

# 1 Chování v prostředí nejistoty

## 1.1 Teorie očekávaného užitku

Trocha opakování z mikroekonomie

- V deterministickém světě – spotřebitelovy preference jsou popsány dle seřazení koše statků
- V prostředí nejistoty – preference spotřebitele lze popsat podle seřazení jednotlivých loterií (her), podle očekávané hodnoty užitku
- 1 statek, spotřeba  $c$ , užitková funkce  $u(c)$
- 2 loterie,  $i = A, B$ .
- Loterie  $i$  přinese  $c_i^1$  jednotek spotřeby s pravděpodobností  $p_i$  a  $c_i^2$  jednotek spotřeby s pravděpodobností  $(1 - p_i)$ , kde  $0 < p_i < 1$ .

### Definice

**Očekávaný užitek** z loterie  $i$  (součet pravděpodobnosti x užitek)

$$p_i u(c_i^1) + (1 - p_i) u(c_i^2)$$

Spotřebitel striktně preferuje loterii A před B

$$p_A u(c_A^1) + (1 - p_A) u(c_A^2) > p_B u(c_B^1) + (1 - p_B) u(c_B^2)$$

preferuje B před A pokud  $<$  a je indiferentní pokud  $=$ .

## 1.2 Chování v prostředí rizika

Spotřebitel, (který maximalizuje užitek) je *rizikově averzní*, když je jeho užitková funkce (striktně) konkávní. Pokud je  $u(c)$  striktně konkávní, implikuje to Jensenovu nerovnost

$$u[E(c)] \geq E[u(c)] \tag{1}$$

kde  $E$  je operátor očekávání (můžete chápat jako střední hodnotu). Jensenova nerovnost nám říká, že spotřebitel preferuje očekávanou hodnotu loterie (s jistotou) před loterií samotnou. Je rizikově averzní – je ochoten zaplatit za vyhnutí se riziku.

### Něco jako důkaz

Pro milovníky mikroekonomie, ostatní můžou přeskocit. Obrázek viz Williamson.

Pokud spotřebitel obdrží konstantní spotřebu  $\bar{c}$  s jistotou, tak potom (1) platí jako rovnost. V případě, že spotřeba je náhodná veličina, potom platí (1) se striktní nerovností.

Vezmeme tečnu k funkci  $u(c)$  v bodě  $(E(c), u[E(c)])$ . Tečna je dána funkcí

$$g(c) = \alpha + \beta c$$

kde  $\alpha$  a  $\beta$  jsou konstanty a pro bod  $E[c]$  platí

$$\alpha + \beta E[c] = u(E[c]) \quad (2)$$

Funkce  $u(c)$  je striktně konkávní, pak máme (jako na obrázku)

$$\alpha + \beta c \geq u(c) \quad (3)$$

pro  $c \geq 0$  a se striktní nerovností, pokud  $c \neq E(c)$ .

Dále pro striktní nerovnost. Operátor očekávání je lineární operátor, můžeme aplikovat očekávání rovnice (3) a vzhledem k tomu, že  $c$  je náhodná veličina dostaneme

$$\alpha + \beta E[c] > E[u(c)]$$

a použitím rovnice (2) dostaneme

$$u[E(c)] > E[u(c)]$$

Ukázali jsme, že Jensenova nerovnost platí.

### Příklad

Loterie přinese spotřebiteli  $c_1$  s pravděpodobností  $p$  a  $c_2$  s s pravděpodobností  $1 - p$ . kde  $0 < p < 1$  a  $c_2 > c_1$ .

$$u[pc_1 + (1 - p)c_2] > pu(c_1) + (1 - p)u(c_2)$$

Užitek z očekávané hodnoty hry  $u[E(c)] >$  očekávaný užitek ze hry  $E[u(c)]$

Body na úsečce AB označují očekávaný užitek agenta pro danou pravděpodobnost  $p$ . Jensenova nerovnost je fakt, že AB leží pod funkcí  $u(c)$ . Vzdálenost DE je disutilita spojená s rizikem. Vzdálenost roste s větším zakřivením užitkové funkce – větší averze k riziku.

