

Řešená cvičení: NMAI059 Pravděpodobnost a statistika 1

Karel Král, TODO

17. března 2021

Tento text není určen k šíření. Všechny chyby v tomto textu jsou samozřejmě záměrné. Reportujte je prosím na adresu kralka@iuuk.mff.cuni

Obsah

1 Zadání	5
1.1 1. Cvičení	5
1.2 2. Cvičení	6
1.3 3. Cvičení	8
2 Tahák	11
2.1 Pravděpodobnostní prostor	11
2.2 Podmíněná pravděpodobnost	11
2.3 Bayesova věta	12
2.4 Nezávislé jevy	12
3 Řešení	13
3.1 1. Cvičení	13
3.2 2. Cvičení	31
3.3 3. Cvičení	45

Kapitola 1

Zadání

1.1 Cvičení

1. Úvodní informace:

- (a) Slyšíte mě všichni dobře?
- (b) Literatura.
- (c) Pravidla zápočtu (domácí úkoly).

Řešení: [1](#)

2. Jak se generuje náhoda programem.

- Python3
- C++
- R

Řešení: [2](#)

3. Připomeňte si definici pravděpodobnostního prostoru (Definice [2.1](#)). Určete, co je

- *množina elementárních jevů (sample space)*, tedy množina Ω ,
- *prostor jevů (event space)*, tedy množina $\mathcal{F} \subseteq \mathcal{P}(\Omega)$,
- *pravděpodobnost (probability)*, tedy funkce $\text{Pr}: \mathcal{F} \rightarrow [0, 1]$

pro následující příklady:

- (a) Hod spravedlivou alkoholovou trojhrannou tužkou (není to kostka kvůli popisu prostoru jevů):

```
import random
drink = random.choice([
    "světlé pivo",
    "tmavé pivo",
    "slivovice",
])
```

- (b) Uniformně náhodné číslo z intervalu $[0, 1)$.

```
import random
print(random.random())
```

Řešení: **3**

4. Dokažte, že $\Pr[A \cup B] = \Pr[A] + \Pr[B] - \Pr[A \cap B]$.

Řešení: **4**

5. Zopakujte si základní kombinatoriku:

- Kolik je různých permutací množiny $\{A, B, C\}$?
- Kolik různých slov skládajících se z písmen $\{A, B\}$ má délku 3?
- Kolik různých podmnožin množiny $\{A, B, C, D, E\}$ má velikost 3?
- Kolik různých kombinací s opakováním z množiny $\{A, B, C, D, E\}$ velikosti 3?

Řešení: **5**


6. Jaká je pravděpodobnost, že při hodu šesti rozlišitelných spravedlivých šestistěnných kostek padnou aspoň na třech kostkách aspoň tři? Jaký je množina elementárních jevů, prostor jevů a pravděpodobnost?

Řešení: **6**

7. Necht' Ω jsou všechny permutace prvních 100 přirozených čísel, prostor jevů jsou všechny podmnožiny Ω a každý elementární jev je stejně pravděpodobný. Označme jev A_j že náhodně zvolená permutace $\pi \in \Omega$ splňuje $\pi(j) = j$ (pro $1 \leq j \leq 100$). Jsou A_1, A_2 nezávislé jevy?

Řešení: **7**

8. Každý obdélník na obrázku je součástka, která se může porouchat s pravděpodobností p . Přesněji řečeno porucha znamená, že skrz ní neteče proud. Poruchy součástek jsou na sobě nezávislé. Jaká je pravděpodobnost, že stále poteče proud mezi dvěma puntíky.



Řešení: **8**

1.2 Cvičení

1. Házíme cinknutou mincí – hlava padne s pravděpodobností $p \in [0, 1)$, orel padne s pravděpodobností $1 - p$. Házíme opakovaně dokud nepadne hlava.
 - (a) Jak vypadá pravděpodobnostní prostor?
 - (b) Jaká je pravděpodobnost, že hodíme právě třikrát (n -krát)?
 - (c) Jaká je pravděpodobnost, že hodíme nejvýš třikrát (n -krát)?
 - (d) Jaká je pravděpodobnost, že hodíme lišekrát?

(e) Simulujte předchozí.

Řešení: **1**

2. Hodíme cinknutou korunou (panna s pravděpodobností $p_1 \in [0, 1]$) a cinknutou dvoukorunou (panna s pravděpodobností $p_2 \in [0, 1]$). Oba hody jsou na sobě nezávislé.

(a) Určete pravděpodobnostní prostor.

(b) Připomněte si definici podmíněné pravděpodobnosti (Definice **2.2**).

(c) Spočítejte pravděpodobnost $\Pr[\text{na obou padne panna} \mid \text{na koruně padne panna}]$.

(d) Spočítejte pravděpodobnost $\Pr[\text{na obou padne panna} \mid \text{padne aspoň jedna panna}]$.

(e) Simulujte:

Řešení: **2**

3. Na louce rostou květiny, které mají buď bílé nebo červené květy. Náhodná květina má bílý květ s pravděpodobností $\Pr[B] = 0.6$, tedy pravděpodobnost že náhodná květina má červený květ je $\Pr[C] = 0.4$. Pravděpodobnost že červená květina je jedovatá je $\Pr[J \mid C] = 0.25$. Pravděpodobnost že bílá květina je jedovatá je $\Pr[J \mid B] = 1/12$. Snědli jsme náhodnou rostlinu a je nám zle, jaká je pravděpodobnost, že ta rostlina měla červený květ?

Řešení: **3**

4. V první krabici je b bílých míčků a c červených míčků, ve druhé krabici také. Napřed vytáhneme jeden míček z první krabice (uniformně náhodně) a dáme ho do druhé krabice. Pak vytáhneme jeden míček z druhé krabice (uniformně náhodně). Jaká je pravděpodobnost, že míček vytažený z druhé krabice je červený?

(a) Navrhněte vhodný pravděpodobnostní prostor.

(b) Spočítejte tu pravděpodobnost, kterou jsme chtěli.

(c) Simulujte.

Řešení: **4**

5. Tento příklad je vymyšlený, zejména čísla nesedí a reálný svět je malinko složitější (tím se ještě budeme zabývat), ale informace v něm nejsou daleko od pravdy. V zemi nám řídí nemoc C .

- Prostor elementárních jevů (sample space) Ω jsou všichni občané.
- Označíme $C^+ \subseteq \Omega$ množinu všech lidí, kteří dnes mají aktivní nemoc C , označíme $C^- = \Omega \setminus C^+$ zdravé lidi.
- Umíme uniformně náhodně samplovat lidi, tedy $\forall \omega \in \Omega: \Pr[\{\omega\}] = 1/|\Omega|$ (tady ω je jeden člověk).
- Test nám pro libovolného člověka odpoví že je člověk zdravý nebo nemocný. Značme $T^+ \subseteq \Omega$ množinu lidí pro které test odpoví, že jsou nemocní. Značme $T^- = \Omega \setminus T^+$ množinu lidí pro které test odpoví, že jsou zdraví. Ale není to tak jednoduché, v příbalovém letáku testu se píše:

– *Sensitivity*: (true positive) $\Pr[T^+ \mid C^+] = 0.9$

– *Specificity*: (true negative) $\Pr[T^- \mid C^-] = 0.8$

z tohoto můžeme odvodit chyby:

– False positive = false alarm = type I error

$$\Pr[T^+ \mid C^-] = 1 - \Pr[T^- \mid C^-] = 0.2$$

– False negative = miss = type II error

$$\Pr[T^- | C^+] = 1 - \Pr[T^+ | C^+] = 0.1$$

- Provedli jsme jeden test u každého z uniformně náhodně vybraných 50000 lidí a pozitivních testů vyšlo 1000. Tedy předpokládáme, že $\Pr[T^+] = \frac{1000}{50000} = \frac{1}{50} = 0.02$ (jak moc je tento předpoklad oprávněný budeme zkoumat nadále).
 - Zajímá nás $\Pr[C^+]$ (vynásobeno 100 nám dá počet nemocných v procentech).
- (a) V čem se toto liší od reality?
 - (b) Spočítejte $\Pr[C^+]$.
 - (c) Co se stalo špatně?
 - (d) Jak by vyšlo předchozí kdyby $\Pr[T^+ | C^+] = 0.99$, $\Pr[T^- | C^-] = 0.98$, $\Pr[T^+] = 0.2$?
 - (e) Simulujte předchozí.

Řešení: **5**

6. V šuplíku mám $b \in \mathbb{N}$ párů bílých, $c \in \mathbb{N}$ párů černých ponožek a $s \in \mathbb{N}$ párů sepraných ponožek. Potřebuju si vytáhnout čtyři páry černých ponožek (jedu na prodloužený víkend tancovat). Když vytáhnou čtyři náhodné páry ponožek (mám je napárované v šuplíku), jaká je pravděpodobnost, že všechny budou černé?

Řešení: **6**

1.3 Cvičení

1. Rozmysleme si, proč nezávislost více jevů není to samé jako nezávislost po dvou.
 - (a) Najděte jevy A, B, C takové, že jevy jsou po dvou nezávislé, ale $\Pr[A \cap B \cap C] \neq \Pr[A] \Pr[B] \Pr[C]$.
 - (b) Najděte jevy A, B, C takové, že $\Pr[A \cap B \cap C] = \Pr[A] \Pr[B] \Pr[C]$, ale jevy nejsou po dvou nezávislé.

Řešení: **1**

2. Házíte dvěma rozlišitelnými kostkami.
 - (a) Určete vhodný pravděpodobnostní prostor.
 - (b) Spočítejte pravděpodobnost, že aspoň na jedné kostce padla šestka, když víte jaký součet padl.

Řešení: **2**

3. V truhle je sto mincí. Z nich 99 je normálních, ale jedna má na obou stranách orla.
 - (a) Určete vhodný pravděpodobnostní prostor.
 - (b) Vytáhneme náhodnou minci a šestkrát s ní hodíme, pokaždé padne orel. Jaká je pravděpodobnost, že jsme si vytáhli dvouorlovou minci? (Zkuste napřed odhadnout, pak spočítat.)
 - (c) Simulujte.

Řešení: **3**

4. Připomeňme co je náhodná veličina a její střední hodnota.
Co kdyby pravděpodobnost kostky nebyla uniformní?

Řešení: [4](#)

5. Na stole jsou dvě obálky, v jedné je k korun, ve druhé ℓ korun ($k, \ell \in \mathbb{N}$). Můžete otevřít jednu obálku a na základě sumy v ní se rozhodnout jestli si necháte tu otevřenou nebo si vezmete tu druhou (nehledě na to, kolik je v té druhé). Umíte vymyslet způsob jak odejít s tou s větším obnosem s pravděpodobností ostře větší než jedna polovina? Určete střední hodnotu výhry.

