

Optimal Granularity for Portfolio Choice

Nicole Branger¹ Katarína Lučivjanská² Alex Weissensteiner³

¹University of Münster, Nemecko

²Univerzita P.J. Šafárika v Košiciach, Slovensko

³Free University of Bolzano, Taliansko

11. apríl 2017

seminár Aká si mi krásna

Úloha investora

- ▶ Statická úloha: klasická úloha hľadania vhodného rozloženia aktív (Markowitz, 1952; Tobin, 1958)
- ▶ Jedno bezrizikové aktívum a N rizikových aktív s nadmernými výnosmi $r_t \sim N(\mu, \Sigma)$, rovnako a nezávisle rozdelené
- ▶ Investor hľadá kombináciu aktív (portfólio), pri ktorej maximalizuje svoju úžitkovú funkciu $U(w)$

$$\max_w \left(w' \mu - \frac{\gamma}{2} w' \Sigma w \right) \quad (1)$$

- ▶ γ - parameter odporu k riziku
- ▶ $w' \mu$ - očakávaná výnosnosť portfólia
- ▶ $w' \Sigma w$ - rozptyl/variancia portfólia $S_0 S_u S_d$

Úloha investora so známymi parametrami

- ▶ Ak investor pozná parametre, potom sú optimálne váhy jednotlivých aktív dané

$$w^* = \frac{1}{\gamma} \Sigma^{-1} \mu \quad (2)$$

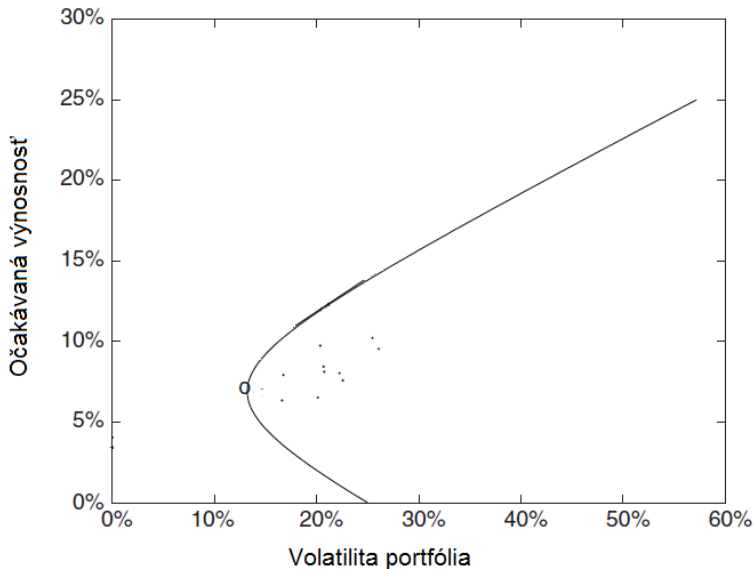
kde $1 - \mathbf{1}' w^*$ je časť investovaná do bezrizikového aktíva,

- ▶ s optimálnou očakávanou hodnotou úžitkovej funkcie

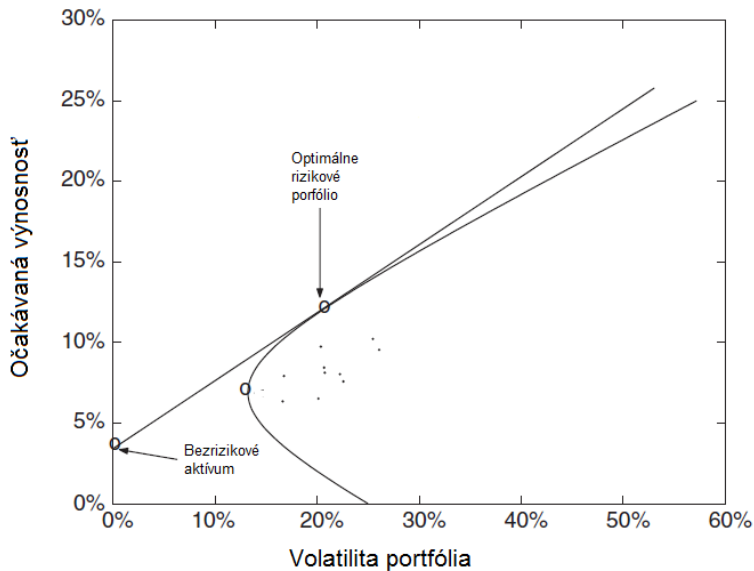
$$E[U(w^*)] = \frac{1}{2\gamma} \mu' \Sigma^{-1} \mu = \frac{\theta^2}{2\gamma} \quad (3)$$

kde θ je Sharpov pomer.