#### 1.2.1 Měření averze k riziku

Při maximalizaci očekávaného užítku jsou výběry dělané v podmínkách nejistoty invariantní (neměnné) při afinních transformacích užitkových funkcí. Máme užitkovou funkci

$$v(c) = \alpha + \beta u(c)$$

kde  $\alpha, \beta$  jsou konstanty,  $\beta > 0$ . Pak platí

$$E[v(c)] = \alpha + \beta E[u(c)]$$

protože  $E$  je lineární operátor. Z toho vyplývá, že loterie jsou seřazeny stejným způsobem, ať uvažujeme funkci  $u(c)$  nebo transformovanou  $v(c)$ .

Jakékoliv měřítko averze vůči riziku by mělo zahrnovat druhou derivaci  $u''(c)$ , protože averze roste, když se zvyšuje zakřivení funkce. Ale, pro transformovanou funkci  $v(c)$  máme

$$v''(c) = \beta u''(c)$$

takže druhá derivace není invariantní vůči afinním transformacím (je tam ta  $\beta$ ). Takže samotná druhá derivace k měření nestačí. Měřítko, které je invariantní vůči afinním transformacím je:

#### 1.2.2 Koeficient absolutní averze vůči riziku

$$ARA(c) = -\frac{u''(c)}{u'(c)}$$

např. funkce, která má konstantní ARA pro všechna  $c$  je

$$u(c) = 1 - e^{-\alpha c}$$

kde  $\alpha > 0$  a koeficient  $ARA(c) = \alpha$  vzhledem k  $c$ . (empiricky + experimentálně, spíše užitková funkce s klesající ARA)

### 1.2.3 Koeficient relativní averze vůči riziku

$$RRA(c) = -c \frac{u''(c)}{u'(c)}$$

např. funkce s konstantní RRA (Constant Relative Risk Aversion, CRRA) pro všechna  $c$  je

$$u(c) = \frac{c^{1-\theta} - 1}{1-\theta}$$

kde  $\theta > 0$  a koeficient  $RRA(c) = \theta$  vzhledem k  $c$ ,  $ARA(c)$  je klesající vzhledem k  $c$ .

U mezičasového výběru, mluvíme o tzv. ISO elastické funkci, elasticita intertemporální substituce  $\sigma = \frac{1}{\theta}$ .

Hodně používaná specifikace, speciální případ CRRA fce je logaritmická funkce  $\ln c$ , (koeficient  $RRA(c) = 1$ ). Důchodový a substituční efekt se vykrátí.

#### Rizikově neutrální spotřebitel

Užitková funkce je lineární ve spotřebě  $u(c) = \beta c$ ,  $\beta > 0$ . Riziko zde nehraje žádnou roli.

$$ARA(c) = RRA(c) = 0$$

#### Anomálie

Teorie očekávaného užitku – vysvětluje chování lidí v prostředí rizika (např. při nákupu pojištění). Teorie se běžně v ekonomii používá, ale existují určité jevy, které nejsou s touto teorií konzistentní, např. Allaisův paradox.

Nejprve výběr mezi loterií A a B. A dává 1 milión s jistotou, B dává 5 miliónů s pravděpodobností 0.1, 1 mil s pravděpodobností 0.89 a nebo 0 miliónů s pravděpodobností 0.01. Potom výběr mezi loterií C a D. C dává 1 milión s pravděpodobností 0.11 nebo 0 miliónů s pravděpodobností 0.89. a loterie D dává 5 miliónů s pravděpodobností 0.1 nebo 0 miliónů s pravděpodobností 0.9.

**Cíl:** Jak vypočítat hodnotu, že se nacházíme v daném stavu? (Markovské procesy, dynamické programování a iterace hodnotové funkce)

## 2 Modelování nejistoty

### Formální zápis nejistoty

Máme proces  $s^t$ .  $s_t$  je stav (událost), množina stavů je  $S = \{s_1, s_2, \dots, s_T\}$ . Množina je konečná (např. počasí - jasno, polojasno, oblačno, zataženo, déšť, sníh.)