Řešení: [5](#)

6. Spočítejte střední počet porovnání quick-sortu:

```
from random import randint

def partition(arr, begin, end):
    pivot_i = randint(begin, end - 1)
    (arr[pivot_i], arr[end-1]) = (arr[end-1], arr[pivot_i])
    pivot = arr[end - 1]
    i = begin
    for j in range(begin, end):
        if arr[j] < pivot:
            (arr[i], arr[j]) = (arr[j], arr[i])
            i += 1
    (arr[i], arr[end-1]) = (arr[end-1], arr[i])
    return i

def quick_sort(arr, begin, end):
    if end <= begin:
        return
    p = partition(arr, begin, end)
    quick_sort(arr, begin, p)
    quick_sort(arr, p+1, end)
```

- (a) Uvědomte si, že každá dvě čísla porovnáte nejvýš jednou (pokud se žádné číslo neopakuje). Pro jednoduchost budeme předpokládat, že se čísla neopakují (jinak bychom museli mluvit o jejich pozici v utříděném poli).
- (b) Vytvořte vhodný pravděpodobnostní prostor.
- (c) Definujte náhodnou proměnnou určující počet porovnaných dvojic, vyjádřete ji jako součet jednodušších a použijte větu o linearitě střední hodnoty.
- (d) S jakou pravděpodobností provede quick-sort aspoň $10n \ln(n)$ porovnání?
- Sčítáme n kladných reálných čísel $a_1, a_2, \dots, a_n \in [0, \infty)$. Víme, že

$$\sum_{i=1}^n a_i = S$$

Pro kolik z těch čísel platí $a_j \geq 5S/n$?

- Co kdybychom ta čísla sčítali váženě? Tedy formálně: mějme náhodnou proměnnou o které víme $\Pr[X = j]$ pro $j \in \{1, 2, \dots, m\}$ (kde pro jednoduchost předpokládáme $\sum_{j=1}^m \Pr[X = j] = 1$, tedy že X má hodnoty $1, 2, \dots, m$). Víme $\mathbb{E}[X] = \sum_{j=1}^m j \Pr[X = j] = S$. Jaká je pravděpodobnost $\Pr[X \geq 5S]$?
- Gratuluji, vymysleli jste Markovovu nerovnost.

- Často bývá mnohem jednodušší použít Markovovu nerovnost než přímo počítat pravděpodobnost. Občas můžeme dostat i silnější odhady pomocí Čebyševovy nebo Černovovy nerovnosti. Na to budeme potřebovat rozptyl a další znalosti o náhodných proměnných.

Řešení: 6

Kapitola 2

Tahák

2.1 Pravděpodobnostní prostor

Definice. Pravděpodobnostní prostor je trojice $(\Omega, \mathcal{F}, \Pr)$, kde

1. Ω je množina elementárních jevů (*sample space*) (je to množina)
2. $\mathcal{F} \subseteq \mathcal{P}(\Omega)$ je prostor jevů (*event space*) (je to množina podmnožin Ω , jednotlivé prvky \mathcal{F} nazýváme jevy) \mathcal{F} je σ -algebra, tedy musí platit:
 - (a) $\emptyset \in \mathcal{F}$ a zároveň $\Omega \in \mathcal{F}$ (celá množina elementárních jevů je jev)
 - (b) $A \in \mathcal{F} \Rightarrow (\Omega \setminus A) \in \mathcal{F}$ (prostor jevů je uzavřený na doplňky)
 - (c) $(\forall n \in \mathbb{N}: A_n \in \mathcal{F}) \Rightarrow (\cup_{n \in \mathbb{N}} A_n) \in \mathcal{F}$ (prostor jevů je uzavřený na spočetná sjednocení, poznámka může se stát, že $A_1 \neq A_2 = A_3 = \dots$, speciálně tedy je uzavřený i na všechna konečná sjednocení)
3. \Pr je funkce $\Pr: \mathcal{F} \rightarrow [0, 1]$ je pravděpodobnost jevu z prostoru jevů, musí splňovat:
 - (a) $\Pr[\emptyset] = 0$ a zároveň $\Pr[\Omega] = 1$
 - (b) \Pr je spočetně aditivní, tedy pro každou $I \subseteq \mathbb{N}$ a každou posloupnost jevů $(A_j)_{j \in I}$, které jsou po dvou disjunktní (tedy $\forall i, j \in I: i \neq j \Rightarrow A_i \neq A_j$) platí:

$$\Pr[\cup_{j \in I} A_j] = \sum_{j \in I} \Pr[A_j]$$

(tedy \Pr je pravděpodobnostní míra)

2.2 Podmíněná pravděpodobnost

Definice. Nechť $(\Omega, \mathcal{F}, \Pr)$ je pravděpodobnostní prostor. Nechť $A, B \in \mathcal{F}$ a navíc $\Pr[B] > 0$. Pak definujeme podmíněnou pravděpodobnost

$$\Pr[A | B] = \frac{\Pr[A \cap B]}{\Pr[B]}$$

2.3 Bayesova věta

Věta 1. *Nechť $(\Omega, \mathcal{F}, \Pr)$ je pravděpodobnostní prostor. Nechť $B_1, B_2, \dots \in \mathcal{F}$ je rozklad Ω (na spočetně mnoho množin). Nechť $A \in \mathcal{F}$ a navíc platí $\Pr[A] > 0$ a navíc $\Pr[B_i] > 0$ pro každé i . Pak*

$$\Pr[B_j | A] = \frac{\Pr[A | B_j] \Pr[B_j]}{\sum_i \Pr[A | B_i] \Pr[B_i]}$$

2.4 Nezávislé jevy

Definice. *Nechť $(\Omega, \mathcal{F}, \Pr)$ je pravděpodobnostní prostor. Nechť $A, B \in \mathcal{F}$ jsou dva jevy. Pak řekneme, že A, B jsou nezávislé jevy, pokud platí:*

$$\Pr[A \cap B] = \Pr[A] \Pr[B]$$

(také se dá říct $\Pr[A | B] = \Pr[A]$ pokud $\Pr[B] > 0$).

Kapitola 3

Řešení

3.1 Cvičení

1. Úvodní informace:

(a) Slyšíte mě všichni dobře?

(b) Literatura.

Řešení: TODO

(c) Pravidla zápočtu (domácí úkoly).

Řešení: TODO

2. Jak se generuje náhoda programem.

● Python3 *Řešení:*

```

# https://docs.python.org/3/library/random.html
# Nepoužívejte pro šifrování!
import random
import scipy

# https://docs.python.org/3/library/itertools.html
import itertools

# Generuj náhodné celé číslo 1 <= x <= 10 (tedy x in range(1, 11))
x = random.randint(1, 10)
print(x)

# Generuj náhodný prvek dané neprázdné posloupnosti.
drink = random.choice([
    "světlé pivo",
    "tmavé pivo",
    "slivovice",
    "bílé víno",
    "červené víno",
    "čaj",
])
print(drink)

# Výsledek 'B' je třikrát pravděpodobnější než 'A'.
print(random.choice(['A', 'B', 'B', 'B']))

# Vrátí list k náhodným prvkům z dané sekvence s danými váhami
# (cum_weights jsou trochu rychlejší).
# https://docs.python.org/3/library/random.html#random.choices
print(random.choices(['A', 'B', 'C'], weights=[1/6, 1/6, 2/3], k=5))

# Náhodná permutace (mění přímo daný list).
my_list = ['a', 'b', 'c', 'd']
random.shuffle(my_list)
print(my_list)

# Vybere dva prvky dané posloupnosti, ve výsledku se nebudou opakovat
# pozice. Pokud se prvky opakují, tak se mohou ve výsledku opakovat.
print(random.sample(['w', 'x', 'y', 'z'], k=2)) # two distinct letters
print(random.sample(['w', 'x', 'y', 'x'], k=2)) # 'x' can repeat

# Pro přesné počítání (vrací iterable):
print(list(itertools.permutations([1, 2, 3])))
print(list(itertools.combinations('ABCD', 2)))
print(list(itertools.combinations_with_replacement('ABCD', 2)))

# Může se hodit scipy: sudo apt-get install python3-scipy
scipy.special.comb(n=5, k=2, exact=True) # vrátí n nad k

```

● C++ *Řešení:*

```
std::default_random_engine generator;
```

```
std::uniform_int_distribution<int> distribution(0, 9);
```

- **R Řešení:**

```
x <- "hello"
```

3. Připomeňte si definici pravděpodobnostního prostoru (Definice 2.1). Určete, co je

- množina elementárních jevů (*sample space*), tedy množina Ω ,
- prostor jevů (*event space*), tedy množina $\mathcal{F} \subseteq \mathcal{P}(\Omega)$,
- pravděpodobnost (*probability*), tedy funkce $\text{Pr}: \mathcal{F} \rightarrow [0, 1]$

pro následující příklady:

(a) Hod spravedlivou alkoholovou trojhrannou tužkou (není to kostka kvůli popisu prostoru jevů):

```
import random
drink = random.choice([
    "světlé pivo",
    "tmavé pivo",
    "slivovice",
])
```

Řešení: V počítači nám stačí předchozí kód (pseudonáhodné číslo vs náhodné číslo). Fyzicky můžeme generovat pomocí hodu trojhrannou tužkou, která má značky na stěnách (a zaručeně nemůže padnout nastojato).

- Množina elementárních jevů $\Omega = \{\text{světlé pivo}, \text{tmavé pivo}, \text{slivovice}\}$
- Prostor jevů $\mathcal{F} = \mathcal{P}(\Omega)$, tedy $|\mathcal{F}| = 2^{|\Omega|} = 2^3$:

$$\mathcal{F} = \{ \emptyset, \{\text{světlé pivo}\}, \{\text{tmavé pivo}\}, \{\text{slivovice}\}, \{\text{světlé pivo}, \text{tmavé pivo}\}, \{\text{světlé pivo}, \text{slivovice}\}, \{\text{tmavé pivo}, \text{slivovice}\}, \{\text{světlé pivo}, \text{tmavé pivo}, \text{slivovice}\} \}$$

- Pravděpodobnost

$$\begin{aligned} \text{Pr}[\emptyset] &= 0 \\ \text{Pr}[\{\text{světlé pivo}\}] &= 1/3 \\ \text{Pr}[\{\text{tmavé pivo}\}] &= 1/3 \\ \text{Pr}[\{\text{slivovice}\}] &= 1/3 \\ \text{Pr}[\{\text{světlé pivo}, \text{tmavé pivo}\}] &= 2/3 \\ \text{Pr}[\{\text{světlé pivo}, \text{slivovice}\}] &= 2/3 \\ \text{Pr}[\{\text{tmavé pivo}, \text{slivovice}\}] &= 2/3 \\ \text{Pr}[\{\text{světlé pivo}, \text{tmavé pivo}, \text{slivovice}\}] &= 1 \end{aligned}$$

Většinou ale nepopisujeme jev jako podmnožinu elementárních jevů, ale nějak lidsky:

$$\text{Pr}[\text{nějaké pivo}] = \text{Pr}[\text{světlé pivo} \vee \text{tmavé pivo}] = \text{Pr}[\{\text{světlé pivo}, \text{tmavé pivo}\}] = 2/3$$

$$\Pr[\text{ne pivo}] = \Pr[\{\text{slivovice}\}] = 1 - \Pr[\{\text{světlé pivo, tmavé pivo}\}] = 1/3$$

(b) Uniformně náhodné číslo z intervalu $[0, 1)$.

```
import random
print(random.random())
```

Řešení: V počítači nám funkce `random.random` vrátí float x , který je přesně reprezentovatelný, platí $0.0 \leq x < 1.0$ a zároveň x je celočíselný násobek 2^{-53} . To ale znamená, že nikdy nedostaneme 0.05954861408025609 i když to je číslo přesně reprezentovatelné jako python float. Můžeme generovat i vícebitová čísla, ale vždy to bude číslo! A to je dobře, většina reálných čísel nejde reprezentovat konečnou posloupností symbolů (pozor, $\sqrt{2}$ jde reprezentovat jako kořen polynomu, ale i třeba $1/\pi$ jde reprezentovat například algoritmem, který ho počítá).

