


Univerzita Karlova v Praze  
Matematicko-fyzikální fakulta

## BAKALÁŘSKÁ PRÁCE



Andrea Polakovičová

# Úloha replikácie indexov pomocou mier rizika

Katedra pravděpodobnosti a matematické statistiky

Vedoucí bakalářské práce: Doc. RNDr. Martin Branda, Ph.D.

Studijní program: Matematika

Studijní obor: Finanční Matematika

Praha 2023

Touto formou by som sa rada poďakovala môjmu vedúcemu bakalárskej práce Doc. RNDr. Martinovi Brandovi, Ph.D. za jeho prístup, cenné rady a čas, ktorý mi venoval v dobe vypracovávaní tejto práce.

Prohlašuji, že jsem tuto bakalářskou práci vypracoval(a) samostatně a výhradně s použitím citovaných pramenů, literatury a dalších odborných zdrojů.

Beru na vědomí, že se na moji práci vztahují práva a povinnosti vyplývající ze zákona č. 121/2000 Sb., autorského zákona v platném znění, zejména skutečnost, že Univerzita Karlova v Praze má právo na uzavření licenční smlouvy o užití této práce jako školního díla podle §60 odst. 1 autorského zákona.

V ..... dne .....

Podpis autora

Názov práce: Úloha replikácie indexov pomocou mier rizika

Autor: Andrea Polakovičová

Katedra: Katedra pravdepodobnosti a matematické statistiky

Vedúci bakalárskej práce: Doc. RNDr. Martin Branda, Ph.D., Katedra pravdepodobnosti a matematické statistiky

Abstrakt: V tejto práci sa budeme zaoberať jednotlivými metódami merania rizík známymi pod pojmami Value at Risk ( $VaR$ ) a Conditional Value at Risk ( $CVaR$ ). Ich vlastnosti a formulácie využijeme pri odvodení optimalizačnej úlohy lineárneho typu. Úloha lineárneho programovania bude pozostávať z minimalizácie účelovej funkcie predstavujúcej odchýlku medzi portfóliom a zvoleným indexom. Výpočet prevedieme na základe viacerých podmienok, kde práve jedna z nich bude využívať uvedené metódy merania rizika  $VaR$  a  $CVaR$ . Cieľom je na základe tohto programu vytvoriť portfólio, pomocou ktorého budeme replikovať index S&P 500. Celý výpočet prevedieme v programe Python na základe historických dát. Následne použijeme optimálne riešenie, ktoré software našiel a zostavíme podľa neho replikačné portfólio, ktorého vývoj budeme sledovať v nasledujúcich časových obdobiach. V závere práce budeme analyzovať a diskutovať jednotlivé výsledky pre rôzne vstupné parametre.

Kľúčové slová: Miery rizika, optimalizácia portfólia, replikácia indexu

Title: Index tracking problem using risk measures

Author: Andrea Polakovičová

Department: Department of probability and mathematical statistics

Supervisor: Doc. RNDr. Martin Branda, Ph.D., Department of probability and mathematical statistics

Abstract: In this thesis, we will introduce various methods for measuring risk known as Value at Risk ( $VaR$ ) and Conditional Value at Risk ( $CVaR$ ). We will use their properties and formulations in deriving a linear optimization problem. The linear programming problem will consist of minimizing the objective function representing the deviation between the portfolio and a chosen index. The calculation will be carried out based on multiple constraints, where one of them will use the aforementioned risk measures  $VaR$  and  $CVaR$ . The goal is to create a portfolio based on this program that replicates the S&P 500 index. We will perform the entire calculation using Python based on historical data. Subsequently, we will use the optimal solution found by the software and construct a replication portfolio that we will track in the following time periods. In conclusion, we will analyze and discuss the individual results for various input parameters.

Keywords: Risk measures, portfolio optimization, index tracking

# Obsah

<b>Úvod</b>	<b>2</b>
<b>1 Miery rizika a ich vlastnosti</b>	<b>3</b>
1.1 Základné definície . . . . .	3
1.2 Zavedenie mier rizika VaR a CVaR . . . . .	4
1.3 Základné charakteristiky pre VaR a CVaR . . . . .	5
<b>2 Reformulácia mier v riziku</b>	<b>7</b>
2.1 Konštrukcia funkcie pre VaR a CVaR . . . . .	7
2.2 Zhrnutie vlastností funkcie . . . . .	9
<b>3 Konštrukcia lineárneho programu pre portfólio</b>	<b>10</b>
3.1 Značenie . . . . .	10
3.2 Formulácia optimalizačnej úlohy . . . . .	11
3.3 Prevedenie nelineárneho programu na lineárny . . . . .	12
<b>4 Praktická aplikácia</b>	<b>14</b>
4.1 Predstavenie problému . . . . .	14
4.2 Prevedenie optimalizačnej úlohy . . . . .	16
4.3 Vyhodnotenie optimalizačnej úlohy . . . . .	17
<b>Záver</b>	<b>20</b>
<b>Literatúra</b>	<b>21</b>
<b>Zoznam obrázkov</b>	<b>22</b>
<b>Zoznam tabuliek</b>	<b>23</b>
<b>Príloha</b>	<b>24</b>

# Úvod

V dnešnej dobe sme všetci tlačení k tomu, aby sme naše peniaze investovali do rôznych finančných aktív vzhľadom na vysokú mieru inflácie. Avšak, každá investícia prináša so sebou riziko, ktoré sa neustále mení v závislosti od komplexnosti finančných nástrojov, do ktorých peniaze investujeme.

V tejto práci si predstavíme, čo pojem riziko predstavuje a zoznámime sa s metódami známymi ako Value at Risk ( $VaR$ ) a Conditional Value at Risk ( $CVaR$ ), pomocou ktorých vieme dané riziko merať a riadiť. Zameriame sa na ich vlastnosti, spôsoby ich výpočtu a jednotlivé súvislosti, ktoré medzi sebou miery majú.

Na základe ich vlastností odvodíme funkciu, pomocou ktorej budeme mať možnosť vypočítať obe miery rizika zároveň. Preskúmame jednotlivé vlastnosti odvodenej funkcie, ktoré budú pre nás neskôr veľmi užitočné.

Cieľom tejto práce bude skonštruovať portfólio, ktoré bude replikovať zvolený finančný index, keďže indexy sú považované z dlhodobého hľadiska za výnosné a mali by pre nás predstavovať menšiu rizikovosť. Na tento účel využijeme znalosti optimalizácie a zostavíme lineárny program, ktorého jedna z podmienok bude práve obmedzenie na mieru rizika. K formulácii tohto obmedzenia využijeme našu odvodenú funkciu, ktorú budeme obmedzovať zhora, vzhľadom na to akú výšku rizika budeme ochotní tolerovať.

Súčasťou výstupu lineárneho programu budú aj optimálne hodnoty jednotlivých aktív, z ktorých bude portfólio pozostávať. Výpočty budeme vykonávať na základe historických dát pomocou programovacieho jazyka Python.

Následne sa budeme venovať pozorovaniu vývoja výsledného portfólia, ktoré bude skonštruované na základe optimálnych hodnôt a jeho správaniu vzhľadom na zvolený index v nasledujúcich časových obdobiach. Týmto spôsobom sa pokúsime lepšie porozumieť rizikovosti nášho investičného portfólia a nahliadneme na presnosť jednotlivých výsledkov.

# Kapitola 1

## Miery rizika a ich vlastnosti

V tejto kapitole si uvedieme základné pojmy používané v oblasti financií. Zavedieme ich matematické definície, vyjadrenia a objasníme ich interpretáciu. Uvedieme čo je, a v akom zmysle je v našom prípade chápané riziko. Ďalej sa dostaneme k niektorým užitočným vlastnostiam funkcií, ktoré budeme neskôr využívať.

### 1.1 Základné definície

**Definícia 1** (Portfólio). (*Dupačová (2002)*) Nech  $n \in \mathbb{N}$  je počet aktív, ktoré máme k dispozícii. Potom povieme, že vektor  $\mathbf{x} = (x_1, \dots, x_n)$  je portfólio ak  $\sum_{i=1}^n x_i = 1$  a zároveň pre  $\forall i$ , kde  $i = 1, \dots, n$  platí  $x_i \geq 0$ .

Na základe definície 1, portfólio bude pre nás predstavovať vektor o dĺžke  $n$ , kde  $n$  zodpovedá počtu finančných aktív, napríklad akcií do ktorých chceme investovať. Ďalej si môžeme predstaviť, že množstvo peňazí, ktoré budeme investovať je rovné hodnote 1. Potom práve  $\sum_{i=1}^n x_i = 1$ , nám hovorí o tom, že jednotlivé hodnoty  $x_1, \dots, x_n$  reprezentujú časť našej počiatočnej investície, ktorá je vložená do konkrétneho aktíva, kde musí platiť že celkový súčet investícií do jednotlivých aktív zodpovedá presne hodnote našej počiatočnej investície. Keďže zároveň musí pre všetky  $i$  platiť  $x_i \geq 0$ , budeme uvažovať také portfólio, v ktorom nie sú povolené predaje nakrátko.

K zavedeniu následujúcej definície budeme uvažovať pravdepodobnostný priestor  $(Y, \mathcal{A}, P)$ , kde  $\mathcal{A}$  je  $\sigma$ -algebra na  $Y$  a  $P$  je pravdepodobnostná miera na  $Y$ . Zároveň budeme uvažovať reálny náhodný vektor  $\mathbf{y} : \{Y, \mathcal{A}\} \rightarrow \{\mathbb{R}^n, \mathcal{B}_0^n\}$ , u ktorého budeme predpokladať nezávislosť na predom danom vektore  $\mathbf{x}$ , splňajúceho definíciu 1.