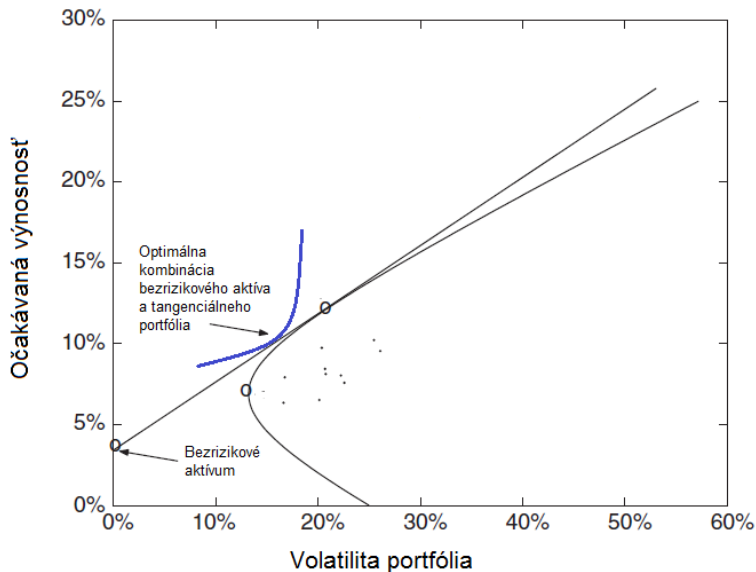
Úloha investora: Množina prípustných portfólií z rizikových aktív



Úloha investora: s bezrizikovým aktívom



Úloha investora: Optimálne portfólio



Neistota v parametroch

- ▶ Hlavnou nevýhodou mean-variance optimalizácie je **neistota v parametroch** modelu
- ▶ Nepoznáme skutočné, s odhadnutými parametrami modelu pracujeme akoby boli skutočné (Plug-in metóda)
- ▶ Priemerné výnosy aktív a ich variancie sú odhadnuté s nedostatočnou presnosťou
- ▶ V praxi: Ad hoc 1/N metóda, kde rizikovým aktívam priradíme rovnaké váhy dáva lepšie výsledky, hlavne pri úlohách s 10 a viac aktívami

Stopy a dôkazy

- ▶ Chopra a Ziemba (1993) - simulácie, straty z neznámych očakávaných výnosov sú 10krát ako vyššie ako z variancií a kovariancií
- ▶ Kan a Zhou (2007) - teoreticky odvodí vzorce pre straty spôsobené odhadovaním parametrov
- ▶ DeMiguel a kol. (2007) - tisíce mesačných dát potrebných na prekonanie $1/N$ pravidla

Navrhované riešenia

- ▶ Minimalizujeme iba rozptyl portfólia, ktorý nie je tak nepresne odhadnutý (Jaganathan a Ma, 2003)
- ▶ Zmršťovanie (shrinking) očakávaných výnosov a/alebo kovariančnej matice (Ledoit a Wolf, 2004; Garlappi a kol., 2007)
- ▶ Kombinácie viacerých pravidiel s nekorelovanou chybou odhadu (Kan a Zhou, 2007)
 - Kombinácia bezrizikového aktíva, tangenciálneho portfólia a portfólia s min. rozptylom (Kan a Zhou, 2007)
 - Kombinácia bezrizikového aktíva, tangenciálneho portfólia, portfólia s min. rozptylom a 1/N stratégie (Tu a Zhou, 2009)

Naše riešenie

- ▶ Kombinácia ad-hoc prístupu a *užitočnej* informácie z optimalizácie
- ▶ Nájďme optimálny počet aktív (optimálna granularita), pre ktoré sa oplatí optimalizovať
- ▶ Poskupinkujme podobné aktíva do optimálneho počtu skupín
- ▶ Menším počtom aktív znížime stratu z chýb vzniknutých pri odhadoch
- ▶ Zároveň si ponecháme výhody optimalizácie (s menším počtom aktív)
- ▶ Faktory vplývajúce na optimálnu granularitu

