = \delta_1 x^1 + \delta_2 x^2$

$$x^1 = \frac{V^{-1} \mathbb{1}}{\mathbb{1}^T V^{-1} \mathbb{1}} \text{ s minimálním rozptylem, } x^2 = \frac{V^{-1} \kappa}{\mathbb{1}^T V^{-1} \kappa}$$

x^2 je portfolio, které maximalizuje Sharpeho poměr:

$$\frac{\mu^2}{\sigma_p^2} = \frac{(\kappa^T x)^2}{x^T V x} \Rightarrow \max_{\mathbb{1}^T x = 1} \dots x^* = x^2$$

• Schwarzova nerovnost: $(\kappa^T x)^2 = (\kappa^T V^{-\frac{1}{2}} V^{\frac{1}{2}} x)^2 \leq (\kappa^T V^{-1} \kappa) \cdot (x^T V x)$

$$\Rightarrow x^* = \lambda V^{-1} \kappa \text{ \& } \mathbb{1}^T x^* = 1 \Rightarrow x^* = \frac{V^{-1} \kappa}{\mathbb{1}^T V^{-1} \kappa}$$