**Definícia 2** (Strata). (*Rockafellar a Uryasev (2002)*) Nech  $\mathbf{x}$  je predom daný vektor vybraný z určitej podmnožiny  $X \in \mathbb{R}^n$ , potom  $z = f(\mathbf{x}, \mathbf{y})$  je náhodná strata vzhľadom k rozhodovaciemu vektoru  $\mathbf{x}$  a náhodnému vektoru  $\mathbf{y}$  a zároveň platí, že funkcia  $f(\mathbf{x}, \mathbf{y})$  je spojitá v  $\mathbf{x}$  a merateľná v  $\mathbf{y}$ .

V definícii 2 budeme vektor  $\mathbf{x}$  interpretovať ako vektor reprezentujúci konkrétne portfólio v zmysle definície 1 a množinu  $X$ , ako množinu, ktorá predstavuje všetky dostupné portfólia. Náhodný vektor  $\mathbf{y}$  bude predstavovať určité neistoty, ktoré môžu hodnotu straty ovplyvniť ako napríklad náhodné ceny uvažovaných aktív. Všeobecne budeme uvažovať, že záporná hodnota straty  $z$  predstavuje zisk.

**Definícia 3** (Distribučná funkcia straty). (Rockafellar a Uryasev (2002)) Pre všetky  $\mathbf{x} \in X$ , označíme  $\varphi(\mathbf{x}, \cdot) \in \mathbb{R}$  ako výslednú distribučnú funkciu straty  $z = f(\mathbf{x}, \mathbf{y})$ , pre ktorú platí

$$\varphi(\mathbf{x}, \zeta) = P[\mathbf{y} | f(\mathbf{x}, \mathbf{y}) \leq \zeta].$$

## 1.2 Zavedenie mier rizika VaR a CVaR

Strata v našom prípade predstavuje určitú formu rizika. V praxi sa preto často stretávame s jeho klasifikáciou pomocou hodnôt *VaR* (Value at Risk) a *CVaR* (Conditional Value at Risk), prekladané ako hodnota v riziku a podmienená hodnota v riziku. Jednotlivé hodnoty udávajú, aká je možná výška straty na určitej hladine spoľahlivosti  $\alpha$  (väčšinou volenej 0.99, 0.95) za dané časové obdobie (napr. 1 deň, 1 rok). Tieto hodnoty si následne zdefinujeme na základe definícií uvedených v časti 1.1.

**Definícia 4** (VaR). (Rockafellar a Uryasev (2002), str. 1447). Nech  $\alpha - VaR$  straty vzhľadom k rozhodovaciemu vektoru  $\mathbf{x}$  je hodnota

$$\zeta_\alpha(\mathbf{x}) = \min\{\zeta \in \mathbb{R} | \varphi(\mathbf{x}, \zeta) \geq \alpha\}, \quad (1.1)$$

kde v 1.1 je dosiahnuté minimum, keďže funkcia  $\varphi(\mathbf{x}, \zeta)$  je nerastúca a zprava spojitá v  $\zeta$ . Ak  $\varphi(\mathbf{x}, \cdot)$  je spojitá a striktné rastúca,  $\zeta_\alpha(\mathbf{x})$  je jednoznačne určené  $\zeta$  spĺňajúce  $\varphi(\mathbf{x}, \zeta) = \alpha$ . Inak riešenie rovnice  $\varphi(\mathbf{x}, \zeta) = \alpha$  neexistuje, alebo ich existuje nespočetné mnoho.

**Definícia 5** (CVaR). (Rockafellar a Uryasev (2002), str. 1448). Predpokladajme, že  $E[|f(\mathbf{x}, \mathbf{y})|] < \infty$  pre  $\forall \mathbf{x} \in X$ , potom  $\alpha - CVaR$  straty vzhľadom k rozhodovaciemu vektoru  $\mathbf{x}$  je hodnota

$$\phi_\alpha(\mathbf{x}) = \text{strednej hodnote } \alpha - \text{chvosta rozdelenia } f(\mathbf{x}, \mathbf{y}),$$

kde ide o rozdelenie dané distribučnou funkciou  $\varphi_\alpha(\mathbf{x}, \cdot)$  definovanou nasledovne

$$\varphi_\alpha(\mathbf{x}, \zeta) = \begin{cases} 0 & \text{pre } \zeta < \zeta_\alpha(\mathbf{x}), \\ [\varphi(\mathbf{x}, \zeta) - \alpha] / [1 - \alpha] & \text{pre } \zeta \geq \zeta_\alpha(\mathbf{x}). \end{cases}$$

Vzhľadom k hodnote  $\alpha \in (0, 1)$  predstavujúcej danú hladinu spoľahlivosti.

Je dobré poznamenať, že distribučná funkcia  $\varphi_\alpha(\mathbf{x}, \cdot)$ , je iná distribučná funkcia než zmienaná funkcia v definícii 3, avšak podobne ako  $\varphi(\mathbf{x}, \cdot)$  je neklesajúca, zprava spojitá, kde  $\varphi_\alpha(\mathbf{x}, \zeta) \rightarrow 1$  pre  $\zeta \rightarrow \infty$ . Pomocou tejto distribučnej funkcie vieme však dobre definovať rozdelenie uvažovaného  $\alpha$ -chvostu.

Vzhľadom na definície 4 a 5 môžeme medzi jednotlivými hodnotami pozorovať rôzne rozdiely. Jedným z hlavných rozdielov je, že hodnota *VaR* nám dáva číslo, ktoré zodpovedá najmenšej hodnote straty, ktorú s uvedenou hladinou spoľahlivosti  $\alpha$  dané portfólio neprekročí.

Na druhej strane, hodnota *CVaR* hovorí o tom, aká veľká bude očakávaná strata, ak danú hodnotu *VaR* strata prekročí, čo je pre nás omnoho smerodajnejšia informácia. V nasledujúcej podkapitole si uvedieme niektoré z ďalších charakteristík týchto hodnôt.



### 1.3 Základné charakteristiky pre VaR a CVaR

V tejto časti sa budeme bližšie zaoberať mierami rizika *VaR* a *CVaR*. Zameriame sa na ich vlastnosti a taktiež budeme skúmať ich vzájomné súvislosti, s ktorými budeme ďalej pracovať.

**Veta 1** (Rockafellar a Uryasev (2002), str.1452). *Nech  $\lambda_\alpha(\mathbf{x})$  je pravdepodobnosť toho, že strata  $z = \zeta_\alpha(\mathbf{x})$ , ktorá je daná rozdelením  $\alpha$ -chvostu uvedeného v definícii 5, konkrétne*

$$\lambda_\alpha(\mathbf{x}) = [\varphi(\mathbf{x}, \zeta_\alpha(\mathbf{x})) - \alpha] / [1 - \alpha] \in [0, 1].$$

*Potom môže nastať jedna z nasledujúcich možností:*

- $\varphi(\mathbf{x}, \zeta_\alpha(\mathbf{x})) < 1$ , teda existuje šanca, že strata bude vyššia ako  $\zeta_\alpha(\mathbf{x})$  a

$$\phi_\alpha(\mathbf{x}) = \lambda_\alpha(\mathbf{x})\zeta_\alpha(\mathbf{x}) + [1 - \lambda_\alpha(\mathbf{x})]\phi_\alpha^+(\mathbf{x}),$$

$$\text{kde } \phi_\alpha^+(\mathbf{x}) = E[f(\mathbf{x}, \mathbf{y}) | f(\mathbf{x}, \mathbf{y}) > \zeta_\alpha(\mathbf{x})].$$

- $\varphi(\mathbf{x}, \zeta_\alpha(\mathbf{x})) = 1$ , tým pádom  $\zeta_\alpha(\mathbf{x})$  je najvyššia možná strata, ktorá môže nastať, z kadiaľ vyplýva rovnosť

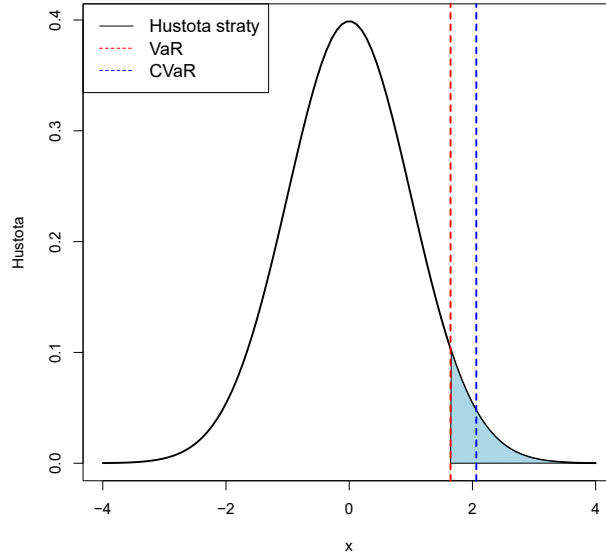
$$\phi_\alpha(\mathbf{x}) = \zeta_\alpha(\mathbf{x}).$$

*Dôkaz.* Tieto vzťahy jednoznačne vyplývajú z definície 5 a z platnosti nerovnosti  $\alpha \leq \varphi(\mathbf{x}, \zeta_\alpha(\mathbf{x}))$ , ktorá vďaka definícii 4 platí vždy. □

*Dôsledok* (Rockafellar a Uryasev (2002), str. 1452). Na základe definícií 4, 5 a vety 1 platí

$$\phi_\alpha(\mathbf{x}) \geq \zeta_\alpha(\mathbf{x}).$$

Dokonca, v prípade kedy neexistuje šanca, že strata bude väčšia ako  $\zeta_\alpha(\mathbf{x})$  platí  $\phi_\alpha(\mathbf{x}) = \zeta_\alpha(\mathbf{x})$ .