Program nadnes

1. Vlastnosti naší strategie pomocí simulací
2. Teoretické výsledky
3. Výsledky s reálnými datami

Úloha investora s neznámymi parametrami

- ▶ Ak je očakavaný výnos μ /alebo variancia Σ neznáma, môžeme ju odhadnúť, napr. maximalizáciou funkcie vierohodnosti

$$\hat{\mu} = \frac{1}{T} \sum_{t=1}^T r_t \quad (4)$$

$$\hat{\Sigma} = \frac{1}{T} \sum_{t=1}^T (r_t - \hat{\mu})'(r_t - \hat{\mu}) \quad (5)$$

- ▶ T je počet pozorovaní, ktoré použijeme na odhad
- ▶ Potom odhad na základe dát je z rozdelenia

$$\hat{\mu} \sim N(\mu, \Sigma/T) \quad (6)$$

$$\hat{\Sigma} \sim W_N(T-1, \Sigma)/T \quad (7)$$

Úloha investora s neznámymi parametrami

- ▶ Ak nepoznáme iba μ , vieme ľahko vypočítať ako sa zmení funkcia úžitku

$$\begin{aligned} E(U(\hat{w})) &= E(\hat{w})\mu - \frac{\gamma}{2} E(\hat{w}'\Sigma^{-1}\hat{w}) \\ &= \frac{1}{\gamma}\mu'\Sigma^{-1}\mu - \frac{1}{2\gamma} E(\hat{\mu}'\Sigma^{-1}\hat{\mu}) \\ &= \frac{1}{\gamma}\mu'\Sigma^{-1}\mu - \frac{1}{2\gamma} \left(\frac{N + T\mu'\Sigma^{-1}\mu}{T} \right) \\ &= \frac{\theta^2}{2\gamma} - \frac{N}{2\gamma T} \end{aligned}$$

obe neznáme

- ▶ Riziko spojené s odhadnutím parametrov spôsobí stratu na hodnote úžitkovej funkcie, ktorá
 - rastie s počtom aktív
 - klesá s počtom pozorovaní použitých na odhad
- ▶ Ak máme málo dát alebo príliš veľa aktív, 1/N pravidlo dáva lepšie výsledky ako optimalizácia

Simulácie

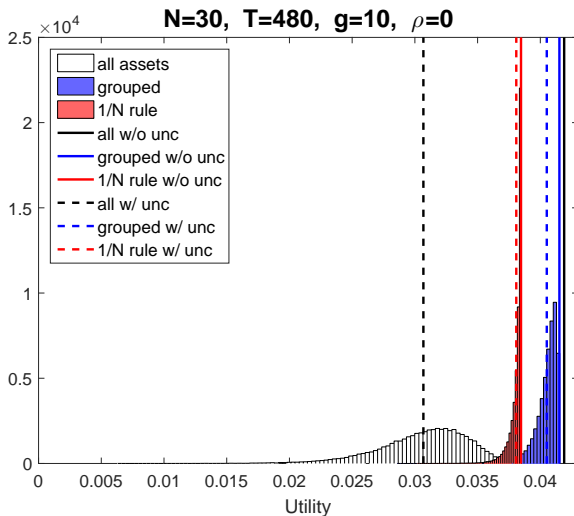
- ▶ 30 aktív, výnosností simulované z rovnomerného rozdelenia
- ▶ Očakávané výnosnosti aj variancie sú neznáme pre investora, odhaduje ich na základe 40 rokov mesačných dát (50000 simulácií)
- ▶ Zjednodušenie: všetky výnosnosti majú rovnaký rozptyl, sú nekorelované, očakávané výnosnosti su rovnomerne rozdelené v danom intervale
- ▶ Parametre sú zvolené tak, aby boli rovnaké ako parametre 30 Fama-French sektorovým portfóliám
- ▶ Hodnota úžitkovej funkcie pri odhade parametrov je