Náhodný proces (to, že jsem v nějakém stavu) může být náhodné (nezávislé) nebo závislé. Jak to specifikujeme, záleží na nás. Budeme používat tyto formy:

- Proces je *iid* (prvky jsou navzájem nezávislé a mají stejné rozdělení). Je to čistá náhoda (hod mincí, hod kostkou)
- Proces  $s^t$  je homogenní Markovský řetězec (Markov chain, MC).

Vlastnosti MC:

- Proces (řetězec) se pohybuje ze stavu do stavu. Každý pohyb se nazývá krok.
- Pokud je řetězec ve stavu  $i$ , tak se přeneseme do stavu  $j$  s pravděpodobností  $p_{ij}$
- $p_{ij}$  je *podmíněná* pravděpodobnost (nezávislá na ničem jiném, krom toho, že jsme ve stavu  $i$ , minulé stavy jsou irelevantní)

$$p_{ij} = \text{Prob}(s_{t+1} = s_j | s_t = s_i) = \text{Prob}(s_{t+1} = s_j | s_t = s_i, s_{t-1} = s_n, \dots, s_1 = s_1)$$

$p_{ij}$  se také nazývá *přenosová* pravděpodobnost. Proces může zůstat ve stavu ve kterém je, a to se stane s pravděpodobností  $p_{ii}$

Matice přenosových pravděpodobností je *přenosová matice*.

$$P = \begin{bmatrix} p_{11} & p_{12} \\ p_{21} & p_{22} \end{bmatrix}$$

např.

$$P = \begin{bmatrix} 0.90 & 0.10 \\ 0.40 & 0.60 \end{bmatrix}$$

- Řádek  $i$  udává pravděpodobnosti při pohybu ze stavu  $i$  (dnes) do všech možných stavů (zítra). Suma po řádku dává dohromady 1 (musíme někde skončit).
- Sloupec  $j$  udává pravděpodobnost, že skončíme ve stavu  $j$  (za podmínky, že jsme vyšli z arbitrárně zvoleného stavu  $i$ )

Jak vypočítat pravděpodobnost stavu někdy v budoucnu? Potřebujeme znát počáteční stav a přenosovou matici.

## Příklad s počasím

Pravděpodobnost, že proces je dnes ve stavu  $i$  a bude ve stavu  $j$  za  $n$  dnů označíme  $p_{ij}^{(n)}$

Jaká bude pravděpodobnost, že bude za 2 dny zataženo, když je dneska zataženo? Přenosová matice

$$P = \begin{bmatrix} 0.50 & 0.25 & 0.25 \\ 0.25 & 0.50 & 0.25 \\ 0.50 & 0.50 & 0.00 \end{bmatrix}$$

Počasi dnes je zataženo, představováno vektorem

$$x^{(0)} = [0 \quad 1 \quad 0]$$

Počasi zítra (jeden den ode dneška) je

$$x^{(1)} = x^{(0)}P$$

Počasi pozítří (dva dny ode dneška) je

$$\begin{aligned} x^{(2)} &= x^{(1)}P \\ x^{(2)} &= x^{(0)}PP = x^{(0)}P^2 \\ x^{(n)} &= x^{(0)}P^n \end{aligned}$$

V limitě

$$\lim_{n \rightarrow \infty} x^{(n)} = \lim_{n \rightarrow \infty} x^{(0)}P^n$$

To, co jsme odvodili pro limitní případ výše je *nepodmíněná* pravděpodobnost. Pravděpodobnost, že skončíme v nějakém stavu, když nevíme nic o předchozích stavech (jak často pozorujeme stav  $i$ , nezávisle na počátečních podmínkách).<sup>1</sup>

Matice  $P^\infty$  má všechny řádky jsou stejné, na počátečním rozdělení nezáleží.