Obr. 1.1: Hodnoty  $VaR$  a  $CVaR$  v prípade predpokladu normovaného normálneho rozdelenia straty na hladine  $\alpha = 0.95$ .

**Veta 2** (Rockafellar a Uryasev (2002), str. 1453). *Predpokladajme, že pravdepodobnostná miera  $P$  je koncentrovaná v konečne mnoho bodoch  $y_k \in Y$  tak, že pre každé  $\mathbf{x} \in X$  distribúcia straty  $z = f(\mathbf{x}, \mathbf{y})$  je podobne koncentrovaná v konečne mnoho bodoch a  $\varphi(\mathbf{x}, \cdot)$  je po častiach lineárna funkcia so skokmi v jednotlivých bodoch. Pre pevné  $\mathbf{x}$ , nech sú zodpovedajúce realizácie straty usporiadané nasledovne  $z_1 < z_2 < \dots < z_N$ , kde  $P(z = z_k) = p_k$  a  $p_k > 0$  pre  $k = 1, \dots, N$ . Nech  $k_\alpha$  je jednoznačne určený index splňajúci*

$$\sum_{k=1}^{k_\alpha} p_k \geq \alpha > \sum_{k=1}^{k_\alpha-1} p_k.$$

Potom pre  $\alpha - VaR$  straty platí

$$\zeta_\alpha(\mathbf{x}) = z_{k_\alpha},$$

a  $\alpha - CVaR$  dostávame z rovnosti

$$\phi_\alpha(\mathbf{x}) = \frac{1}{1-\alpha} \left[ \left( \sum_{k=1}^{k_\alpha} p_k - \alpha \right) z_{k_\alpha} + \sum_{k=k_\alpha+1}^N p_k z_k \right].$$

*Dôkaz.* Jednotlivé kroky dôkazu nájdeme v článku (Rockafellar a Uryasev (2002), str. 1453). □

# Kapitola 2

## Reformulácia mier v riziku

V tejto časti bude našim cieľom vyjadriť hodnoty  $VaR$  a  $CVaR$  pomocou jednej funkcie, ktorej konštrukciu postavíme na základe definícií a viet, ktoré sme si uviedli v prvej kapitole. Zadefinovanie takejto funkcie nám neskôr prinesie možnosti na jednoduchší výpočet hodnôt v riziku.

### 2.1 Konštrukcia funkcie pre VaR a CVaR

Z definície 4 a za predpokladu existencie riešenia rovnosti  $\varphi(\mathbf{x}, \zeta) = \alpha$  dostávame, že  $\zeta_\alpha(\mathbf{x})$  predstavuje ľavý krajný bod neprázdneho intervalu, ktorý obsahuje hodnoty  $\zeta$  také, že  $\varphi(\mathbf{x}, \zeta) = \alpha$ . Rovnosť plynie z vlastností distribučnej funkcie  $\varphi(\mathbf{x}, \zeta)$ , ktorá je spojitá a neklesajúca vzhľadom k premennej  $\zeta$ . Na druhej strane z definície 5 dostávame, že  $P[f(\mathbf{x}, \mathbf{y}) \geq \zeta_\alpha(\mathbf{x})] = 1 - \alpha$ . Teda hodnota  $\phi_\alpha(\mathbf{x})$  zodpovedá podmienenej strednej hodnote straty vzhľadom k  $\mathbf{x}$  ku ktorému bude strata rovná hodnote  $\zeta_\alpha(\mathbf{x})$  alebo väčšia.

Na základe týchto poznatkov a predpokladu, že náhodný vektor  $\mathbf{y}$  definovaný na pravdepodobnostnom priestore  $(Y, \mathcal{B}, P)$  pochádza zo spojitého rozdelenia definovaného hustotou  $p(\mathbf{y})$ , môžeme charakterizovať hodnoty  $\zeta_\alpha(\mathbf{x})$  a  $\phi_\alpha(\mathbf{x})$  pomocou funkcie  $F_\alpha$  definovanej na množine  $X \times \mathbb{R}$  nasledovne

$$F_\alpha(\mathbf{x}, \zeta) = \zeta + \frac{1}{1 - \alpha} \int_{\mathbf{y} \in \mathbb{R}^n} [f(\mathbf{x}, \mathbf{y}) - \zeta]^+ p(\mathbf{y}) d\mathbf{y}, \quad (2.1)$$

kde  $[t]^+ = \max\{0, t\}$  pre  $t = [f(\mathbf{x}, \mathbf{y}) - \zeta]$ .

Jednou z najdôležitejších vlastností funkcie  $F_\alpha$  definovanej pomocou 2.1 je jej konvexita, ktorá je kľúčovou z pohľadu optimalizácie. Keďže našim cieľom bude funkciu neskôr minimalizovať vzhľadom k premennej  $\zeta$ . Na túto vlastnosť a jej dôsledky sa bližšie pozrieme v nasledujúcej vete 3.

**Veta 3.** (Rockafellar a Uryasev (2000), str.5) *Nech náhodný vektor  $\mathbf{y}$  definovaný na pravdepodobnostnom priestore  $(Y, \mathcal{B}, P)$  pochádza zo spojitého rozdelenia definovaného hustotou  $p(\mathbf{y})$ . Potom odvodená funkcia  $F_\alpha(\mathbf{x}, \zeta)$  je ako funkcia premennej  $\zeta \in \mathbb{R}$  konvexná a spojitě diferencovateľná. Hodnotu  $\alpha - CVaR$  straty vzhľadom k ľubovoľnému vektoru  $\mathbf{x}$  vieme určiť z rovnosti*

$$\phi_\alpha(\mathbf{x}) = \min_{\zeta} F_\alpha(\mathbf{x}, \zeta). \quad (2.2)$$

Množinu hodnôt  $\zeta$ , pre ktoré funkcia nadobúda minimum označíme

$$A_\alpha(\mathbf{x}) = \arg \min_{\zeta} F_\alpha(\mathbf{x}, \zeta), \quad (2.3)$$

ktorá je neprázdny, uzavretým a obmedzeným intervalom (väčšinou zredukovaným na jeden bod) a hodnota  $\alpha - VaR$  straty je daná ako

$$\zeta_\alpha(\mathbf{x}) = \text{ľavý krajný bod intervalu } A_\alpha(\mathbf{x}).$$

Konkrétne vždy platí

$$\zeta_\alpha(\mathbf{x}) \in \arg \min_{\zeta} F_\alpha(\mathbf{x}, \zeta) \quad \text{a} \quad \phi_\alpha(\mathbf{x}) = F_\alpha(\mathbf{x}, \zeta_\alpha(\mathbf{x})).$$

*Dôkaz.* Jednotlivé kroky dôkazu sú podrobne popísané v článku Rockafellar a Uryasev (2000) str. 25. □

Vetou 3 sa autori zaberajú aj neskôr v článku Rockafellar a Uryasev (2002), kde môžeme nájsť jej formuláciu pre ľubovoľné rozdelenie.

Ďalej poznamenajme, že z hľadiska výpočtu vieme rovnako dobre minimalizovať funkciu  $(1 - \alpha)F_\alpha(\mathbf{x}, \zeta)$  ako aj  $F_\alpha(\mathbf{x}, \zeta)$ . Týmto spôsobom sa vieme vyhnúť deleniu integrálu výrazom  $(1 - \alpha)$ , čo môže byť z numerického hľadiska výhodnejšie najmä v prípadoch, kedy je hodnota  $(1 - \alpha)$  príliš malá.

Na základe vety 3, ktorá nám poskytuje informáciu o vlastnostiach funkcie  $F_\alpha(\mathbf{x}, \zeta)$  a vedomostiam z teórie optimalizácie vieme, že funkcie ktoré sú spojito diferencovateľné a konvexné sa dajú jednoducho numericky minimalizovať. Práve konvexita, ktorá je kľúčovou vlastnosťou z hľadiska optimalizácie nám zaručí, že pri postupnom prechádzaní funkcie a hľadaním minima nenatrafíme na lokálne minimum, ktoré by bolo rozdielne od globálneho. To znamená, že optimálna hodnota je určená jednoznačne.

Rovnosť 2.2 nám poskytuje prístup k výpočtu hodnoty  $\alpha - CVaR$  bez nutnosti prvotného výpočtu hodnoty  $\alpha - VaR$  na základe ktorej je podmienená hodnota v riziku na danej úrovni spoľahlivosti  $\alpha$  definovaná (viz. Definícia 5). Avšak v prípade potreby vieme hodnotu  $\alpha - VaR$  získať ako vedľajší produkt, ktorý získame určením intervalu  $A_\alpha(\mathbf{x})$  definovaného pomocou 2.3 a extrahovaním jeho ľavého krajného bodu, pokiaľ daný interval obsahuje viac ako jeden bod.

Pre jednoduchšie narábanie s funkciou  $F_\alpha(\mathbf{x}, \zeta)$ , vieme jej časť, ktorá je definovaná pomocou integrálu (2.1) nahradiť jeho príslušnou aproximáciou.