$$U(\hat{w}) = \hat{w}'\mu - \frac{\gamma}{2}\hat{w}'\Sigma\hat{w} \quad (8)$$

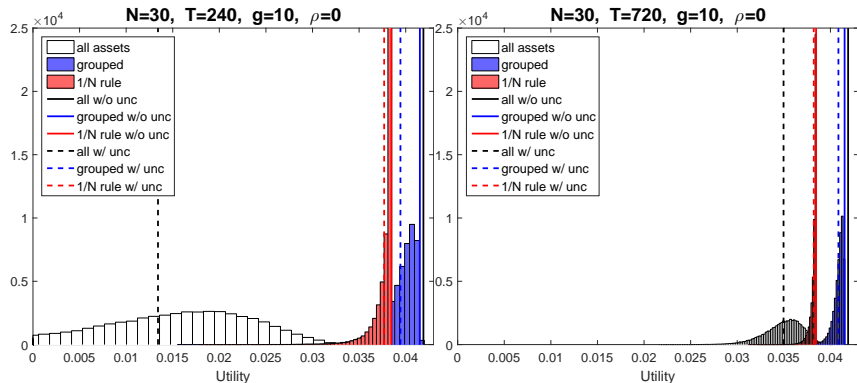
Stratégie

1. Optimalizačná úloha naprieč všetkými aktívami s použitím iba odhadnutých parametrov
2. Optimalizačná úloha naprieč poskupinkovaným aktívam s použitím iba odhadnutých parametrov (veľkosť skupiny $g = 10$, počet skupín $N/g = 3$)
3. jednoduché $1/N$ pravidlo pre rizikové aktíva

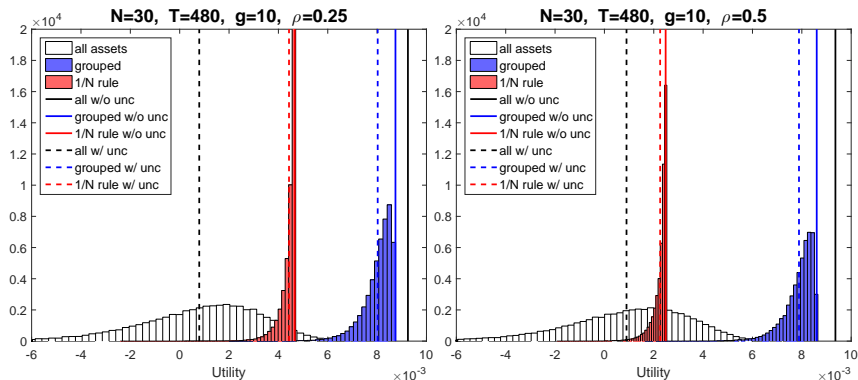
Úžitková funkcia pre stratégie



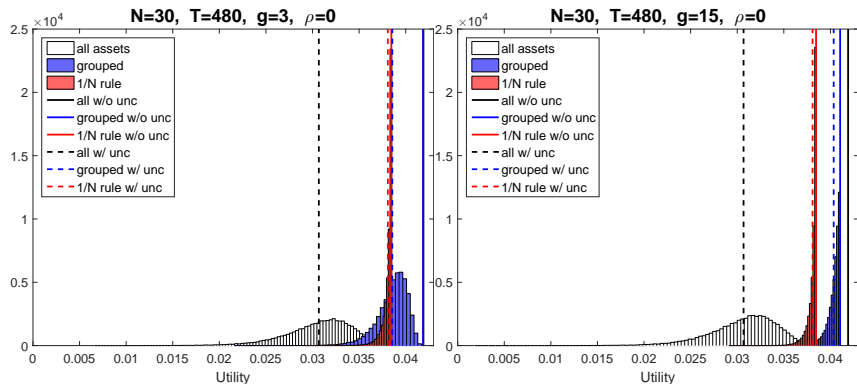
Citlivost' na počet skupin T



Citlivosť na korelačný koeficient ρ



Citlivost' na veľkosť skupiny g



Analytické výsledky o optimálnej granularite

- ▶ Zjednodušený model pre traktabilitu
- ▶ Zameranie na neznáme očakávané výnosnosti, rozptyl je známy (Chopra a Ziemba, 1993)
- ▶ Optimálne váhy sú založené na odhadnutých, nie skutočných parametroch
- ▶ Potom, očakávaná hodnota úžitku je

$$E[U(\hat{w})|\Sigma] = \frac{\mu' \Sigma^{-1} \mu}{2\gamma} - \underbrace{\frac{N}{2\gamma T}}_{\text{strata}} \quad (9)$$