Jak bychom fyzikálně generovali uniformně náhodné číslo z intervalu $[0, 1)$? Uniformně náhodné znamená, že každé číslo bude stejně pravděpodobné. Hod šipkou na interval má nevýhodu, že buď budou konce intervalu méně pravděpodobné než prostředek nebo se nám může stát že hodíme šipku mimo interval (nejspíš obojí). Můžeme ale udělat terč s jedním vyznačeným poloměrem, který bude kruh, připevnit jeho střed k vrtačce, roztočit a hodit šipku (tak abychom netrefili střed, ale určitě trefili kruh). Pak náhodné číslo $x \in [0, 1)$ bude úhel který svírá vyznačný poloměr a naše šipka dělený 2π .

- Toto je jen myšlenkový experiment, fyzická implementace je nejspíš poměrně nebezpečná. Doma to nezkoušejte!
- Můžete namítnout, že šipka nevybere přesně bod, že terč je tvořen atomy a tedy je také z nějakého pohledu diskrétní. Asi ano, ale já neříkal, že reálná čísla existují. Pro představu atom může mít poloměr okolo $10^{-10}m$, tedy na délce $1m$ jich vedle sebe vyskládáme zhruba 10^{10} . Srovnajte s přesností $2^{-53} \approx 10^{-16}$, tedy pokud bychom výsledek `random.random()` brali jako pozici v metrech, pak máme přesnost zhruba na dvě miliontiny atomu.
- *množina elementárních jevů (sample space)*, tedy množina $\Omega = [0, 1)$
- *prostor jevů (event space)*, tedy množina $\mathcal{F} \subseteq \mathcal{P}(\Omega)$

Napřed se zeptejme, jestli by nemohlo platit, že $\mathcal{F} = \mathcal{P}(\Omega)$. Asi bychom chtěli následující vlastnosti:

- pokud $A \in \mathcal{F}$ je interval, pak $\Pr[A]$ je rovna délce A
- pokud $A \in \mathcal{F}$ a navíc $x + A = \{x + a \mid a \in A\} \subseteq \Omega$ pro nějaké reálné číslo x , pak $\Pr[A] = \Pr[x + A]$.
- každá podmnožina Ω má přiřazenou nějakou pravděpodobnost

Ale to nejde, protože ne každá množina má míru (tady \Pr odpovídá takzvané pravděpodobnostní míře – míra celého prostoru je rovna jedné). Nejznámějším příkladem je https://en.wikipedia.org/wiki/Banach%E2%80%93Tarski_paradox Hezké video: <https://www.youtube.com/watch?v=s86-Z-CbaHA>.

Naše řešení: \mathcal{F} je množina Lebesgueovsky měřitelných podmnožin Ω .

- *pravděpodobnost (probability)*, tedy funkce $\Pr: \mathcal{F} \rightarrow [0, 1]$ je Lebesgueova míra.

Pokud jste neslyšeli o tom, co je to míra, tak se nelekejte. Dobré k zapamatování:

- Pravděpodobnost je číslo mezi nulou a jedničkou (obecná míra celého prostoru nemusí být rovna jedné, ale nás zajímá pravděpodobnostní míra).

- “Nic se nestane” má pravděpodobnost nula – $\Pr[\emptyset] = 0$ (tedy speciálně \emptyset je měřitelná).
- “Něco se stane” má pravděpodobnost jedna – $\Pr[\Omega] = 1$ (tedy speciálně Ω je měřitelná).
- “Stane se A ” má pravděpodobnost 1-“Nestane se A ” – $\Pr[A] = 1 - \Pr[\Omega \setminus A]$ (tedy pokud je A měřitelná, pak je i její doplněk měřitelný).
- $\Pr[\text{Na kostce padne jedna tečka nebo dvě tečky}] = \Pr[\text{padne jedna tečka}] + \Pr[\text{padnou dvě tečky}]$ – pravděpodobnost sjednocení disjunktních množin je rovna součtu jejich pravděpodobností (platí také pro *spočetně* mnoho disjunktních množin a navíc sjednocení spočetně mnoha disjunktních měřitelných množin je taky měřitelné)
- Lebesgueova míra jednoho bodu je nulová (tedy ze spočetného disjunktního sjednocení máme že pravděpodobnost že uniformně náhodné reálné číslo z intervalu $[0, 1)$ je racionální je nulová).
Pozor na to, že sice platí $\Pr[\{0.1\}] = 0$, ale to neznamená, že jev že padne 0.1 je nemožný (akorát velice velice nepravděpodobný). Naopak pokud je jev nemožný $\Pr[\text{na šestistěnné kostce padne sedm}]$, pak je jeho pravděpodobnost nulová.
- Úsečka v $[0, 1] \times [0, 1] \subseteq \mathbb{R}^2$ má Lebesgueovu míru nula.

Takže ty definice, které vám přijdou divné jsou tam kvůli teorii míry (případně později kvůli teorii integrálu).

Pozor na to, že ne každá pravděpodobnost je Lebesgueova míra, můžeme uvažovat například $\Omega = [0, 1)$, \mathcal{F} jsou Lebesgueovsky měřitelné, \Pr která $\Pr[\{0.1\}] = 1/2$ a $\Pr[A] = \lambda(A)/2 + 1/2$ pokud $0.1 \in A$ a $\Pr[A] = \lambda(A)/2$ jinak (kde $\lambda(A)$ značí Lebesgueovu míru množiny A).

Někdy také mluvíme o pravděpodobnostní distribuci, zatím to můžete brát jako synonymum k pravděpodobnosti.

4. **Dokažte, že** $\Pr[A \cup B] = \Pr[A] + \Pr[B] - \Pr[A \cap B]$.

Řešení: Předpokládejme, že platí $A \cap B, A \cup B, A, B \in \mathcal{F}$ (jinak by výraz nahoře neměl smysl). Z definice pravděpodobnostního prostoru (Definice 2.1) máme spočetnou aditivitu pro disjunktní jevy. Rozdělíme tedy $A \cup B$ na disjunktní množiny:

$$\begin{aligned} C_1 &= A \cap B \\ C_2 &= A \setminus B \\ C_3 &= B \setminus A \end{aligned}$$

tedy máme $A \cup B = C_1 \cup C_2 \cup C_3$ a zároveň $C_i \cap C_j = \emptyset$ pro každé dvě $1 \leq i < j \leq 3$. Dle spočetné aditivity můžeme psát:

$$\begin{aligned} \Pr[A \cup B] &= \Pr[C_1 \cup C_2 \cup C_3] \\ &= \Pr[C_1] + \Pr[C_2] + \Pr[C_3] \end{aligned}$$

Máme také:

$$\begin{aligned} A &= C_2 \cup C_1 = (A \setminus B) \cup (A \cap B) \\ B &= C_3 \cup C_1 = (B \setminus A) \cup (A \cap B) \end{aligned}$$

takže můžeme psát:

$$\begin{aligned} \Pr[A \cup B] &= \Pr[C_1] + \Pr[C_2] + \Pr[C_3] \\ &= \Pr[C_1] + \Pr[C_2] + 2\Pr[C_3] - \Pr[C_3] \\ &= (\Pr[C_1] + \Pr[C_3]) + (\Pr[C_2] + \Pr[C_3]) - \Pr[C_3] \\ &= (\Pr[A]) + (\Pr[B]) - \Pr[C_3] \\ &= \Pr[A] + \Pr[B] - \Pr[A \cap B] \end{aligned}$$

což jsme chtěli dokázat.

5. Zopakujte si základní kombinatoriku:

- Kolik je různých permutací množiny $\{A, B, C\}$?

Řešení: $3! = 3 \cdot 2 \cdot 1$, obecně $n!$ pokud máme n rozlišitelných prvků

```
import itertools

permutations = list(itertools.permutations(['A', 'B', 'C']))
print(f'There are {len(permutations)} permutations: {permutations}')

# There are 6 permutations:
#   [('A', 'B', 'C'),
#    ('A', 'C', 'B'),
#    ('B', 'A', 'C'),
#    ('B', 'C', 'A'),
#    ('C', 'A', 'B'),
#    ('C', 'B', 'A')]
```

- Kolik různých slov skládajících se z písmen $\{A, B\}$ má délku 3?

Řešení: $2^3 = 8$, obecně n^r kde n je počet písmen, r délka slova

```
import itertools

all_words = list(itertools.product('AB', repeat=3))
print(f'There are {len(all_words)} words: {all_words}')

# There are 8 words:
#   [('A', 'A', 'A'),
#    ('A', 'A', 'B'),
#    ('A', 'B', 'A'),
#    ('A', 'B', 'B'),
#    ('B', 'A', 'A'),
#    ('B', 'A', 'B'),
#    ('B', 'B', 'A'),
#    ('B', 'B', 'B')]
```

- Kolik různých podmnožin množiny $\{A, B, C, D, E\}$ má velikost 3?

Řešení: $\binom{n}{r} = \frac{n!}{r!(n-r)!} = \binom{5}{3} = 10$

```
import itertools

all_subsets = list(itertools.combinations('ABCDE', 3))
print(f'There are {len(all_subsets)} subsets: {all_subsets}')

# There are 10 subsets:
#   [('A', 'B', 'C'),
#    ('A', 'B', 'D'),
#    ('A', 'B', 'E'),
#    ('A', 'C', 'D'),
#    ('A', 'C', 'E'),
#    ('A', 'D', 'E'),
#    ('B', 'C', 'D'),
#    ('B', 'C', 'E'),
#    ('B', 'D', 'E'),
#    ('C', 'D', 'E')]
```

- Kolik různých kombinací s opakováním z množiny $\{A, B, C, D, E\}$ velikosti 3?

Řešení: $\binom{n+r-1}{r}$ kde $n = 5$, $r = 3$. Protože máme $n - 1$ svíslítek a r hvězdiček a kódujeme takto:

$$AAD = ** ||| * |$$

tedy

$$\text{počet A} | \text{počet B} | \text{počet C} | \text{počet D} | \text{počet E}$$

kde každý počet je reprezentován počtem hvězdiček a vybíráme které z $n+r-1$ symbolů budou hvězdičky.

```
import itertools
```

```
sorted_sequences = list(itertools.combinations_with_replacement('ABCDE', r=3))
print(f'Máme {len(sorted_sequences)} sekvencí: {sorted_sequences}')
```

```
# There are 35 sorted sequences:
#      [('A', 'A', 'A'), ('A', 'A', 'B'), ('A', 'A', 'C'),
#      ('A', 'A', 'D'), ('A', 'A', 'E'), ('A', 'B', 'B'),
#      ('A', 'B', 'C'), ('A', 'B', 'D'), ('A', 'B', 'E'),
#      ('A', 'C', 'C'), ('A', 'C', 'D'), ('A', 'C', 'E'),
#      ('A', 'D', 'D'), ('A', 'D', 'E'), ('A', 'E', 'E'),
#      ('B', 'B', 'B'), ('B', 'B', 'C'), ('B', 'B', 'D'),
#      ('B', 'B', 'E'), ('B', 'C', 'C'), ('B', 'C', 'D'),
#      ('B', 'C', 'E'), ('B', 'D', 'D'), ('B', 'D', 'E'),
#      ('B', 'E', 'E'), ('C', 'C', 'C'), ('C', 'C', 'D'),
#      ('C', 'C', 'E'), ('C', 'D', 'D'), ('C', 'D', 'E'),
#      ('C', 'E', 'E'), ('D', 'D', 'D'), ('D', 'D', 'E'),
#      ('D', 'E', 'E'), ('E', 'E', 'E')]
```

6. Jaká je pravděpodobnost, že při hodu šesti rozlišitelných spravedlivých šestistěnných kostek padnou aspoň na třech kostkách aspoň tři? Jaký je množina elementárních jevů, prostor jevů a pravděpodobnost?