Jednou z možností je, že si vygenerujeme náhodný výber vektorov  $\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_T$  z rozdelenia daného hustotou  $p(\mathbf{y})$  vzhľadom ku ktorej bude aproximácia funkcie  $F_\alpha(\mathbf{x}, \zeta)$  vyzeráť nasledovne

$$\tilde{F}_\alpha(\mathbf{x}, \zeta) = \zeta + \frac{1}{(1 - \alpha)T} \sum_{t=1}^T [f(\mathbf{x}, \mathbf{y}_t) - \zeta]^+. \quad (2.4)$$

Funkcia  $\tilde{F}_\alpha(\mathbf{x}, \zeta)$  je konvexná a po častiach lineárna vzhľadom k  $\zeta$ , avšak nieje diferencovateľná vzhľadom k  $\zeta$ . Napriek tomu ju však môžeme minimalizovať pomocou riešenia problému elementárneho lineárneho programovania.

Nasledujúca veta, ktorú si zavedieme opäť poukazuje na dôležitosť vyjadrenia hodnôt  $\alpha - VaR$  a  $\alpha - CVaR$  pomocou funkcie  $F_\alpha$ . Na základe jej vlastností uvedených vo vete 3 sa dostávame k formálnemu vyjadreniu riešenia minimalizačného problému.

**Veta 4.** (Rockafellar a Uryasev (2000), str. 6) Predpokladajme, že náhodný vektor  $\mathbf{y}$  definovaný na pravdepodobnostnom priestore  $(Y, \mathcal{B}, P)$  pochádza zo spojitého rozdelenia definovaného hustotou  $p(\mathbf{y})$ . Minimalizácia hodnoty  $\alpha - CVaR$  straty vzhľadom k rozhodovaciemu vektoru  $\mathbf{x} \in X$  je ekvivalentná minimalizáciou funkcie  $F_\alpha(\mathbf{x}, \zeta)$  cez všetky  $(\mathbf{x}, \zeta) \in X \times \mathbb{R}$ , v zmysle

$$\min_{\mathbf{x} \in X} \phi_\alpha(\mathbf{x}) = \min_{(\mathbf{x}, \zeta) \in X \times \mathbb{R}} F_\alpha(\mathbf{x}, \zeta),$$

kde navyše pre dvojicu  $(\mathbf{x}^*, \zeta^*)$  dosahuje funkcia na pravej strane rovnosti hodnotu minima, práve vtedy a len vtedy ak aj funkcia na ľavej strane rovnosti dosahuje minimum pre hodnotu  $\mathbf{x}^*$  a  $\zeta^* \in A_\alpha(\mathbf{x}^*)$ . Najmä preto, za okolností, keď je interval  $A_\alpha(\mathbf{x}^*)$  zredukovaný na jeden bod (ako bežne býva), minimalizáciou funkcie  $F_\alpha(\mathbf{x}, \zeta)$  cez všetky  $(\mathbf{x}, \zeta) \in X \times \mathbb{R}$  dostávame ako riešenie dvojicu  $(\mathbf{x}^*, \zeta^*)$ , nie nutne jednoznačnú, takú že  $\mathbf{x}^*$  minimalizuje hodnotu  $\alpha - CVaR$  a zároveň  $\zeta^*$  zodpovedá korešpondujúcej hodnote  $\alpha - VaR$ .

*Dôkaz.* Jednotlivé kroky dôkazu nájdeme v článku Rockafellar a Uryasev (2000), uvedené na strane 26. □

**Veta 5.** (Rockafellar a Uryasev (2002), str. 1457) Ak je funkcia  $f(\mathbf{x}, \mathbf{y})$  konvexná vzhľadom k premennej  $\mathbf{x}$  a pre každé  $\mathbf{y}$  potom,  $\phi_\alpha(\mathbf{x})$  je taktiež konvexná vzhľadom k premennej  $\mathbf{x}$  a podobne aj funkcia  $F_\alpha(\mathbf{x}, \zeta)$  je konvexná vzhľadom k dvojici  $(\mathbf{x}, \zeta)$ .

*Dôkaz.* Podrobné prevedenie dôkazu nájdeme v článku Rockafellar a Uryasev (2002) na strane 1457. □

*Dôsledok.* Ak sú podmienky minimalizácie funkcie v tvare, ktorý spĺňa podmienky vety 5, smerujeme k riešeniu minimalizačnej konvexnej úlohy, keďže aj množina  $X$  je konvexnou množinou.

## 2.2 Zhrnutie vlastností funkcie

Veta 4 nám poskytuje možnosť, ako jednoduchým spôsobom vyčíslime hodnotu zodpovedajúcu minimu  $\alpha - CVaR$  a hodnotu  $\alpha - VaR$  zároveň. Pri výpočte  $\mathbf{x}$ , ktoré zodpovedá hodnote minima  $\alpha - CVaR$ , nieje teda nutné pracovať priamo s funkciou  $\phi_\alpha(\mathbf{x})$ , ale môžeme použiť odvodenú funkciu  $F_\alpha(\mathbf{x}, \zeta)$ .

Naďalej budeme pre jednoduchosť pracovať s funkciou  $F_\alpha(\mathbf{x}, \zeta)$ , ktorá je podľa vety 5 konvexná vzhľadom k premennej  $\zeta$  a taktiež k dvojici  $(\mathbf{x}, \zeta)$ . Zároveň si môžeme povšimnúť, že z konvexity funkcie  $f(\mathbf{x}, \mathbf{y})$  vzhľadom k  $\mathbf{x}$  vyplývala aj konvexita aproximačnej funkcie  $F_\alpha(\mathbf{x}, \zeta)$  taktiež vzhľadom k dvojici  $(\mathbf{x}, \zeta)$ , kde funkcia  $\tilde{F}_\alpha(\mathbf{x}, \zeta)$  je zadaná pomocou rovnosti 2.4.

Minimalizačný prístup pre hodnotu  $\phi_\alpha(\mathbf{x})$  uvedený vo vete 4 môžeme využiť v kombinácii s aproximačnou metódou integrálu v definícii funkcie  $F_\alpha(\mathbf{x}, \zeta)$ .

Dostávame sa teda k tomu, že problém minimalizácie funkcie  $F_\alpha$  na množine  $X \times \mathbb{R}$  spadá do kategórie konvexného programovania. Z toho dôvodu existuje široká škála spôsobov ako danú problematiku hľadania minima riešiť, kde práve veta 4 nám dovoľuje použiť tieto techniky pri minimalizácii hodnoty  $\alpha - CVaR$ .

# Kapitola 3

## Konštrukcia lineárneho programu pre portfólio

V tejto časti sa budeme zaoberať odvodením lineárneho programu pre optimalizáciu portfólia. Naším cieľom bude, aby naše portfólio čo najlepšie replikovalo zvolený index, teda aby odchýlka medzi cenami portfólia a uvažovaného indexu bola čo najmenšia. Riešenie tohto problému vedie na úlohu konvexného programovania, ktorú prevedieme na lineárnu z dôvodu jednoduchosti jej výpočtu. Ďalej uvedieme využitie reformulácie pre hodnoty *CVaR* a *VaR* pomocou funkcie  $F_\alpha$ , ktorú použijeme ako jedno z obmedzení pri riešení minimalizačnej úlohy.

### 3.1 Značenie

Uvažujeme index  $I$ , pozostávajúci z viacerých akcií. Na základe tohto indexu si vyberieme konkrétne akcie  $S_j$ ,  $j = 1, \dots, n$ , ktoré sú súčasťou indexu  $I$ . Označíme  $I_t$  cenu indexu  $I$  v čase  $t$  pre  $t = 1, \dots, T$  a  $y_{t,j}$  cenu akcie  $S_j$  v čase  $t$ . Nech  $\nu$  je hodnota investície do portfólia v čase 1. Potom označíme  $\theta = \nu/I_1$  počet jednotiek indexu  $I$  v čase 1. Nech  $x_j$ , pre  $j = 1, \dots, n$  je počet jednotiek akcie  $S_j$  v navrhovanom portfóliu, pomocou ktorého budeme index replikovať. Na základe zavedeného označenia dostávame, že hodnota portfólia v čase  $t$  je rovná  $\sum_{j=1}^n y_{t,j} x_j$ .

Následne vieme povedať, že absolútna hodnota relatívnej odchýlky hodnoty replikovaného portfólia od cieľovej hodnoty  $\nu = \theta I_t$  je

$$\left| (\theta I_t - \sum_{j=1}^n y_{t,j} x_j) / \theta I_t \right|.$$

Je dobré si uvedomiť, že absolútna hodnota relatívnej odchýlky nám udáva, ako veľmi je vzdialené portfólio od daného indexu, či už smerom nahor alebo nadol.

Uvažovaný vektor cien  $\mathbf{y}_t = (y_{t,1}, \dots, y_{t,n})$  pre  $t = 1, \dots, T$ , získame z pozorovaní náhodného vektoru  $\mathbf{y} \in \mathbb{R}^n$ , zavedeného pri definícii straty 2. Následne predpokladáme, že náhodný vektor  $\mathbf{y}$  má diskkrétne rovnomerné rozdelenie na množine pozorovaní  $\{\mathbf{y}_1, \dots, \mathbf{y}_T\}$  a teda platí  $P[\mathbf{y} = \mathbf{y}_t] = 1/T$  pre všetky  $t$ .

Vezmeme funkciu straty  $f(\mathbf{x}, \mathbf{y})$ , pomocou ktorej zavedieme relatívnu hodnotu straty. V našom prípade relatívna strata predstavuje spomínanú relatívnu

odchýlku nášho portfólia od indexu, pomocou ktorého chceme uvažovaný index replikovať, teda

$$f(\mathbf{x}, \mathbf{y}_t) = (\theta I_t - \sum_{j=1}^n y_{t,j} x_j) / \theta I_t. \quad (3.1)$$

V tomto zápise funkciu následne využijeme ako funkciu pomocou ktorej budeme minimalizovať strednú hodnotu absolútnej odchýlky  $|f(\mathbf{x}, \mathbf{y}_t)|$ .