Optimálna granularita

- ▶ Optimalizácia len cez redukovanú množinu (poskupinkovaných aktív): $N \rightarrow \bar{N} = N/g$
- ▶ Veľkosť skupiny g , rovnaké váhy vrámci skupiny
- ▶ Skupinkovanie prináša zlepšenie, ak


$$\frac{\theta^2}{2\gamma} - \frac{N}{2\gamma T} \leq \frac{\bar{\theta}^2}{2\gamma} - \frac{\bar{N}}{2\gamma T} \quad (10)$$

kde $\bar{\theta}^2 = \bar{\mu}'\bar{\Sigma}^{-1}\bar{\mu}$ je druhá mocnina Sharpovho pomeru pre poskupinkované dáta

- strata kvôli odhadu parametrov $N > \bar{N}$
- výhody z optimalizácie sú nižšie $\theta > \bar{\theta}$

Zjednodušený prípad 1

- ▶ Rovnaká variancia pre každé aktívum σ^2 (skalár)
- ▶ Nulový korelačný koeficient
- ▶ Rovnomerne rozložený očakávaný výnos, s rovnakým krokom s :
$$\mu_i = \mu + s(i - 1)$$
- ▶ Skupinkovanie: znížiť počet aktív zoskupením aktív s podobným výnosom



- ▶ Umocnený Sharpov pomer pri skupinkovaní





$$\bar{\theta}^2 = \frac{N}{\sigma^2} \left[\mu^2 + \mu s(N-1) + \frac{s^2}{12} \left(2(N-1)(2N-1) + 1 - g^2 \right) \right] \quad (11)$$

- ▶ Pôvodná množina aktív verus skupinkovanie

$$\underbrace{\theta^2 - \bar{\theta}^2}_{\text{Strata z menšej diverzifikácie pri skupinkovaní}} < \underbrace{\frac{N - \bar{N}}{T}}_{\text{Nárast užitočnosti vďaka menšej chybe odhadu}} \quad (12)$$

$$\frac{N}{\sigma^2} \frac{(g^2 - 1)s^2}{12} < \frac{N(1 - 1/g)}{T} \quad (13)$$



Zmeny v diverzifikácii a neistote odhadov



Kalibrácia: $\mu_{max} - \mu_{min} = 0.01/12$, $\sigma^2 = 0.04/12$, $\rho = 0$; Zmeny v diverzifikácii (čiarkovane) a neistote odhadov (plná čiara) v závislosti od počtu pozorovaní


Optimálna veľkosť skupiny

$$\frac{\partial E[U(\hat{w})|\Sigma]}{\partial g} = 0 \rightarrow g^* = \sqrt[3]{\frac{6\sigma^2}{s^2 T}} \quad (14)$$



Kalibrácia: $\mu_{max} - \mu_{min} = 0.01/12, \sigma^2 = 0.04/12, \rho = 0$

Optimálna veľkosť skupiny



Zjednodušený případ 2

- ▶ Rovná variace pro každé aktívum σ^2
- ▶ **Nové:** Rovná korelačný koeficient ρ pro každý pár aktív
- ▶ Rovnomerne rozložený očakávaný výnos, s rovnakým krokom s :
$$\mu_i = \mu + s(i - 1)$$

Zjednodušený prípad 2



- ▶ Rovnaká variancia pre každé aktívum σ^2
- ▶ **Nové:** Rovnaký korelačný koeficient ρ pre každý pár aktív
- ▶ Rovnomerne rozložený očakávaný výnos, s rovnakým krokom s :
 $\mu_i = \mu + s(i - 1)$
- ▶ Pôvodná množina aktív verzus skupinkovanie

$$\frac{N}{\sigma^2} \frac{(g^2 - 1)s^2}{12(1 - \rho)} < \frac{N(1 - 1/g)}{T} \quad (15)$$

- ▶ Optimálna veľkosť skupiniek

$$g^* = \sqrt[3]{\frac{6\sigma^2(1 - \rho)}{s^2 T}} \quad (16)$$

Nenulová párová korelácia: Optimálna veľkosť skupiny




Kalibrácia: $\mu_{max} - \mu_{min} = 0.01/12$, $\sigma^2 = 0.04/12$, $\gamma = 5$