Řešení:

- Množina elementárních jevů je $\Omega = \{1, 2, 3, 4, 5, 6\}^6 = \{111111, 111112, \dots, 666666\}$, tedy $|\Omega| = 6^6 = 46656$.
- Prostor jevů je $\mathcal{F} = \mathcal{P}(\Omega)$, tedy $|\mathcal{F}| = 2^{46656}$
- Pravděpodobnost $\Pr[\{abcdef\}] = 1/6^6$ pro libovolná $a, b, c, d, e, f \in \{1, 2, 3, 4, 5, 6\}$.

Jak takový příklad řešit? Uvědomit si přesně o čem mluvíme, pak zkusit přemýšlet o jednodušších jevech.

- Na jedné kostce padnou aspoň tři s pravděpodobností $4/6 = 2/3$ (musí padnout 3, 4, 5, 6, tedy nepadne 1, 2).
- Pokud vybereme k kostek, pak pravděpodobnost, že přesně na těchto kostkách padne aspoň tři je přesně $(2/3)^k(1/3)^{6-k}$ (kostky jsou nezávislé). Kupříkladu pokud vybereme první čtyři kostky, pak nás zajímá:

$$\Pr[\{ABCDef \mid A, B, C, D \in \{3, 4, 5, 6\}, e, f \in \{1, 2\}\}] = \frac{4^4 \cdot 2^2}{6^6} = (2/3)^4(1/3)^{6-4}$$

- Přesně k kostek vybereme $\binom{6}{k}$ způsoby.
- Rozdělíme pravděpodobnostní prostor na jevy, kde přesně na k kostkách padne číslo aspoň tři (tedy máme disjunktí rozklad) a $k \geq 3$, tedy použijeme definici pravděpodobnosti a sečteme předchozí pro $k \in \{3, 4, 5, 6\}$:

$$\begin{aligned} \Pr[\text{aspoň na třech kostkách aspoň tři}] &= \binom{6}{3} (2/3)^3(1/3)^{6-3} \\ &\quad + \binom{6}{4} (2/3)^4(1/3)^{6-4} \\ &\quad + \binom{6}{5} (2/3)^5(1/3)^{6-5} \\ &\quad + \binom{6}{6} (2/3)^6(1/3)^{6-6} \\ &= 0.8998628257887514 \end{aligned}$$

Tady jsme vlastně použili větu z přednášky, že pokud $B_0, B_1, \dots, B_{2^6-1}$ jsou rozklad Ω (tedy $B_i \neq B_j$ pro $i \neq j$ a zároveň $\cup B_i = \Omega$), pak $\Pr[A] = \sum_i \Pr[A \mid B_i] \Pr[B_i]$. Kde jev A je že na aspoň třech kostkách padne aspoň tři. Jev B_i je že na přesně určených kostkách padne aspoň tři (tedy jevy B_i, B_j jsou opravdu disjunktí). Konkrétně 22 zapsané binárně je 010110, pak jev B_{22} je jev že na druhé, čtvrté a páté kostce padlo číslo aspoň tři. Pak $\Pr[A \mid B_x] = 1$ pokud x má v binárním zápisu aspoň tři jedničky a $\Pr[A \mid B_x] = 0$ jinak. Už jsme spočítali, že $\Pr[B_x] = (2/3)^k(1/3)^{6-k}$ pokud x má v binárním zápisu k jedniček.

Pomocí programu:

```
import itertools
import scipy.special
import random
```

```

# Přesný výsledek pomocí kombinatoriky:

def p(k):
    """ Probability that there are exactly k out of 6 dice with at least 3. """
    return scipy.special.comb(6, k, exact=True) * ((2/3)**k) * ((1/3)**(6-k))

exact_computed = sum(p(k) for k in range(3, 7))
print(f'Přesný výsledek: {exact_computed}')

# Přesný výsledek spočítaný hrubou silou:

def indicator(dice):
    """ Return 1 if at least three dice have at least 3, otherwise
    return 0. """
    if sum(1 for x in dice if x >= 3) >= 3:
        return 1
    else:
        return 0

all_outcomes = itertools.product(range(1, 7), repeat=6)
exact_bruteforce = sum(indicator(d) for d in all_outcomes) / (6**6)
print(f'Hrubá síla: {exact_bruteforce}')

# Simulace:

N = 1000 # Number of tries
simulated = sum(indicator(random.choices(range(1, 7), k=6))
                 for _ in range(N)) / N
print(f'Simulace: {simulated}')

# Možný výsledek:
# Přesný výsledek: 0.8998628257887514
# Hrubá síla: 0.8998628257887518
# Simulace: 0.903

```

Porovnejme naše metody:

- Výpočet vzorcem:
 - přesný výsledek
 - potřebovali jsme kombinatoriku a přemýšlet
 - pokud se změní zadání, tak řešení se změní celkem dost
 - velice rychlý výpočet
- Procházení všech možností:
 - jednodušší vymýšlení
 - potřebujeme programovat

- přesný výsledek (liší se v posledních místech floatu, dáno nepřesnostmi floatové reprezentace, `exact=True` nevrací nativní float)
- pokud se změní zadání, tak se řešení skoro nezmění
- pokud je množina elementárních jevů velká, tak se tento postup nepoužitelný
- Simulace:
 - jednoduché vymyšlení (skoro jako předchozí případ)
 - pokud se změní zadání, tak se řešení skoro nezmění
 - časová složitost není lineární ve velikosti množiny elementárních jevů (N krát vybíráme náhodný prvek Ω , což často zvládáme v $\mathcal{O}(\log |\Omega|)$ krocích)
 - nepřesný výsledek – závisí na náhodných bitech počítače a počtu pokusů
 - budeme potřebovat trochu teorie abychom odhadli jak jistí si jsme výsledkem

7. Nechť Ω jsou všechny permutace prvních 100 přirozených čísel, prostor jevů jsou všechny podmnožiny Ω a každý elementární jev je stejně pravděpodobný. Označme jev A_j že náhodně zvolená permutace $\pi \in \Omega$ splňuje $\pi(j) = j$ (pro $1 \leq j \leq 100$). Jsou A_1, A_2 nezávislé jevy?

Řešení:

- Počet permutací v A_j je přesně 99! (jeden prvek je fixní, zbytek permutujeme), tedy

$$\Pr[A_j] = \frac{99!}{100!} = \frac{1}{100}$$

- Počet permutací v $A_1 \cap A_2$ je přesně 98! (dva prvky jsou fixní, zbytek permutujeme), tedy

$$\Pr[A_1 \cap A_2] = \frac{98!}{100!} = \frac{1}{9900}$$

- Dle definice nezávislých jevů bychom potřebovali $\Pr[A_1] \Pr[A_2] = \Pr[A_1 \cap A_2]$ (Definice 2.4), ale to neplatí:

$$\Pr[A_1 \cap A_2] = \frac{1}{9900} \neq \frac{1}{10000} = \Pr[A_1] \Pr[A_2]$$

Zamysleme se nad počítačovým řešením:

```
import random

# indexujeme od nuly
def fixed(my_list, j):
    return my_list[j] == j

my_list = list(range(100))
N = 100000

A1 = 0
for _ in range(N):
    random.shuffle(my_list)
    A1 += 1 if fixed(my_list, 0) else 0
A1 = A1 / N
print(f'Pr[A_1] = Pr[A_2] = {A1} (= {1/100})')


A1A2 = 0
for _ in range(N):
    random.shuffle(my_list)
    A1A2 += 1 if fixed(my_list, 0) and fixed(my_list, 1) else 0
A1A2 = A1A2 / N
print(f'Pr[A_1 and A_2] = {A1A2} (= {1/9900})')

# Možný výsledek:
# Pr[A_1] = Pr[A_2] = 0.00993 (= 0.01)
# Pr[A_1 and A_2] = 0.00012 (= 0.000101010101010101)
```

- jednoduchá simulace

- potřebujeme více pokusů, protože potřebujeme odhadnout s větší přesností (menší pravděpodobnost, tak abychom nedostali nulu)
- vůbec nemůžeme použít hrubou sílu, neboť $100! \approx 9.33 \cdot 10^{157}$, pro představu:
 - počítač vykoná zhruba 10^9 instrukcí za sekundu
 - lineární algoritmus (další permutaci najdeme v jednotkovém čase) by trval zhruba 10^{148} sekund
 - stáří vesmíru se odhaduje na $13.787 \cdot 10^9$ let
 - jeden rok trvá zhruba $\pi \cdot 10^7$ sekund
 - stáří vesmíru je tedy zhruba $4.34 \cdot 10^{17}$ sekund
 - tedy lineární algoritmus který by prošel všechny permutace 100 prvkové množiny by běžel zhruba 10^{131} stáří vesmíru

8. Každý obdélník na obrázku je součástka, která se může porouchat s pravděpodobností p . Přesněji řečeno porucha znamená, že skrz ní neteče proud. Poruchy součástek jsou na sobě nezávislé. Jaká je pravděpodobnost, že stále poteče proud mezi dvěma puntíky.



Řešení:

(a) Jak postupujeme:

- Jedna součástka se neporouchá (tedy je ok, jev O , porouchá jev P) s pravděpodobností $\Pr[O] = 1 - \Pr[P] = 1 - p$.
- Aby proud tek, tak všechny součástky musí být ok. Tedy nás zajímá

$$\Pr[O_1 \cap O_2 \cap O_3]$$

- Z nezávislosti jevů P_1, P_2 máme i nezávislost jevů O_1, O_2 (tedy jejich doplňků):
 - Chceme: $\Pr[A \cap B] = \Pr[A] \Pr[B]$ právě tehdy když $\Pr[\bar{A} \cap \bar{B}] = \Pr[\bar{A}] \Pr[\bar{B}]$ kde $\bar{A} = \Omega \setminus A$ je doplněk
 - Z minulého příkladu přeuspořádáním dostaneme (pro libovolné jevy)

$$\Pr[A \cap B] = \Pr[A] + \Pr[B] - \Pr[A \cup B]$$

– Tedy:

$$\Pr[\bar{A} \cap \bar{B}] = \Pr[\bar{A}] + \Pr[\bar{B}] - \Pr[\bar{A} \cup \bar{B}]$$

– Použijeme že $\bar{A} \cup \bar{B} = \overline{A \cap B}$

– Tedy píšeme:

$$\begin{aligned} \Pr[\bar{A} \cap \bar{B}] &= \Pr[\bar{A}] + \Pr[\bar{B}] - \Pr[\bar{A} \cup \bar{B}] \\ &= \Pr[\bar{A}] + \Pr[\bar{B}] - \Pr[\overline{A \cap B}] \\ &= (1 - \Pr[A]) + (1 - \Pr[B]) - (1 - \Pr[A \cap B]) \\ &= 1 - \Pr[A] - \Pr[B] + \Pr[A \cap B] \quad (\text{z nezávislosti } A, B) \end{aligned}$$

- Chtěli jsme $\Pr[\bar{A} \cap \bar{B}] = \Pr[\bar{A}] \Pr[\bar{B}] = (1 - \Pr[A])(1 - \Pr[B])$, což je akorát jinak napsaný předchozí řádek.