**Poznámka:** Markovské řetězce zajistí při simulacích větší perzistentenci (pomáhají replikovat data), ale tato persistence není vysvětlena z ekonomického hlediska. Nevíme, proč k ní dochází.

## 3 Dynamické programování a Bellmanova rovnice

Optimalizační problémy (domácnosti, firem), které řešíme jsou **stacionární** – jsou nezávislé na čase (produkční funkce je stejná, rozpočtové omezení, chování domácností a firem rovněž atd.). Problém se v čase nemění, jediné co se mění jsou počáteční podmínky – hodnota proměnných určených v minulém období (rozhodnutím nebo náhodou).

Tyto problémy můžeme řešit rekurzivně pomocí nástrojů **dynamického programování**.

Co to je? Hledáme *hodnotovou funkci* a *rozhodovací pravidlo*.

- **Rozhodovací pravidlo** (*decision rule* někdy i *policy function*) nám říká, co máme udělat s proměnnými během tohoto období na základě počátečních podmínek (daných minulostí). Např. kolik investovat a kolik spotřebovat na základě daného stavu kapitálu.
- **Hodnotová funkce** je např. hodnota diskontovaného užítku při maximalizaci v nekonečném horizontu (když byl maximalizační problém vyřešen) nebo hodnota firmy (daná současnou hodnotou cash-flow).

---

<sup>1</sup>Když je každý prvek matice  $P$  je kladný, pak existuje jediné nepodmíněné rozdělení pravděpodobnosti.

## Bellmanova rovnice

Takhle bude vypadat příště

$$v(k_t) = \max_{k_{t+1}} \{u(k_t, k_{t+1}) + \beta E v(k_{t+1})\}$$

nebo v rekursivní notaci

$$v(k) = \max_{k'} \{u(k, k') + \beta E v(k')\}$$

$k$  je současný stav,  $k'$  je stav o krok vpřed.

Dneska budeme mít trochu jednodušší případ:

$$v(s_t) = c(s_t) + \beta P v(s_{t+1})$$

**Příklad** Jaká je čistá současná hodnota budoucího cash-flow firmy? Firma se může nacházet ve třech stavech: dobrý (Good), normální (Normal) a špatný (Bad). Hodnota cash-flow podle stavů je: pro Good 20 mil., pro Normal 10 mil. a pro Bad  $-5$  mil.

Matrice přenosových pravděpodobností, která může být zjištěna z historických dat, vypadá následovně

$$P = \begin{bmatrix} .55 & .40 & .05 \\ .35 & .55 & .10 \\ .20 & .20 & .60 \end{bmatrix}$$

Diskontní míra je  $r$ , nejprve deterministický případ. Bellmanova rovnice

$$v(s_t) = c(s_t) + \frac{1}{1+r} v(s_{t+1})$$

Stochastický případ – známe  $c(s_t)$ , ale budoucnost je nejistá (použijeme očekávání).

$$v(s_t) = c(s_t) + \frac{1}{1+r} E_t v(s_{t+1})$$

Víme, že nejistota je Markovská, takže

$$v(s_t) = c(s_t) + \frac{1}{1+r} P v(s_{t+1})$$

Známe možné stavy  $s(\cdot)$ , funkci  $c(\cdot)$ , parametr  $r$  a přenosovou matici  $P$ . Jediné, co neznáme je funkce  $v(\cdot)$ . Jak ji najít?

Použijeme postup zvaný **iterace hodnotové funkce** (value function iteration, VFI). Vezmeme počáteční hodnotovou funkci  $v_0(s_t)$  např. vektor 0 a řešíme iterací.

$$v_{i+1}(s_t) = c(s_t) + \frac{1}{1+r} P v_i(s_{t+1})$$

Iterujeme dokud to nezkonverguje, tj.

$$\|v_{i+1}(s_t) - v_i(s_t)\| < \epsilon$$

kde  $\epsilon$  je malé číslo.