Aplikácie s reálnymi dátami

- ▶ 30 Fama-French sektorových portfólií, mesačné dáta 1926M7-2013M7
- ▶ Hľadáme očakávaný úžitok pri roznych veľkostiach skupín
 - $g = 1$: celková optimalizácia,
 - $g = N$: 1/N pravidlo, a
 - ostatné možné veľkosti skupiniek g : skupinkovanie
- ▶ Aktíva zoskupené podľa biet z jednofaktorového modelu
- ▶ Porovnanie s teoreticky odvodenou hodnotou g

30 Fama-French sektorových portfólií



10 a 12 Fama-French sektorových portfólií



Délka T	5 rokov	10 rokov	25 rokov	50 rokov
30 FF sektorových portfólií	15	10	10	6
12 FF sektorových portfólií	6	6	4	4
10 FF sektorových portfólií	5	5	5	5

Analýza out-of-sample

- ▶ Každý mesiac investor vypočíta teoreticky optimálnu veľkosť skupín na základe dostupných dát
- ▶ Výkonnosť (očakávaný užitek a Sharpov pomer) stratégie vzhľadom na alternatívne stratégie
 - feature selection method by Bjerring et al. (2016)
 - trojfondové pravidlo rule od Kan a Zhou (2007)
 - štvorfondové pravidlo od Tu a Zhou (2011)
 - optimalizácia cez podpriestor faktorov od Chen a Yuan (2016)
 - optimalizácia s dodatočnými podmienkami od Li (2015)
 - 1/N pravidlo bez bezrizikového aktíva

Analýza out-of-sample: Výsledky

Panel A: 12 sektorových portfólií

	Full	Grouping	Naive	Bjerring	Kan	Tu	Chen	Li	Naive w/o
SR	0.1460	0.1853	0.1515	0.1361	0.1644	0.1774	0.1368	0.1638	0.1591
EU	0.0020	0.0032	0.0019	0.0018	0.0027	0.0031	0.0016	0.0024	0.0023

Panel B: 30 sektorových portfólií

SR	0.1340	0.1964	0.1443	0.1513	0.1731	0.1816	0.1288	0.1444	0.1526
EU	0.0002	0.0038	0.0018	0.0023	0.0030	0.0033	0.0016	0.0019	0.0018

Panel C: 25 Size- a Book-to-Market Portfolios

SR	0.2777	0.1735	0.1500	0.2727	0.2600	0.2597	0.2039	0.1528	0.1584
EU	0.0075	0.0025	0.0017	0.0047	0.0054	0.0055	0.0034	0.0013	0.0018

Panel D: 20 národných portfólií

SR	0.0586	0.1076	0.0989	0.0991	0.1141	0.1095	0.0916	0.0955	0.1093
EU	-0.0018	0.0008	0.0005	0.0007	0.0013	0.0001	0.0004	0.0008	-0.0010

Závěrečné poznámky

- ▶ Negatívne dôsledky z nedostatočne presných odhadov parametrov môžu byť zjemnené zoskupením podobných aktív.
- ▶ Aplikovaním optimálnej veľkosti skupín vyvážíme výhody diverzifikácie z optimalizácie a strát z odhadov
- ▶ Skupinkovanie dáva lepšie výsledky ako 1/N pravidlo pri stovkách mesačných dát

Plán do budúca

- ▶ Zmierniť predpoklady v teoretickom modeli
- ▶ Pravidlá pre zoskupovanie
- ▶ Očakávané výnosy meniace sa v čase

Ďakujem za Vašu pozornosť.
Otázky a pripomienky sú vítané!

Očakávaný úžitok ak parametre μ a Σ nepoznáme

$$E[U(\hat{w})] = k_1 \frac{1}{2\gamma} \mu' \Sigma^{-1} \mu - \frac{NT(T-2)}{2\gamma(T-N-1)(T-N-2)(T-N-4)} \quad (17)$$

kde

$$k_1 = \left(\frac{T}{T-N-2} \right) \left(2 - \frac{T(T-2)}{(T-N-1)(T-N-4)} \right) < 1. \quad (18)$$

spat