- Z nezávislosti jevů O_1, O_2, O_3 máme rovnou

$$\begin{aligned}\Pr[O_1 \cap O_2 \cap O_3] &= \Pr[O_1] \Pr[O_2] \Pr[O_3] \\ &= (1 - \Pr[P_1])(1 - \Pr[P_2])(1 - \Pr[P_3]) \\ &= (1 - p)^3\end{aligned}$$

- (b) Druhý příklad je podobný, ale potřebujeme aby aspoň jedna součástka fungovala, tedy chceme

$$\Pr[O_1 \cup O_2 \cup O_3]$$

Jako nápoředu použijte pozorování že $\Pr[A \cup B] = \Pr[A] + \Pr[B] - \Pr[A \cap B]$.

Jednodušší postup je, uvědomit si, že se nemůžou porouchat všechny a použít nezávislost, tedy

$$\begin{aligned}\Pr[O_1 \cup O_2 \cup O_3] &= 1 - \Pr[P_1 \cap P_2 \cap P_3] \\ &= 1 - \Pr[P_1] \Pr[P_2] \Pr[P_3] \\ &= 1 - p^3\end{aligned}$$

- (c) Kombinace myšlenek předchozích.

Samozřejmě můžeme simulovat (všimněte si, jak se podmínka v indikátoru mechanicky překlápí na vzorec pravděpodobnosti):

```
from random import choices
from typing import Sequence

# Pravděpodobnost chyby konkrétní součástky (chyby jsou nezávislé).
p = 0.1
# Počet pokusů.
N = 1000000

def bernoulli_list(k: int, pr: float = p) -> Sequence[bool]:
    """Vrací k samplů z Bernoulliho rozdělení s pravděpodobností pr."""
    return choices([True, False], weights=[pr, 1-pr], k=k)

# a)
#   +-----+   +-----+   +-----+
# o---| 0 |---| 1 |---| 2 |---o
#   +-----+   +-----+   +-----+

def proud_tece_a(soucastky: Sequence[bool]) -> int:
    """Indikátor, jestli proud teče.
    soucastky[i] = i-tá součástka je porouchaná."""
    assert len(soucastky) == 3
    return int(not soucastky[0] and not soucastky[1] and not soucastky[2])

# Kolikrát proud tekł z N pokusů.
proud_tekl_a = sum(proud_tece_a(bernoulli_list(3)) for _ in range(N))
```

```

simulation_a = proud_tekl_a / N
answer_a = (1 - p)**3
error_a = abs(answer_a - simulation_a)
print(f'a) Simulováno: {simulation_a} (chyba {error_a})')

```

```

# b)
#           +-----+
#       +---| 0 |---+
#       |   +-----+   |
#       |   +-----+   |
#       |   +-----+   |
#  o---+---| 1 |---+---o
#       |   +-----+   |
#       |   +-----+   |
#       |   +-----+   |
#       +---| 2 |---+
#           +-----+

```

```

def proud_tece_b(soucastky: Sequence[bool]) -> int:
    """Indikátor, jestli proud teče.
    soucastky[i] = i-tá součástka je porouchaná."""
    assert len(soucastky) == 3
    return int(not (soucastky[0] and soucastky[1] and soucastky[2]))

```

```
proud_tekl_b = sum(proud_tece_b(bernoulli_list(3)) for _ in range(N))
```

```

simulation_b = proud_tekl_b / N
answer_b = 1 - (p**3)
error_b = abs(answer_b - simulation_b)
print(f'b) Simulováno: {simulation_b} (chyba {error_b})')

```

```

# c)
#           +-----+           +-----+
#       +---| 0 |---+           +-----| 3 |-----+
#       |   +-----+   |   +-----+   |           +-----+   |
#  o---+---+           +---| 2 |---+           +-----+   |
#       |   +-----+   |   +-----+   |   +-----+   +-----+   |
#       +---| 1 |---+           +---| 4 |---| 5 |---+
#           +-----+           +-----+   +-----+

```

```

def proud_tece_c(soucastky: Sequence[bool]) -> int:
    """Indikátor, jestli proud teče.
    soucastky[i] = i-tá součástka je porouchaná."""
    assert len(soucastky) == 6
    return int(not (soucastky[0] and soucastky[1]
                    and not soucastky[2]
                    and (not (soucastky[3] and (soucastky[4] or soucastky[5])))))

```

```
proud_tekl_c = sum(proud_tece_c(bernoulli_list(6)) for _ in range(N))
```

```
simulation_c = proud_tekl_c / N
answer_c = (1 - (p**2)) * (1 - p) * (1 - (p * (1 - ((1 - p)**2))))
error_c = abs(answer_c - simulation_c)
print(f'c) Simulováno: {simulation_c} (chyba {error_c})')
```

Možný výsledek:

```
# a) Simulováno: 0.728696 (chyba 0.000304000000000082)
# b) Simulováno: 0.999005 (chyba 5.00000000032756e-06)
# c) Simulováno: 0.874083 (chyba 1.200000000012001e-05)
```

3.2 Cvičení

1. Házíme cinknutou mincí – hlava padne s pravděpodobností $p \in [0, 1)$, orel padne s pravděpodobností $1 - p$. Házíme opakovaně dokud nepadne hlava.

(a) Jak vypadá pravděpodobnostní prostor?

Řešení:

- *Množina elementárních jevů:* Série hodů, které uvažujeme můžeme kódovat pomocí H pokud padne hlava, O pokud padne orel, takže bychom mohli možné série hodů reprezentovat jako

$$\{H, OH, OOH, OOOH, OOOOH, \dots\}.$$

Ale to je poněkud nepraktické, raději budeme reprezentovat počtem hodů (poslední je určitě hlava, ty před ním jsou orlové):

$$\Omega = \{1, 2, 3, 4, \dots\}$$

- *Prostor jevů:* Máme spočetnou množinu elementárních jevů, takže můžeme brát jako prostor jevů celou potenční množinu množiny elementárních jevů: $\mathcal{F} = \mathcal{P}(\Omega)$.

Lehké cvičení z matematické analýzy: dokažte, že pokud každému elementárnímu jevu přiřadíme pravděpodobnost, tedy

$$\forall \omega \in \Omega: \Pr[\{\omega\}] \in [0, 1]$$

pak víme, že

–

$$\Pr[\Omega] = \sum_{\omega \in \Omega} \Pr[\{\omega\}] = 1$$

–

$$\forall A \in \mathcal{F}: \Pr[A] = \sum_{\omega \in A} \Pr[\{\omega\}]$$

a tento výraz je dobře definovaný (vzpomeňte na absolutní konvergenci, neklesající posloupnost a omezenou posloupnost).

- *Pravděpodobnost:* Jak jsme viděli v předchozím bodě, tak stačí určit pravděpodobnost, že hodíme právě n -krát, což je

$$\Pr[\{n\}] = (1 - p)^{n-1}p \quad (\text{pro libovolné } n \in \mathbb{N}^+)$$

protože napřed musí padnout $n - 1$ orlů a pak jedna hlava.

Zkontrolujme ještě, že se vše sečte na jedničku. Pro jistotu napřed zopakujme součty geometrické řady.

$$\begin{aligned} S &= \sum_{j=0}^n q^j \\ &= 1 + q + q^2 + \dots + q^n \\ &= 1 + q(1 + q + q^2 + \dots + q^{n-1}) \\ &= 1 + q(S - q^n) \end{aligned}$$

tedy

$$S = 1 + q(S - q^n)$$

$$\begin{aligned}
 S - qS &= 1 - q^{n+1} \\
 S &= \frac{1 - q^{n+1}}{1 - q} \quad (\text{pokud } q \neq 1)
 \end{aligned}$$

a pro nekonečný případ

$$\begin{aligned}
 \sum_{j=0}^{\infty} q^j &= \lim_{n \rightarrow \infty} \sum_{j=0}^n q^j \\
 &= \lim_{n \rightarrow \infty} \frac{1 - q^{n+1}}{1 - q} \\
 &= \frac{1}{1 - q} \quad (\text{pokud } |q| < 1)
 \end{aligned}$$

Ted' už můžeme aplikovat předchozí pro naši pravděpodobnost:

$$\begin{aligned}
 \sum_{n \in \Omega} \Pr[\{n\}] &= \sum_{n \in \Omega} (1 - p)^{n-1} p \\
 &= p(1 + (1 - p) + (1 - p)^2 + \dots) \\
 &= 1
 \end{aligned}$$

(b) **Jaká je pravděpodobnost, že hodíme právě třikrát (n -krát)?**

Řešení: To už jsme určili v předchozím bodě, ale tato vlastnost je tak důležitá, že to radši zopakujeme:

$$\Pr[\{n\}] = (1 - p)^{n-1} p \quad (\text{pro libovolné } n \in \mathbb{N}^+)$$

Připomeňme, že tomuto se také někdy říká geometrické rozdělení. Dejte pozor na to, že $0 < p \leq 1$ (proč?). Hodí se, když při hodu kostkou házíme znovu a zajímá nás celkový počet hodů.

(c) **Jaká je pravděpodobnost, že hodíme nejvýš třikrát (n -krát)?**

Řešení: Využijeme součet geometrické posloupnosti:

$$\begin{aligned}
 \Pr[\{1, 2, \dots, n\}] &= \sum_{j=1}^n p(1 - p)^{j-1} \\
 &= p \sum_{j=1}^n (1 - p)^{j-1} \\
 &= p \frac{1 - (1 - p)^n}{1 - (1 - p)} \\
 &= 1 - (1 - p)^n
 \end{aligned}$$

(d) **Jaká je pravděpodobnost, že hodíme lišekrát?**

Řešení: Opět přímý výpočet:

$$\begin{aligned}
 \Pr[\{1, 3, 5, 7, \dots\}] &= \sum_{j=0}^{\infty} p(1 - p)^{2j} \\
 &= p \sum_{j=0}^{\infty} ((1 - p)^2)^j
 \end{aligned}$$

$$= p \sum_{j=0}^{\infty} ((1-p)^2)^j$$

$$= p \frac{1}{1 - (1-p)^2}$$

(e) Simulujte předchozí.

Řešení:

```
from random import random

def geometric(pr: float = 0.5) -> int:
    """pr is success probability, return the number of tosses until
    the first success."""
    assert pr > 0
    sample = 1
    fail_pr = 1 - pr
    while random() < fail_pr:
        sample += 1
    return sample

N = 1000000 # Pokusů
pr = 0.3

exactly_three_sim = sum(int(geometric(pr) == 3) for _ in range(N)) / N
exactly_three = pr * (1 - pr)**2
print(f'a) Pr[tři] = {exactly_three_sim} (= {exactly_three})')

at_most_three_sim = sum(int(geometric(pr) <= 3) for _ in range(N)) / N
at_most_three = 1 - (1 - pr)**3
print(f'b) Pr[nejvýš tři] = {at_most_three_sim} (= {at_most_three})')

odd_number_sim = sum(int(geometric(pr) % 2 == 1) for _ in range(N)) / N
odd_number = pr / (1 - (1 - pr)**2)
print(f'c) Pr[lišekrát] = {odd_number_sim} (= {odd_number})')

# Možný výstup:
# a) Pr[tři] = 0.147168 (= 0.14699999999999996)
# b) Pr[nejvýš tři] = 0.65664 (= 0.657)
# c) Pr[lišekrát] = 0.58815 (= 0.5882352941176471)
```

2. Hodíme cinknutou korunou (panna s pravděpodobností $p_1 \in [0, 1]$) a cinknutou dvoukorunou (panna s pravděpodobností $p_2 \in [0, 1]$). Oba hody jsou na sobě nezávislé.

(a) Určete pravděpodobnostní prostor.