## 3.2 Formulácia optimalizačnej úlohy

K nájdeniu optimálneho riešenia sa formálne dostávame k minimalizačnej úlohe, pomocou ktorej budeme naše portfólio replikovať. Ako účelovú funkciu zvolíme absolútnu hodnotu funkcie  $f(\mathbf{x}, \mathbf{y}_t)$  zadefinovanú v 3.1, ktorú budeme minimalizovať v jednotlivých časových intervaloch  $1, \dots, T$  tak, aby súčet výsledných absolútnych odchýliek bol čo najmenší. Optimalizačnú úlohu formulujeme v tvare

$$\min g(\mathbf{x}) = \frac{1}{T} \sum_{t=1}^T \left| \left( \theta I_t - \sum_{j=1}^n y_{t,j} x_j \right) / \theta I_t \right|, \quad (3.2)$$

za podmienok :

$$\sum_{j=1}^n y_{1,j} x_j = \nu \quad (3.3)$$

$$\zeta + \frac{1}{(1-\alpha)T} \sum_{t=1}^T [f(\mathbf{x}, \mathbf{y}_t) - \zeta]^+ \leq \omega \quad (3.4)$$

$$x_j \geq 0, j = 1, \dots, n \quad (3.5)$$

kde minimalizujeme funkciu vzhľadom k vektoru  $\mathbf{x} = (x_1, \dots, x_n)$  a premennej  $\zeta$ . Podmienka 3.3 nám zabezpečí, že portfólio bude zostavené, tak aby sme investovali celú počiatočnú investíciu  $\nu$ . Teda, na základe cien jednotlivých akcií v čase 1 sa rozhodneme koľko jednotiek danej akcie kúpime, aby celkový súčet investícií bol v hodnote  $\nu$ . Číslo  $\omega$  v podmienke 3.4 je maximálna tolerovaná hodnota pre *CVaR*, ktorú volíme tak, aby minimalizačná úloha bola prípustná. Funkcia straty  $f(\mathbf{x}, \mathbf{y}_t) = (\theta I_t - \sum_{j=1}^n y_{t,j} x_j) / \theta I_t$ , tým pádom vieme podmienku 3.4 ekvivalentne zapísať do tvaru

$$\zeta + \frac{1}{(1-\alpha)T} \sum_{t=1}^T \left[ \left( \theta I_t - \sum_{j=1}^n y_{t,j} x_j \right) / \theta I_t - \zeta \right]^+ \leq \omega. \quad (3.6)$$

Výraz na ľavej strane nerovnosti (3.6) je rovný funkcií  $F_\alpha(\mathbf{x}, \zeta)$  z definície 2.1. V diskretnom prípade, ktorý uvažujeme, aplikáciou operátora strednej hodnoty  $E$  je

$$E[f(\mathbf{x}, \mathbf{y}) - \zeta]^+ = \frac{1}{T} \sum_{t=1}^T \left[ \left( \theta I_t - \sum_{j=1}^n y_{t,j} x_j \right) / \theta I_t - \zeta \right]^+,$$

z kadiaľ sa odvíja rovnosť pravej strany s funkciou.

Problémom funkcie  $g(\mathbf{x})$  vzhľadom k výpočtu je, že nie je lineárna kvôli absolútnej hodnote v jej predpise. Avšak pre ľubovoľné  $\alpha$  a  $\omega$ , vieme tento problém previesť na úlohu lineárneho programovania.

### 3.3 Prevedenie nelineárneho programu na lineárny

Ako prvé si pri linearizácii daného programu označíme problémovú zložku funkcie  $g(\mathbf{x})$ . V našom prípade ide o absolútnu hodnotu, ktorá porušuje uvažovanú funkciu. Nech  $\eta_{t,0} = |f(\mathbf{x}, \mathbf{y}_t)| = |(\theta I_t - \sum_{j=1}^n y_{t,j} x_j) / \theta I_t|$  pre všetky  $t = 1, \dots, T$ . So zavedením ďalších podmienok môžeme úlohu formulovať v tvare

$$\min g(\mathbf{x}) = \frac{1}{T} \sum_{t=1}^T \eta_{t,0} \quad (3.7)$$

za podmienok :

$$\eta_{t,0} = \left| (\theta I_t - \sum_{j=1}^n y_{t,j} x_j) / \theta I_t \right|, \quad t = 1, \dots, T \quad (3.8)$$

a podmienok 3.3, 3.5 a 3.6 uvedených vyššie. Vzhľadom na to, že minimalizujeme účelovú funkciu, môžeme v podmienke 3.8 namiesto rovnosti použiť nerovnosť  $\geq$ , čím sa nám program nezmení keďže pre

$$\eta_{t,0} \geq \left| (\theta I_t - \sum_{j=1}^n y_{t,j} x_j) / \theta I_t \right|,$$

platí

$$\left| (\theta I_t - \sum_{j=1}^n y_{t,j} x_j) / \theta I_t \right| = \max \left[ (\theta I_t - \sum_{j=1}^n y_{t,j} x_j) / \theta I_t, - (\theta I_t - \sum_{j=1}^n y_{t,j} x_j) / \theta I_t \right] \quad (3.9)$$

$$\eta_{t,0} \geq \max \left[ (\theta I_t - \sum_{j=1}^n y_{t,j} x_j) / \theta I_t, - (\theta I_t - \sum_{j=1}^n y_{t,j} x_j) / \theta I_t \right], \quad (3.10)$$

$$\Leftrightarrow \eta_{t,0} \geq (\theta I_t - \sum_{j=1}^n y_{t,j} x_j) / \theta I_t, \quad \eta_{t,0} \geq - (\theta I_t - \sum_{j=1}^n y_{t,j} x_j) / \theta I_t. \quad (3.11)$$

Do rozporu s linearitou sa však dostáva ešte podmienka 3.6, kde uvažujeme iba kladnú časť. Na vyriešenie tohto problému si zavedieme pomocnú premennú  $u_t$  pomocou ktorej podmienku linearizujeme.

Náš finálny lineárny program, ktorý bude riešiť problematiku replikácie indexu pomocou nášho portfólia pre ľubovoľné hodnoty  $\alpha$  a  $\omega$  na základe odvodení vyššie, bude potom v tvare



$$\min g(\mathbf{x}) = \frac{1}{T} \sum_{t=1}^T \eta_{t,0}$$

za podmienok :

$$\sum_{j=1}^n y_{1,j} x_j = \nu$$

$$(\theta I_t - \sum_{j=1}^n y_{t,j} x_j) / \theta I_t \leq \eta_{t,0}, \quad t = 1, \dots, T$$

$$- (\theta I_t - \sum_{j=1}^n y_{t,j} x_j) / \theta I_t \leq \eta_{t,0}, \quad t = 1, \dots, T$$

$$\zeta + \frac{1}{(1-\alpha)T} \sum_{t=1}^T u_t \leq \omega$$

$$[(\theta I_t - \sum_{j=1}^n y_{t,j} x_j) / \theta I_t - \zeta] \leq u_t, \quad t = 1, \dots, T$$

$$u_t \geq 0, \quad t = 1, \dots, T$$

$$\eta_{t,0} \geq 0, \quad t = 1, \dots, T$$

$$x_j \geq 0, \quad j = 1, \dots, n$$

ktorý budeme minimalizovať vzhľadom k  $\mathbf{x} = (x_1, \dots, x_n)$ , premennej  $\zeta$  a k novozavedeným premenným  $\eta$  a  $u$ .

Niektorými časťami minimalizačnej úlohy sa zaoberali aj autori v článku Rockafellar a Uryasev (2002), kde linearizovali podmienku 3.8 pomocou zavedenia pomocnej premennej  $\eta$  a jej rozkladu na kladnú a zápornú časť. My sme sa týmto rozkladom podrobnejšie zaoberali v rovniciach 3.9, 3.10 a 3.11. Následne sme navyše zaviedli pomocnú premennú  $u$ , pomocou ktorej sme previedli podmienku 3.6 do lineárneho tvaru. Tieto kroky nám zaručili, že účelová funkcia a aj všetky jej podmienky minimalizácie budú v lineárnom tvare, čo znamená, že môžeme úlohu riešiť pomocou nástrojov lineárneho programovania.

# Kapitola 4

## Praktická aplikácia

Finálny tvar optimalizačnej úlohy, ktorú sme odvodili na konci kapitoly 3.3 využijeme pri replikácii indexu S&P 500 pomocou nami zvolených akcií v portfóliu. Na riešenie minimalizačnej úlohy využijeme programovací jazyk Python a balíček PuLP, kde následne prevedieme výpočet v dvoch fázach. Na konkrétnu konštrukciu tohto kódu je možné nahliadnúť v prílohe tejto práce.

V prvej fáze, takzvanej *in – sample*, prevedieme výpočet optimalizačnej úlohy na základe dostupných historických dát. V druhej fáze *out – of – sample* aplikujeme výsledky z prvej fázy na dáta, ktoré neboli v kategórii *in – sample* a budeme pozorovať nakoľko presnú replikáciu sme previedli.

### 4.1 Predstavenie problému

Portfólio, pomocou ktorého budeme replikovať spomínaný index  $I = \text{S\&P 500}$ , bude pozostávať z nasledujúcich dvadsiatich akcií, ktorých názov je uvedený pod takzvanými tickerami: AAPL, WMT, IBM, MU, BA, AXP, META, PEP, MCD, NFLX, ADI, BAC, PFE, KO, MA, TSLA, HPQ, STT, CMG, PSX. V zmysle zavedeného značenia v podkapitole 3.1 akcie predstavujú jednotlivé zložky  $S_j$ , kde  $j = 1, \dots, 20$ .

Dalej budeme pri výpočte uvažovať

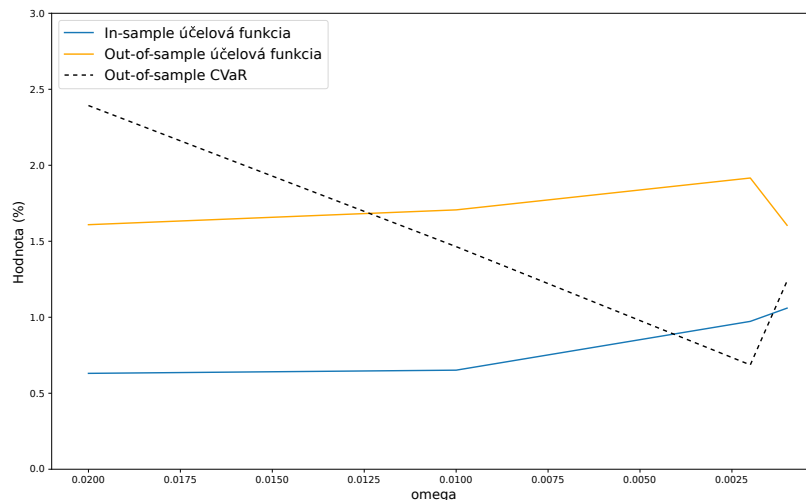
- Časové obdobie od 08.06.2020 do 12.12.2022 predstavujúce 131 týždňov, kde do fázy *in – sample* zaradíme týždne v časovom období od 08.06.2020 do 06.06.2022 a do fázy *out – of – sample* týždne od 06.06.2022 do 12.12.2022
- Pondelkové uzatváracie ceny jednotlivých aktív, upravené o trhové parametre v týždňoch  $t = 1, \dots, 131$
- Cenu indexu  $I_t$  v týždni  $t = 1, \dots, 131$
- Náhodný vektor cien  $y_{t,j}$ , ktorý predstavuje cenu akcie  $S_j$  pre  $j = 1, \dots, 20$  v danom týždni  $t = 1, \dots, 131$
- Počiatočnú investíciu do portfólia v hodnote  $\nu = 1000$  USD
- Počet jednotiek  $\theta = \nu/I_1$  indexu S&P 500 vzhľadom k počiatočnej investícii
- Hodnotu  $x_j$  predstavujúcu počet jednotiek akcie  $S_j$  pre  $j = 1, \dots, 20$  v portfóliu

- Úroveň spoľahlivosti  $\alpha = 0.95$  pre mieru rizika  $CVaR$
- Toleranciu podmienenej hodnoty v riziku  $\omega$

Ako prvý prevedieme výpočet *in – sample*, ktorý prebieha v týždňoch  $t = 1, \dots, 104$  pre rôzne hodnoty  $\omega$ , na úrovni spoľahlivosti  $\alpha$ . Následne použijeme riešenia k výpočtu hodnoty účelovej funkcie a miery rizika  $CVaR$  vo fáze *out – of – sample* v týždňoch  $t = 105, \dots, 131$ . Na základe výsledných hodnôt, ktoré sú uvedené tabuľke 4.1, môžeme pozorovať, že pri hodnote  $\omega = 0.02$  dosahuje účelová funkcia v období *in – sample* najnižšiu hodnotu. Znamená to teda, že odchýlky medzi replikačným portfóliom a indexom sú najmenšie. Z toho dôvodu si na prevedenie výpočtu optimalizačnej úlohy zvolíme pevnú hodnotu  $\omega = 0.02$ .

Hodnota $\omega$	Hodnota účelovej funkcie vo fáze <i>in – sample</i> (%)	Hodnota účelovej funkcie vo fáze <i>out – of – sample</i> (%)	Hodnota $CVaR$ vo fáze <i>out – of – sample</i> (%)
0.02	0.63083	1.60902	2.3930
0.01	0.65183	1.70646	1.4646
0.002	0.97288	1.91618	0.6865
0.001	1.05997	1.60507	1.2386

Tabuľka 4.1: Hodnoty funkcií v závislosti na premennej  $\omega$ .



Obr. 4.1: Pribeh jednotlivých funkcií v závislosti na hodnotách  $\omega$  uvedených v tabuľke 4.1.

Z obrázku 4.1 môžeme vidieť, že zvolená hodnota  $\omega$  má najväčší vplyv na mieru rizika  $CVaR$  v období *out – of – sample*, kedy do určitého bodu jej miera spoločne s klesajúcou hodnotou  $\omega$  taktiež klesá. Čo sa týka hodnôt účelovej funkcie, obe so znižujúcou sa hodnotou  $\omega$  mierne stúpajú, čo sme aj očakávali, keďže znižovaním hodnoty  $\omega$  kladieme vyššie nároky na podmienku, čím sa stáva prísnejšou, čoho následkom je nárast veľkosti odchýliek. Avšak na konci môžeme pozorovať výraznejší pokles účelovej funkcie v období *out – of – sample*, ale naopak nárast miery rizika  $CVaR$  pre dané obdobie.

## 4.2 Prevedenie optimalizačnej úlohy

Začíname opäť výpočtom vo fáze *in – sample* pre hodnoty uvedené v podkapitole 4.1 a pre pevnú hodnotu  $\omega = 0.02$ . Účelová funkcia v tejto fáze pre dané hodnoty splňa nasledujúcu rovnosť

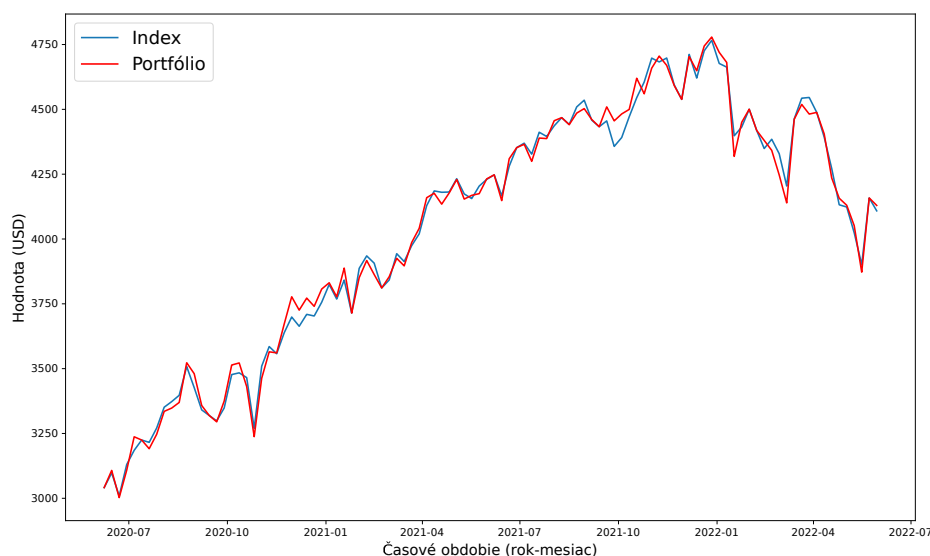
$$\min g(\mathbf{x}) = \frac{1}{104} \sum_{t=1}^{104} \eta_{t,0} = 0.0063083.$$

Zároveň pre optimálne hodnoty  $\mathbf{x}^* = (x_1^*, \dots, x_{20}^*)$  predstavujúce počet jednotiek jednotlivých akcií v našom portfóliu platí nasledujúca tabuľka 4.2.

Ticker	Premenná	Počet jednotiek
AAPL	$x_1^*$	0.940108
WMT	$x_2^*$	0.919993
IBM	$x_3^*$	1.471402
MU	$x_4^*$	0.000000
BA	$x_5^*$	0.000000
AXP	$x_6^*$	0.025225
META	$x_7^*$	3.865146
PEP	$x_8^*$	1.277443
MCD	$x_9^*$	0.000000
NFLX	$x_{10}^*$	0.061941
ADI	$x_{11}^*$	0.000000
BAC	$x_{12}^*$	0.297218
PFE	$x_{13}^*$	0.000000
KO	$x_{14}^*$	0.306777
MA	$x_{15}^*$	0.065135
TSLA	$x_{16}^*$	2.552543
HPQ	$x_{17}^*$	0.272763
STT	$x_{18}^*$	0.000000
CMG	$x_{19}^*$	0.000000
PSX	$x_{20}^*$	1.303415

Tabuľka 4.2: Výsledné rozloženie portfólia pre  $\omega = 0.02$ .

Môžeme si všimnúť, že software vyhodnotil, že niektoré akcie, ktoré sme uvažovali, nie sú pri replikácii indexu potrebné. Ďalej sa pozrieme na grafické znázornenie vývoju indexu S&P500 a nášho replikačného portfólia v období od 08.06.2020 do 12.12.2022 zobrazeného na obrázku 4.2.



Obr. 4.2: Vývoj indexu S&P 500 a replikačného portfólia v období *in – sample*.