Řešení:

- Množina elementárních jevů:

$$\Omega = \{P_1P_2, P_1O_2, O_1P_2, O_1O_2\}$$

kde P je panna O orel a index ukazuje na které minci to padlo.

- Prostor jevů:

$$\mathcal{F} = \mathcal{P}(\Omega)$$

- Pravděpodobnost: určíme znovu jen na jednoprvkových jevech (na obecném jevu suma):

$$\begin{aligned}\Pr[\{P_1P_2\}] &= p_1p_2 \\ \Pr[\{P_1O_2\}] &= p_1(1-p_2) \\ \Pr[\{O_1P_2\}] &= (1-p_1)p_2 \\ \Pr[\{O_1O_2\}] &= (1-p_1)(1-p_2)\end{aligned}$$

(b) Připomněte si definici podmíněné pravděpodobnosti (Definice 2.2).

(c) Spočítejte pravděpodobnost $\Pr[\text{na obou padne panna} \mid \text{na koruně padne panna}]$.

Řešení: Jev A „na obou padne panna“ je formálně $A = \{P_1P_2\}$, jev B „na koruně padne panna“ je formálně $B = \{P_1P_2, P_1O_2\}$ (má pravděpodobnost ostře větší než jedna). Pak podmíněná pravděpodobnost je:

$$\Pr[A \mid B] = \frac{\Pr[A \cap B]}{\Pr[B]}$$

tedy

$$\begin{aligned}\Pr[\{P_1P_2\} \mid \{P_1P_2, P_1O_2\}] &= \frac{\Pr[\{P_1P_2\} \cap \{P_1P_2, P_1O_2\}]}{\Pr[\{P_1P_2, P_1O_2\}]} \\ &= \frac{\Pr[\{P_1P_2\}]}{\Pr[\{P_1P_2, P_1O_2\}]} \\ &= \frac{p_1p_2}{p_1p_2 + p_1(1-p_2)} \\ &= p_2 \quad (\text{což dává smysl, protože ty hody jsou nezávislé})\end{aligned}$$

(d) Spočítejte pravděpodobnost $\Pr[\text{na obou padne panna} \mid \text{padne aspoň jedna panna}]$.

Řešení: Jev A „na obou padne panna“ je formálně $A = \{P_1P_2\}$, jev B „aspoň jedna panna“ je formálně $C = \{P_1P_2, P_1O_2, O_1P_2\}$ (má pravděpodobnost ostře větší než jedna). Pak podmíněná pravděpodobnost je:

$$\begin{aligned}\Pr[\{P_1P_2\} \mid \{P_1P_2, P_1O_2, O_1P_2\}] &= \frac{\Pr[\{P_1P_2\} \cap \{P_1P_2, P_1O_2, O_1P_2\}]}{\Pr[\{P_1P_2, P_1O_2, O_1P_2\}]} \\ &= \frac{\Pr[\{P_1P_2\}]}{\Pr[\{P_1P_2, P_1O_2, O_1P_2\}]}\end{aligned}$$

$$= \frac{p_1 p_2}{p_1 p_2 + p_1(1 - p_2) + (1 - p_1)p_2}$$

(e) Simulujte:

Řešení:

```

from random import random

def toss(weights):
    """True = panna, False = Orel"""
    coins = [False] * len(weights)
    for i in range(len(weights)):
        coins[i] = random() < weights[i]
    return coins

N = 1000000
p1 = 0.1 # panna na první minci
p2 = 0.6 # panna na druhé minci

obe_panna = 0
prvni_je_panna = 0
aspon_jedna_panna = 0

for _ in range(N):
    coins = toss(weights=[p1, p2])
    if all(coins):
        obe_panna += 1
    if coins[0]:
        prvni_je_panna += 1
    if any(coins):
        aspon_jedna_panna += 1

pr_c_sim = obe_panna / prvni_je_panna
pr_c = p2

pr_d_sim = obe_panna / aspon_jedna_panna
pr_d = p1 * p2 / (p1 * p2 + p1 * (1 - p2) + (1 - p1) * p2)

print(f'Pr[obě panna|koruna panna] = {pr_c_sim} (= {pr_c})')
print(f'Pr[obě panna|aspoň jedna panna] = {pr_d_sim} (= {pr_d})')

# Možný výstup:
# Pr[obě panna|koruna panna] = 0.6017034618418556 (=0.6)
# Pr[obě panna|aspoň jedna panna] = 0.09411977858579801 (=0.09375)

```

3. Na louce rostou květiny, které mají buď bílé nebo červené květy. Náhodná květina má bílý květ s pravděpodobností $\Pr[B] = 0.6$, tedy pravděpodobnost že náhodná květina má červený květ je $\Pr[C] = 0.4$. Pravděpodobnost že červená květina je jedovatá je $\Pr[J | C] = 0.25$. Pravděpodobnost že bílá květina je jedovatá je $\Pr[J | B] = 1/12$. Snědli jsme náhodnou rostlinu a je nám zle, jaká je pravděpodobnost, že ta rostlina měla červený květ?

Řešení: Řešení 1 – použití Bayesovy věty (Věta 1) jako stroj:

- Máme Ω , což je množina všech květin.
- Máme rozklad Ω (víme, že kvetou buď bíle nebo červeně), tedy jevy $B_1 = B, B_2 = C$.
- Víme $\Pr[J | C]$ i $\Pr[J | B]$.
- Zajímá nás $\Pr[C | J]$.
- Dosadíme do vzorce:

$$\begin{aligned} \Pr[C | J] &= \frac{\Pr[J | C] \Pr[C]}{\Pr[J | C] \Pr[C] + \Pr[J | B] \Pr[B]} \\ &= \frac{0.25 \cdot 0.4}{0.25 \cdot 0.4 + (1/12) \cdot 0.6} \\ &= 2/3 \end{aligned}$$

Řešení 2 – použijeme představivost a kreslíme:

- Necht' je na louce 100 kytek.
- Takže bílých je 60.
- Červených je 40.
- Jedovatých červených je 10.
- Jedovatých bílých je 5.
- Jedovatých je 15 (to je jmenovatel v Bayesově větě).
- Pravděpodobnost že kytky je červená když je jedovatá je $10/15 = 2/3$.

Pár poznámek:

- Čísla byla hezká, takže druhý postup je jednoduchý.
- Naprostá většina lidí nezvládá tento typ úlohy. Takže si nejlépe osvojte oba postupy. První je super pro počítač, druhý pro rychlý odhad.

Můžeme zkusit i naivní simulaci:

```
from enum import Enum
from random import random
```

```
def bernoulli(pr: float = 0.5) -> bool:
    return random() < pr
```

```
class Color(Enum):
    RED = 1
    WHITE = 2
```

```
class Plant:
    """Random plant."""
    def __init__(self):
        if bernoulli(0.6):
            self.color = Color.WHITE
            self.is_poisonous = bernoulli(1/12)
        else:
            self.color = Color.RED
            self.is_poisonous = bernoulli(0.25)

N = 1000000 # Pokusů
poisonous = 0 # Kolik jsme viděli jedovatých rostlin.
poisonous_red = 0 # Kolik z těch jedovatých bylo červených

for _ in range(N):
    p = Plant()
    if p.is_poisonous:
        poisonous += 1
        if p.color == Color.RED:
            poisonous_red += 1

assert poisonous > 0, "Pravděpodobnost Pr[A|B] není definovaná pokud Pr[B]=0"
print(f'Viděli jsme {poisonous_red} červených jedovatých rostlin')
print(f'z celkem {poisonous} jedovatých rostlin')
print(f'tedy Pr[červená|jedovatá] = {poisonous_red/poisonous} (= {2/3})')

# Možný výstup:
# Viděli jsme 100562 červených jedovatých rostlin
# z celkem 150617 jedovatých rostlin
# tedy Pr[červená|jedovatá] = 0.6676669964213867 (= 0.6666666666666666)
```

4. V první krabici je b bílých míčků a c červených míčků, ve druhé krabici také. Napřed vytáhneme jeden míček z první krabice (uniformně náhodně) a dáme ho do druhé krabice. Pak vytáhneme jeden míček z druhé krabice (uniformně náhodně). Jaká je pravděpodobnost, že míček vytažený z druhé krabice je červený?

(a) Navrhněte vhodný pravděpodobnostní prostor.

Řešení:

- *Množina elementárních jevů:* $\Omega = \{B_1B_2, B_1C_2, C_1B_2, C_1C_2\}$ kde B_1B_2 značí že jsme z první krabice vytáhli bílý míček (a dali ho do druhé krabice) a pak jsme z druhé krabice vytáhli bílý míček. . .
- *Prostor jevů:* $\mathcal{F} = \mathcal{P}(\Omega)$.
- *Pravděpodobnost:* znovu jen pro jednoprvkové jevy

$$\Pr[\{B_1B_2\}] = \left(\frac{b}{b+c}\right) \left(\frac{b+1}{b+1+c}\right)$$

$$\Pr[\{B_1C_2\}] = \left(\frac{b}{b+c}\right) \left(\frac{c}{b+1+c}\right)$$

$$\Pr[\{C_1B_2\}] = \left(\frac{c}{b+c}\right) \left(\frac{b}{b+1+c}\right)$$

$$\Pr[\{C_1C_2\}] = \left(\frac{c}{b+c}\right) \left(\frac{c+1}{b+1+c}\right)$$

(b) Spočítejte tu pravděpodobnost, kterou jsme chtěli.

Řešení: Použijeme podmíněnou pravděpodobnost (a projdeme možnosti, co se stane).

$$\begin{aligned} \Pr[2. \text{ červený}] &= \Pr[2. \text{ červený} \mid 1. \text{ bílý}] \Pr[1. \text{ bílý}] + \Pr[2. \text{ červený} \mid 1. \text{ červený}] \Pr[1. \text{ červený}] \\ &= \frac{c}{b+1+c} \frac{b}{b+c} + \frac{c+1}{b+1+c} \frac{c}{b+c} \\ &= \frac{bc}{(b+c)(b+1+c)} + \frac{c(c+1)}{(b+c)(b+1+c)} \\ &= \frac{c(b+c+1)}{(b+c)(b+1+c)} \\ &= \frac{c}{b+c} \end{aligned}$$

A to samé bychom dostali i přímo z rozepsání:

$$\begin{aligned} \Pr[\{B_1C_2, C_1C_2\}] &= \left(\frac{b}{b+c}\right) \left(\frac{c}{b+1+c}\right) + \left(\frac{c}{b+c}\right) \left(\frac{c+1}{b+1+c}\right) \\ &= \dots \\ &= \frac{c}{b+c} \end{aligned}$$

(c) Simulujte.

Řešení:

```
import random
```

```
bilych = 15
```

```
cervenych = 37

kbelik_1 = ['B'] * bilych + ['C'] * červenych
kbelik_2 = ['B'] * bilych + ['C'] * červenych

N = 1000000
cervenych_z_druheho = 0
for _ in range(N):
    druhu_kbelik = kbelik_2 + [random.choice(kbelik_1)]
    assert len(druhy_kbelik) == 1 + len(kbelik_1)
    if random.choice(druhy_kbelik) == 'C':
        červenych_z_druheho += 1

vysledek = červenych / (cervenych + bilych)
print(f'Nasimulovali jsme {cervenych_z_druheho/N} (={vysledek})')

# Možný výstup:
# Nasimulovali jsme 0.711212 (=0.7115384615384616)
```

5. Tento příklad je vymyšlený, zejména čísla nesedí a reálný svět je malinko složitější (tím se ještě budeme zabývat), ale informace v něm nejsou daleko od pravdy. V zemi nám řádí nemoc C .