### 4.3 Vyhodnotenie optimalizačnej úlohy

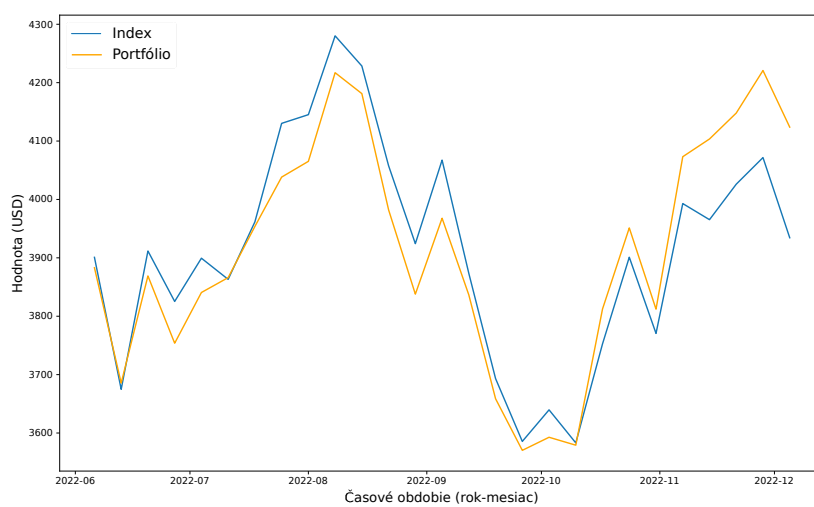
Dôležitou bude pre nás, práve fáza *out – of – sample*, na základe ktorej zistíme nakoľko presné boli naše výpočty v predošlej fáze. Pri výpočte budeme uvažovať portfólio ktorého zloženie pozostáva práve z výsledných hodnôt pre  $x_1^*, \dots, x_{20}^*$  uvedených v tabuľke 4.2. Následne sa pozrieme na vývoj cien jednotlivých akcií v časovom období od 06.06.2022 do 12.12.2022 predstavujúce 27 týždňov a hodnotu, ktorú nadobúda účelová funkcia v tejto fáze. Dosadením optimálnych hodnôt do pôvodnej optimalizačnej úlohy, pre hodnotu účelovej funkcie v tomto období dostávame

$$g(\mathbf{x}) = \frac{1}{27} \sum_{t=1}^{27} \eta_{t,0} = 0.0160902.$$

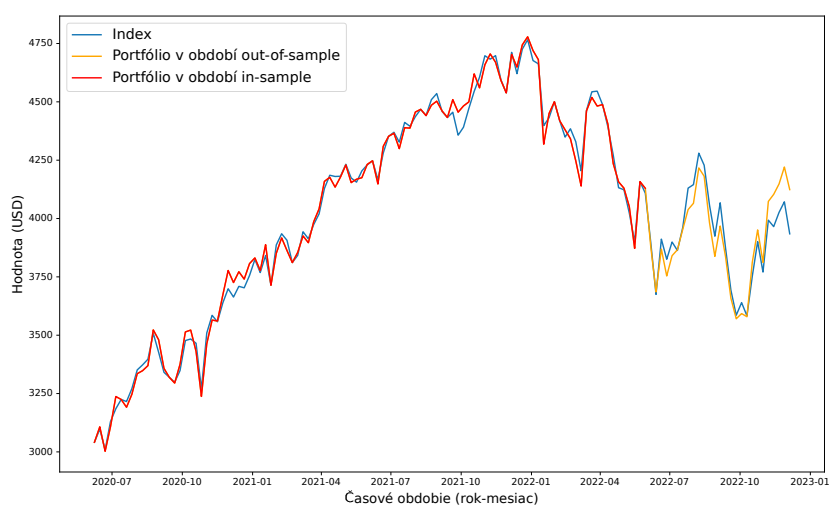
Mieru rizika *CVaR*, ktorú portfólio dosahuje vyčíslime na základe vety 2 pomocou rovnosti

$$\phi_{\alpha}(\mathbf{x}) = \frac{1}{1 - \alpha} \left[ \left( \sum_{k=1}^{25} p_k - \alpha \right) z_{k_{\alpha}} + \sum_{k=26}^{27} p_k z_k \right] = 0.02393,$$

kde  $p_k = \frac{1}{27}$  pre  $k = 1, \dots, 27$  a  $z_{k_{\alpha}}$  zodpovedá miere rizika *VaR* v období *out – of – sample*.



Obr. 4.3: Vývoj indexu S&P 500 a replikačného portfólia v období *out – of – sample*.



Obr. 4.4: Vývoj indexu S&P 500 a replikačného portfólia v období od 08.06.2020 do 12.12.2022.

Z obrázka 4.3 môžeme vidieť pomerne dobrú zhodu vývoja replikačného portfólia vzhľadom k indexu. Dokonca môžeme pozorovať, že portfólio približne od polky desiateho mesiaca roku 2022 nadobúdalo väčšiu hodnotu než samostatný index. Pre lepšiu ukážku sa môžeme pozrieť na obrázok 4.4, ktorý zobrazuje celé časové obdobie od 08.06.2020 do 12.12.2022.

Čo sa týka porovnania hodnôt účelových funkcií ich rozdiel pre jednotlivé fázy zodpovedá rozdielu

$$0.0160902 - 0.0063082 = 0.009782.$$

To znamená, že v období *out - of - sample* bol celkový súčet odchýliek replikačného portfólia od indexu o 0.009782 väčší než v období *in - sample*. A pre hodnoty *CVaR* platí

$$0.02393 - \omega = 0.02393 - 0.02 = 0.00393,$$

z kadiaľ dostávame, že podmienená hodnota v riziku bola o 0.00393 vyššia.

Po prevedení všetkých výpočtov a nahliadnutím na obrázky sme sa dostali k záveru, že na základe historických dát v rozsahu 104 týždňov s použitím 20 akcií je možné v dostatočne dobrej miere replikovať index S&P 500. Tento záver môžeme usúdiť na základe výsledných hodnôt, ktoré portfólio dosahovalo nasledujúcich 27 týždňov v období *out - of - sample*, kde dokonca miestami malo väčšiu hodnotu ako samostatný index.

Je dôležité však poznamenať, že ak by sme chceli predikovať vývoj portfólia na dlhšie časové obdobie, bolo by pravdepodobne potrebné na dosiahnutie podobne dobrých výsledkov použiť historické dát vo väčšom rozsahu.

# Záver

V tejto práci sme sa zoznámili s viacerými pojmami, ktoré sú bežne používané v oblasti financií ako napríklad pojmy portfólio a riziko. Definovali sme ich matematické formulácie, kde sme sa následne zamerali na jednotlivé metódy merania rizika, ktorými boli  $Var$  a  $CVaR$ . Na základe vlastností týchto metód sme odvodili funkciu, ktorá nám umožnila efektívne vypočítať riziká súvisiace s portfóliom. Hlavným cieľom tejto práce bolo skonštruovať portfólio, ktoré bude schopné replikovať zvolený index S&P 500.

Na riešenie tohto problému sme využili poznatky z oblasti optimalizácie a zostavili sme lineárny program s účelovou funkciou minimalizácie rizika. Konkrétne sme sa snažili minimalizovať súčet absolútnych hodnôt odchýliek replikačného portfólia od indexu.

V procese konštrukcie programu sme aplikovali aj odvodenú funkciu pre jednotlivé riziká ako jednu z podmienok minimalizácie. Táto funkcia bola obmedzená hodnotou, ktorá predstavovala maximálne riziko, ktoré sme ochotní tolerovať. Výpočet sme prvotne previedli na historických dátach a následne sme sledovali vývoj indexu a replikačného portfólia v nasledujúcich časových obdobiach.

V praktickej aplikácii sme teda ukázali akou formou vieme narábať s rizikom a využiť ho pri riešení optimalizačnej úlohy v oblasti financií. Výsledky tejto práce môžu byť potenciálne užitočné pre investičné spoločnosti a jednotlivých investorov, ktorí sa zaujímajú o efektívne využitie ich financií.



# Literatúra

DUPAČOVÁ, J. (2002). *Stochastic modeling in economics and finance*. Applied optimization ; 75. Kluwer Academic Publishers, Dordrecht. ISBN 1402008406.

ROCKAFELLAR, R. T. a URYASEV, S. (2000). Optimization of conditional value-at risk. *Journal of Risk*, **3**, 21–41.

ROCKAFELLAR, R. a URYASEV, S. (2002). Conditional value-at-risk for general loss distributions. *Journal of Banking & Finance*, **26**(7), 1443–1471.

# Zoznam obrázkov

1.1	Hodnoty $VaR$ a $CVaR$ v prípade predpokladu normovaného normálneho rozdelenia straty na hladine $\alpha = 0.95$ . . . . .	6
4.1	Priebeh jednotlivých funkcií v závislosti na hodnotách $\omega$ uvedených v tabuľke 4.1. . . . .	15
4.2	Vývoj indexu S&P 500 a replikačného portfólia v období <i>in-sample</i> . . . . .	17
4.3	Vývoj indexu S&P 500 a replikačného portfólia v období <i>out-of-sample</i> . . . . .	18
4.4	Vývoj indexu S&P 500 a replikačného portfólia v období od 08.06.2020 do 12.12.2022. . . . .	18

# Zoznam tabuliek

4.1	Hodnoty funkcií v závislosti na premennej $\omega$ . . . . .	15
4.2	Výsledné rozloženie portfólia pre $\omega = 0.02$ . . . . .	16

# Príloha

Kód použitý na riešenie optimalizačnej úlohy v jazyku Python pomocou balíčka PuLP.

---

```
1 import yfinance as yf
2 import numpy as np
3 import pandas as pd
4 from pulp import *
5
6 #PERIÓDA V KTOREJ PRACUJEME S TÝŽDENNÝMI CENAMI
7 start_day = '2020-6-8' #pondelok
8 end_day = "2022-6-6" #pondelok
9 casovy_interval = "1wk" #týždňový interval
10
11
12 #CENY INDEXU S&P
13 cena_indexu = pd.DataFrame(yf.download("^GSPC", start_day, end_day,
14                             interval = casovy_interval)['Adj Close'])
15
16 #ukážka prvých 5 cien
17 print(cena_indexu.head())
18
19 #ZISKANIE DAT CENY AKCII
20
21 tickers = ['AAPL', 'WMT', 'IBM', 'MU', 'BA', 'AXP', "META", "PEP", "MCD",
22           "NFLX", "ADI", "BAC", "PFE", "KO", "MA", "TSLA", "HPQ", "STT", "CMG", "PSX"]
23
24 # Stiahnutie pondelkových cien akcií upravených o trhové parametre
25 ceny_akcii = pd.DataFrame(yf.download(tickers, start_day, end_day,
26                                     interval = casovy_interval)['Adj Close'])
27
28 #ukážka prvých 5 riadkov
29 print(ceny_akcii.head())
30
31 #LINEARNY PROGRAM
32
33 #premenné
34 T= ceny_akcii.shape[0] #čas sa rovná počtu riadkov
35 v= 1000 #počiatočná investícia
36 n= ceny_akcii.shape[1] #počet akcií pre indexy j= 1,...,n
```

```

37 alpha = 0.95 #hladina spolahlivosti
38 omega = 0.02 #omedzenie pre hodnotu CVaR
39 theta = v/ cena_indexu.iloc[0,0] #počet jednotiek indexu
40 pocet_x = np.arange(0,n).tolist()
41 casy_t =np.arange(0,T).tolist()
42
43 #MODEL
44
45 model = LpProblem(name="Optimalizacia_Portfolia", sense=LpMinimize)
46
47 #rozhodovacie premenné
48
49 x = LpVariable.dicts("x", list(range(n)), lowBound=0)
50 zeta = LpVariable("zeta",lowBound=0)
51 u = LpVariable.dicts("u", list(range(T)), lowBound=0)
52 eta =LpVariable.dicts("eta", list(range(T)), lowBound=0)
53
54
55 #účelová funkcia
56 model += lpSum([eta[t] for t in range(T)]) / T
57
58 #obmezenia
59 model += (lpSum([ceny_akcii.iloc[0,j] * x[j] for j in range(n)]) == v)
60 model += (zeta + 1/((1- alpha)*T)* lpSum([u[t] for t in range(T)]) <= omega)
61 for t in range(T):
62     model += (((theta * cena_indexu.iloc[t,0] - lpSum([ceny_akcii.iloc[t,j] *
63         x[j] for j in range(n)])) / (theta * cena_indexu.iloc[t,0]))
        ↪ <= eta[t])
64     model += (((-1) * ((theta * cena_indexu.iloc[t,0] -
        ↪ lpSum([ceny_akcii.iloc[t,j] *
65         x[j] for j in range(n)])))/ (theta * cena_indexu.iloc[t,0] )))
        ↪ <= eta[t])
66     model += (((theta * cena_indexu.iloc[t,0] - lpSum([ceny_akcii.iloc[t,j] *
67         x[j] for j in range(n)])))/ (theta * cena_indexu.iloc[t,0] ) -
        ↪ zeta) <= u[t])
68
69
70
71 model.solve()
72
73 print("Minimálna hodnota:", value(model.objective)) #Hodnota účelovej funkcie
74
75 x_values = []
76 for v in model.variables(): #Optimálne hodnoty
77     if v.name.startswith("x"):
78         x_values.append((v.name, v.varValue))
79
80 x_values_sorted = sorted(x_values, key=lambda x: int(x[0].split('_')[1]))

```

```

81 print("tabuľka hodnôt ")
82 tabulka = pd.DataFrame(x_values_sorted, columns=["Variable", "Value"], index=
↳ tickers)
83 print(tabulka) # v práci značíme premenné (x~*)_1,...,(x~*)_20
84
85 ##### OUT - OF - SAMPLE
↳ #####
86 #out of sample data
87 start_day2= end_day #pre čisto out of sample
88 end_day2 = "2022-12-12" #pondelok
89 cena_indexuofs = pd.DataFrame(yf.download("^GSPC",start_day,end_day2,
90 interval = casovy_interval)['Adj Close']) #celé časové
↳ obdobie
91 ceny_akciiofs = pd.DataFrame(yf.download(tickers,start_day,end_day2,
92 interval = casovy_interval)['Adj Close'])#celé časové
↳ obdobie
93
94 cena_indexuofs2 = pd.DataFrame(yf.download("^GSPC",start_day2,end_day2,
95 interval = casovy_interval)['Adj Close']) #iba ofs
96 ceny_akciiofs2 = pd.DataFrame(yf.download(tickers,start_day2,end_day2,
97 interval = casovy_interval)['Adj Close']) #iba ofs
98 Tofs = ceny_akciiofs2.shape[0] #časové obdobie out - of - sample
99 hodnoty_x =(tabulka.iloc[:,1])
100
101
102 #Hodnoty funkcií out of sample
103 hodnoty_eta_ofs = [] #hodnoty odýchlíek
104 for i in range(Tofs):
105     etat = (theta * cena_indexuofs2.iloc[i,0] -
↳ np.matmul(np.array(ceny_akciiofs2.iloc[i,:]),
106 np.array(hodnoty_x)))/ (theta * cena_indexuofs2.iloc[i,0])
107     hodnoty_eta_ofs.append(etat)
108
109 var_ofs= pd.DataFrame(hodnoty_eta_ofs).quantile(alpha)
110 print("VaR Out of sample ", var_ofs)
111
112
113 hodnoty_z =sorted(hodnoty_eta_ofs)
114 hodnoty_z_nad_kvantilom = []
115 for i in hodnoty_z:
116     if i > float(var_ofs):
117         hodnoty_z_nad_kvantilom.append(i)
118
119 print("Účelová funkcia out of sample")
120 print((1/Tofs)* sum(np.abs(hodnoty_eta_ofs)))
121 print("CVaR out of sample podľa vety 2 ")
122 print(1/(1-alpha)*(((25/27)- alpha)*var_ofs +
123 (1/27)*(sum(hodnoty_z_nad_kvantilom))))

```

## Výstup kódu.

```

[*****100%*****] 1 of 1 completed
Adj Close
Date
2020-06-08 3041.310059
2020-06-15 3097.739990
2020-06-22 3009.050049
2020-06-29 3130.010010
2020-07-06 3185.040039
[*****100%*****] 20 of 20 completed
      AAPL      ADI      AXP      ...      STT      TSLA      WMT
Date      ...
2020-06-08 83.273621 112.690491 97.660835 ... 57.603680 62.352001 112.760124
2020-06-15 85.957664 114.374985 96.950096 ... 59.684418 66.726669 114.780876
2020-06-22 86.918701 112.176575 89.727341 ... 55.240028 63.982666 113.315582
2020-06-29 89.494568 115.383781 90.601372 ... 57.612804 80.577332 114.167946
2020-07-06 94.304688 118.486313 89.951149 ... 59.014786 102.976669 125.152817

[5 rows x 20 columns]
Welcome to the CBC MILP Solver
Version: 2.10.3
Build Date: Dec 15 2019

command line -
↳ /Users/andreapolakovicova/venv/lib/python3.8/site-packages/pulp/solverdir/cbc/osx/64/cbc
↳ /var/folders/1f/y5fj1q954p3627tp53_shsw0000gn/T/4d354254868d45349399cde2b3a8835e-pulp.mps
↳ timeMode elapsed branch printingOptions all solution
↳ /var/folders/1f/y5fj1q954p3627tp53_shsw0000gn/T/4d354254868d45349399cde2b3a8835e-pulp.sol
↳ (default strategy 1)
At line 2 NAME      MODEL
At line 3 ROWS
At line 319 COLUMNS
At line 7205 RHS
At line 7520 BOUNDS
At line 7521 ENDATA
Problem MODEL has 314 rows, 229 columns and 6781 elements
Coin0008I MODEL read with 0 errors
Option for timeMode changed from cpu to elapsed
Presolve 314 (0) rows, 229 (0) columns and 6781 (0) elements
Perturbing problem by 0.001% of 0.012714866 - largest nonzero change 5.0546408e-06 ( 0.05187479%)
↳ - largest zero change 5.0376604e-06
0 Obj 0 Primal inf 188.92781 (209)
31 Obj 0.00090556942 Primal inf 40.944698 (126)
78 Obj 0.0046607834 Primal inf 8.6433813 (118)
125 Obj 0.0059080194 Primal inf 0.83329501 (51)
161 Obj 0.006314715
Optimal - objective value 0.0063082578
Optimal objective 0.006308257763 - 161 iterations time 0.012
Option for printingOptions changed from normal to all
Total time (CPU seconds):      0.01 (Wallclock seconds):      0.02

Minimálna hodnota: 0.00630825776355769
tabuľka hodnôt
Variable      Value
AAPL      x_0 0.940105
WMT      x_1 0.919989
IBM      x_2 1.476853
MU      x_3 0.000000
BA      x_4 0.000000
AXP      x_5 0.025225
META      x_6 3.865161
PEP      x_7 1.277447
MCD      x_8 0.000000
NFLX      x_9 0.062037
ADI      x_10 0.000000
BAC      x_11 0.297218
PFE      x_12 0.000000
KO      x_13 0.306778
MA      x_14 0.065141
TSLA      x_15 2.552534
HPQ      x_16 0.272761
STT      x_17 0.000000

```

```
CMG      x_18  0.000000
PSX      x_19  1.303414
[*****100%*****] 1 of 1 completed
[*****100%*****] 20 of 20 completed
[*****100%*****] 1 of 1 completed
[*****100%*****] 20 of 20 completed
VaR Out of sample 0 0.022205
Name: 0.95, dtype: float64
Účelová funkcia out of sample
0.016090249438966323
CVaR out of sample podľa vety 2
0 0.02393
Name: 0.95, dtype: float64

Process finished with exit code 0
```