- Prostor elementárních jevů (sample space) Ω jsou všichni občané.
- Označíme $C^+ \subseteq \Omega$ množinu všech lidí, kteří dnes mají aktivní nemoc C , označíme $C^- = \Omega \setminus C^+$ zdravé lidi.
- Umíme uniformně náhodně samplovat lidi, tedy $\forall \omega \in \Omega: \Pr[\{\omega\}] = 1/|\Omega|$ (tady ω je jeden člověk).
- Test nám pro libovolného člověka odpoví že je člověk zdravý nebo nemocný. Značme $T^+ \subseteq \Omega$ množinu lidí pro které test odpoví, že jsou nemocní. Značme $T^- = \Omega \setminus T^+$ množinu lidí pro které test odpoví, že jsou zdraví. Ale není to tak jednoduché, v příbalovém letáku testu se píše:

– *Sensitivity*: (true positive) $\Pr[T^+ | C^+] = 0.9$

– *Specificity*: (true negative) $\Pr[T^- | C^-] = 0.8$

z tohoto můžeme odvodit chyby:

– False positive = false alarm = type I error

$$\Pr[T^+ | C^-] = 1 - \Pr[T^- | C^-] = 0.2$$

– False negative = miss = type II error

$$\Pr[T^- | C^+] = 1 - \Pr[T^+ | C^+] = 0.1$$

- Provedli jsme jeden test u každého z uniformně náhodně vybraných 50000 lidí a pozitivních testů vyšlo 1000. Tedy předpokládáme, že $\Pr[T^+] = \frac{1000}{50000} = \frac{1}{50} = 0.02$ (jak moc je tento předpoklad oprávněný budeme zkoumat nadále).
- Zajímá nás $\Pr[C^+]$ (vynásobeno 100 nám dá počet nemocných v procentech).

(a) V čem se toto liší od reality?

Řešení:

- Zejména v tom náhodném testování. Uvědomte si, že trasování nevybírá lidi náhodně. Ve skutečnosti je velmi těžké vybrat náhodného člověka (více o tom později).
- Sensitivita a specificita jsou opravdu důležité parametry testu (nezávisí na tom jaké je procento nemocných). Jejich výhoda je, že pokud známe četnost nemocí v populaci, pak můžeme pomocí Bayesovy věty spočítat pravděpodobnost, že náhodně vybraný člověk je nemocný, pokud test vyšel pozitivní. Pak se stejně dělá ještě další test, abychom si byli jistí (viz domácí úkol).
- Sensitivita a specificita se určují experimentálně, tedy je neznáme přesně (můžete zkusit v simulaci co to udělá).
- Milion komplikací při popisu skutečného světa, například nevíme na čem závisí pravděpodobnost chyby prvního nebo druhého druhu (třeba je pro danou krevní skupinu false positive pravděpodobnější...).

(b) Spočítejte $\Pr[C^+]$.

Řešení: Využijeme větu o úplné pravděpodobnosti: pokud $B_1, B_2 \in \mathcal{F}$ je rozklad Ω (tedy $B_1 \cap B_2 = \emptyset$ a navíc $B_1 \cup B_2 = \Omega$, připomeňme že věta platí i pro spočetný rozklad B_1, B_2, \dots), pak pro libovolné $A \in \mathcal{F}$ máme

$$\Pr[A] = \Pr[A | B_1] \Pr[B_1] + \Pr[A | B_2] \Pr[B_2]$$

Aplikujeme předchozí:

$$\begin{aligned}\Pr[T^+] &= \Pr[T^+ | C^+] \Pr[C^+] + \Pr[T^+ | C^-] \Pr[C^-] \\ &= \Pr[T^+ | C^+] \Pr[C^+] + \Pr[T^+ | C^-](1 - \Pr[C^+])\end{aligned}$$

přeuspořádáme

$$\begin{aligned}\Pr[T^+] &= \Pr[T^+ | C^+] \Pr[C^+] + \Pr[T^+ | C^-](1 - \Pr[C^+]) \\ \Pr[T^+] &= \Pr[T^+ | C^+] \Pr[C^+] + \Pr[T^+ | C^-] - \Pr[T^+ | C^-] \Pr[C^+] \\ \Pr[T^+] &= (\Pr[T^+ | C^+] - \Pr[T^+ | C^-]) \Pr[C^+] + \Pr[T^+ | C^-] \\ \Pr[C^+] &= \frac{\Pr[T^+] - \Pr[T^+ | C^-]}{\Pr[T^+ | C^+] - \Pr[T^+ | C^-]} \\ \Pr[C^+] &= \frac{0.02 - 0.2}{0.9 - 0.2} \\ \Pr[C^+] &\approx -0.257\end{aligned}$$

(c) Co se stalo špatně?

Řešení: Taková data bychom nečekali ani kdyby všichni byli zdraví (vyšlo nám příliš málo pozitivních).

Erratum:

- i. Původně bylo: Takže jsme rozhodně netestovali náhodný vzorek populace.
- ii. Problém tohoto vysvětlení: Ani kdybychom testovali jen zdravé lidi, tak by to nebylo dobré vysvětlení.
- iii. Lepší pokus o vysvětlení:
 - Možná, že parametry testu byly odhadnuty chybně.
 - Je možné, že laboratoř omylem poslala špatná data (například jeden laborant prohodil počet pozitivních a negativních výsledků u svých testů).
 - Je možné, že náhodou testy fungovaly mnohem lépe, než měly. Třeba jsme dostali várku nečekaně přesných testů. Speciálně není nemožné, že 20 hodů spravedlivou mincí nám dá 20 hlav, je to jen extrémně nepravděpodobné. Odhadem pravděpodobnosti takovéto chyby se budeme v rámci předmětu ještě zabývat.

(d) Jak by vyšlo předchozí kdyby $\Pr[T^+ | C^+] = 0.99, \Pr[T^- | C^-] = 0.98, \Pr[T^+] = 0.2$?

Řešení:

$$\begin{aligned}\Pr[C^+] &= \frac{\Pr[T^+] - \Pr[T^+ | C^-]}{\Pr[T^+ | C^+] - \Pr[T^+ | C^-]} \\ &= \frac{0.2 - 0.02}{0.99 - 0.02} \\ &\approx 0.185\end{aligned}$$

Což dává smysl (je spíš pravděpodobné, že zdravého chybně označíme za nemocného než naopak).

(e) Simulujte předchozí.

Řešení:

```

from random import random

def bernoulli(pr: float = 0.5) -> bool:
    return random() < pr

class Human:
    """_illness_probability is our unknown! """
    _illness_probability = 0.185

    """Random human."""
    def __init__(self):
        self.is_ill = bernoulli(Human._illness_probability)

class IllnessTest:
    sensitivity = 0.99 # = Pr[T+|C+]
    specificity = 0.98 # = Pr[T-|C-]

    def test(h: Human) -> bool:
        """Return True if the test says h is ill."""
        if h.is_ill:
            return bernoulli(IllnessTest.sensitivity)
        else:
            return not bernoulli(IllnessTest.specificity)

N = 50000 # Number of samples
false_positives = 0
true_positives = 0
ill_humans = 0

for _ in range(N):
    h = Human()
    if h.is_ill:
        ill_humans += 1
        if IllnessTest.test(h):
            # The test is positive and the human is ill.
            true_positives += 1
    else:
        if IllnessTest.test(h):
            # The test is positive and the human is healthy.
            false_positives += 1

pr_positive_test = (true_positives + false_positives) / N
pr_true_positive = true_positives / ill_humans
pr_false_positive = false_positives / (N - ill_humans)
illness_estimate = ((pr_positive_test - pr_false_positive)
                    / (pr_true_positive - pr_false_positive))

print(f'Pr[positive test]={pr_positive_test}')
print(f'Pr[false positive]={pr_false_positive} (={1-IllnessTest.specificity})')
print(f'Pr[true positive]={pr_true_positive} (={IllnessTest.sensitivity})')

```

```
print(f'Pr[nemoc]={illness_estimate} (={Human._illness_probability})')  
  
# Možný výstup:  
# Pr[positive test]=0.1976  
# Pr[false positive]=0.01945124938755512 (=0.020000000000000018)  
# Pr[true positive]=0.989760348583878 (=0.99)  
# Pr[nemoc]=0.1836 (=0.185)
```

6. V šuplíku mám $b \in \mathbb{N}$ párů bílých, $c \in \mathbb{N}$ párů černých ponožek a $s \in \mathbb{N}$ párů sepraných ponožek. Potřebuju si vytáhnout čtyři páry černých ponožek (jedu na prodloužený víkend tancovat). Když vytáhnu čtyři náhodné páry ponožek (mám je napárované v šuplíku), jaká je pravděpodobnost, že všechny budou černé?

Řešení: Dle definice podmíněné pravděpodobnosti (Definice 2.2) můžeme napsat (která pravděpodobnost musí být nenulová?):

$$\begin{aligned}\Pr[A \cap B] &= \Pr[A] \Pr[B | A] \\ \Pr[A \cap B \cap C] &= \Pr[A] \Pr[B | A] \Pr[C | A \cap B]\end{aligned}$$

Tedy můžeme psát C_1, C_2, C_3, C_4 jevy, že první, druhý, třetí, čtvrtý pár vytažených ponožek jsou černé.

$$\begin{aligned}\Pr[C_1 \cap C_2 \cap C_3 \cap C_4] &= \Pr[C_1] \Pr[C_2 | C_1] \Pr[C_3 | C_1 \cap C_2] \Pr[C_4 | C_1 \cap C_2 \cap C_3] \\ &= \left(\frac{c}{b+c+s}\right) \left(\frac{c-1}{b+c-1+s}\right) \left(\frac{c-2}{b+c-2+s}\right) \left(\frac{c-3}{b+c-3+s}\right)\end{aligned}$$

Mohli bychom spočítat kolik je čtveřic černých ze všech čtveřic (ale předchozí postup bývá užitečný):

$$\Pr[C_1 \cap C_2 \cap C_3 \cap C_4] = \frac{\binom{c}{4}}{\binom{b+c+s}{4}}$$

```
from random import sample
from scipy.special import comb
```

```
b = 10 # bílých ponožek
c = 15 # černých ponožek
s = 5  # sepraných ponožek
```

```
suplik = ['B'] * b + ['C'] * c + ['S'] * s
```

```
N = 1000000
cernych = 0
for _ in range(N):
    vyber = sample(suplik, k=4)
    if vyber == ['C'] * 4:
        cernych += 1
```

```
pr_vsechny_cerne = c*(c-1)*(c-2)*(c-3) / ((b+c+s)*(b+c-1+s)*(b+c-2+s)*(b+c-3+s))
print(f'Pr[4 cerne] = {cernych/N} ({pr_vsechny_cerne})')
```

```
pr_vsechny_cerne_komb_cislo = comb(c, 4, exact=True) / comb(b+c+s, 4, exact=True)
assert abs(pr_vsechny_cerne - pr_vsechny_cerne_komb_cislo) < 0.000001
```

```
# Možný výstup:
# Pr[4 cerne] = 0.049479 (=0.04980842911877394)
```

A, B jsou nezávislé $\Leftrightarrow \Pr[A \cap B] = \Pr[A] \Pr[B]$
 A, B, C jsou nezávislé $\Leftrightarrow \Pr[A \cap B \cap C] = \Pr[A] \Pr[B] \Pr[C]$ X ✓
 $\wedge \Pr[A \cap B] = \Pr[A] \Pr[B]$
 $\wedge \Pr[B \cap C] = \Pr[B] \Pr[C]$
 $\wedge \Pr[A \cap C] = \Pr[A] \Pr[C]$ "100% drobné" X ✓

3.3 Cvičení

1. Rozmysleme si, proč nezávislost více jevů není to samé jako nezávislost po dvou.

(a) Najděte jevy A, B, C takové, že jevy jsou po dvou nezávislé, ale $\Pr[A \cap B \cap C] \neq \Pr[A] \Pr[B] \Pr[C]$.

Řešení: Mějme pravděpodobnostní prostor hod dvěma spravedlivými mincemi $\Omega = \{HH, HO, OH, OO\}$, $\mathcal{F} = \mathcal{P}(\Omega)$, $\Pr[HH] = \Pr[HO] = \Pr[OH] = \Pr[OO] = 1/4$. Mějme jevy

$$A = \{HH, HO\}$$

$$B = \{HH, OH\}$$

$$C = \{HO, OH\}$$

tedy

$$\Pr[A] = \Pr[B] = \Pr[C] = 1/2$$

Ty jsou po dvou nezávislé:

$$\Pr[A \cap B] = \Pr[\{HH\}] = 1/4$$

$$\Pr[A \cap C] = \Pr[\{HO\}] = 1/4$$

$$\Pr[B \cap C] = \Pr[\{OH\}] = 1/4$$

Ale

$$\Pr[A \cap B \cap C] = \Pr[\emptyset] = 0 \neq 1/8 = \Pr[A] \Pr[B] \Pr[C]$$

(b) Najděte jevy A, B, C takové, že $\Pr[A \cap B \cap C] = \Pr[A] \Pr[B] \Pr[C]$, ale jevy nejsou po dvou nezávislé.

Řešení: Jedno z možných řešení: Uvažme pravděpodobnostní prostor s elementárními jevy $\Omega = \{a, b, c, z\}$ a jevy $A = \{a, z\}$, $B = \{b, z\}$, $C = \{c, z\}$. Necht' $\Pr[\{a\}] = \Pr[\{b\}] = \Pr[\{c\}] = p$ a $\Pr[\{z\}] = q$. Aby bylo $\Pr[\Omega] = 1$, musí platit $3p + q = 1$, tedy $q = 1 - 3p$. Pak máme $\Pr[A] = \Pr[B] = \Pr[C] = p + q = 1 - 2p$.

Chceme, aby jevy byly po třech nezávislé, tedy $\Pr[A \cap B \cap C] = \Pr[A] \Pr[B] \Pr[C]$. Průnik všech tří obsahuje jenom z , takže má pravděpodobnost q , všechny tři jevy na pravé straně mají pravděpodobnost $1 - 2p$. Takže musí platit $q = (1 - 2p)^3$, tedy $1 - 3p = (1 - 2p)^3$. To je kubická rovnice s jedním kořenem v intervalu $(0, 1)$, konkrétně

$$q = \frac{3 - \sqrt{3}}{4} \doteq 0.317.$$

Z toho dostaneme $p = 1 - 3q \doteq 0.049$. Máme tedy A, B, C po třech nezávislé.

Jak je to s nezávislostí po dvou? Průniky dvojic obsahují zase jenom z , takže by muselo platit $q = (1 - 2p)^2$, tedy $1 - 3p = (1 - 2p)^2$. Ale jelikož $1 - 3p$ je už rovno $(1 - 2p)^3$, nemůže to být současně $(1 - 2p)^2$, leda by bylo $1 - 2p = 1$, čili $p = 0$.

2. Házíte dvěma rozlišitelnými kostkami.

(a) Určete vhodný pravděpodobnostní prostor.

Řešení:

- Množina elementárních jevů $\Omega = \{11, 12, 13, 14, 15, 16, 21, 22, \dots, 66\}$ ($|\Omega| = 36$).
- Prostor jevů $\mathcal{F} = \mathcal{P}(\Omega)$. $A = \{11, 22, 33, 44, 55, 66\} \in \mathcal{F}$
- Pravděpodobnost je pro každý elementární jev stejná, tedy $\Pr[\{xy\}] = 1/36$ kde $x, y \in \{1, 2, 3, 4, 5, 6\}$.

(b) Spočítejte pravděpodobnost, že aspoň na jedné kostce padla šestka, když víte jaký součet padl.

Řešení: Zajímá nás

$$\Pr[\{xy\} | x + y = k] \quad (\text{kde } x, y \in \{1, 2, 3, 4, 5, 6\}, k \in \{2, 3, \dots, 12\})$$

Handwritten: {16, 26, 36, 46, 56, 66, 61, 62, ... 65}

Napřed zkusme jen chvíli přemýšlet, například pokud $k = 2$, tak určitě víme, že ani na jedné kostce nepadla šestka (protože bychom dostali součet aspoň sedm). Takže už víme

$$\Pr[\{xy\} | x + y = 2] = \Pr[\{xy\} | x + y = 3] = \dots = \Pr[\{xy\} | x + y = 6] = 0$$

Pokud bychom na to šli z druhé strany, tak pokud součet je aspoň jedenáct, tak určitě aspoň na jedné kostce padla šestka (součet deset jde získat jako součet dvou pětěk).

$$\Pr[\{xy\} | x + y = 12] = \Pr[\{xy\} | x + y = 11] = 1$$


Jak tedy dopadne pravděpodobnost, když součet je deset? Označme si jev

$$D = \{46, 55, 64\}$$

Handwritten: {46, 55, 64} circled in green

když padl součet deset. Označme si jev aspoň jedna šestka

$$S = \{16, 26, 36, 46, 56, 66, 61, 62, 63, 64, 65\}.$$



$$\begin{aligned} \Pr[S | D] &= \frac{\Pr[S \cap D]}{\Pr[D]} \\ &= \frac{\Pr[\{46, 64\}]}{\Pr[\{46, 55, 64\}]} \\ &= \frac{2}{3} \end{aligned}$$

Handwritten: The entire calculation is circled in green.

Obdobně bychom mohli spočítat zbytek. Tohle je spíš práce pro počítač (takhle malý pravděpodobnostní prostor můžeme probrat celý).

soucet[k] = kolikrát jsme viděli součet k

soucet = [0] * 13

sestek[k] = kolikrát jsme viděli aspoň jednu šestku, když součet byl k

sestek = [0] * 13

```
for i in range(1, 7):
    for j in range(1, 7):
        soucet[i + j] += 1
```

```

    if (i == 6) or (j == 6):
        sestek[i + j] += 1

for s in range(2, 13):
    print(f'Pr[aspoň jedna šestka | součet = {s}] = {sestek[s]}/{soucet[s]}')

# Výstup:
# Pr[aspoň jedna šestka | součet = 2] = 0/1
# Pr[aspoň jedna šestka | součet = 3] = 0/2
# Pr[aspoň jedna šestka | součet = 4] = 0/3
# Pr[aspoň jedna šestka | součet = 5] = 0/4
# Pr[aspoň jedna šestka | součet = 6] = 0/5
# Pr[aspoň jedna šestka | součet = 7] = 2/6 = 1/3
# Pr[aspoň jedna šestka | součet = 8] = 2/5
# Pr[aspoň jedna šestka | součet = 9] = 2/4
# Pr[aspoň jedna šestka | součet = 10] = 2/3
# Pr[aspoň jedna šestka | součet = 11] = 2/2
# Pr[aspoň jedna šestka | součet = 12] = 1/1

```

Mohli bychom i simulovat i přesně počítat pomocí jazyka R, skript napsal Robert Šámal:

```

---
title: "cvici-simulace kostek"
output:
  pdf_document: default
  html_notebook: default
---

# Simulace

Napřed jednoduché hrátky s házením jednou kostkou.
Příkaz sample vrací datový typ vector, s tím se dá vektorově pracovat.

```{r}
N=10
kostka = sample(1:6, N, replace=TRUE)
kostka
#2*kostka
#kostka==1
#sum(kostka==1)
#kostka[c(1,2,3,4)]
#kostka[kostka<=3]
#sum(kostka==1)+sum(kostka==2)+sum(kostka==3)+sum(kostka==4)+sum(kostka==5)+sum(kostka==6)
```

A teď se dostáváme k simulaci domácího úkolu s kostkami.
Všimněte si, jak podmíněná pravděpodobnost znamená vlastně to,
že se omezíme (v čitateli i ve jmenovateli) na ty souřadnice, kde platí podmiňující jev.

```{r}
N = 10^4

kostka1 = sample(1:6, N, replace=TRUE)
kostka2 = sample(1:6, N, replace=TRUE)
soucet = kostka1 + kostka2

```

```

SD = soucet==10
PS = kostka1==6
NS = kostka1==6 | kostka2==6

cat("\nP(SD)=", sum(SD)/N)
cat("\nP(PS)=", sum(PS)/N)
cat("\nP(NS)=", sum(NS)/N)

cat("\nP(PS|SD)=", sum(PS & SD)/sum(SD))
cat("\nP(NS|SD)=", sum(NS & SD)/sum(SD))
cat("\nP(PS|NS)=", sum(PS & NS)/sum(NS))
cat("\nP(SD|NS)=", sum(SD & NS)/sum(NS))
cat("\nP(NS|PS)=", sum(NS & PS)/sum(PS))
cat("\nP(SD|PS)=", sum(SD & PS)/sum(PS))
cat("\n")
c(6/11, 1/6, 1/12, 1/3, 2/3, 2/11,11/36)
...

Projití celého pravděpodobnostního prostoru

Funguje jen pro malé prostory, jinak trvá moc dlouho!

```{r}
Omega = expand.grid(k1=1:6,k2=1:6)
kostka1 = Omega$k1; kostka1
kostka2 = Omega$k2; kostka2
soucet = kostka1 + kostka2
N = length(kostka1)
SD = soucet==10

Omega$soucet = soucet
Omega$SD = SD
Omega

SD
PS = kostka1==6
NS = kostka1==6 | kostka2==6

cat("\nP(SD)=", sum(SD)/N)
cat("\nP(PS)=", sum(PS)/N)
cat("\nP(NS)=", sum(NS)/N)

cat("\nP(PS|SD)=", sum(PS & SD)/sum(SD))
cat("\nP(NS|SD)=", sum(NS & SD)/sum(SD))
cat("\nP(PS|NS)=", sum(PS & NS)/sum(NS))
cat("\nP(SD|NS)=", sum(SD & NS)/sum(NS))
cat("\nP(NS|PS)=", sum(NS & PS)/sum(PS))
cat("\nP(SD|PS)=", sum(SD & PS)/sum(PS))
cat("\n")
...

```


- 1) vyloží se mince,
- 2) 6x s ní hodím

$$Pr[\text{dvouorlová} | 000000] = ?$$

pravděpodobně

3. V truhle je sto mincí. Z nich 99 je normálních, ale jedna má na obou stranách orla.

(a) Určete vhodný pravděpodobnostní prostor.

Řešení:

- Množina elementárních jevů (mince jsou očíslované):

$$\Omega = \left\{ \begin{array}{l} 1 - HHHHHH, \\ 1 - HHHHHO, \\ \dots \\ 1 - OOOOOO, \\ 2 - HHHHHH, \\ \dots \\ 99 - HHHHHH, \\ \dots \\ 99 - OOOOOO, \\ 100 - OOOOOO \end{array} \right\}$$

Handwritten notes: $\forall j \quad Pr[\text{mince } j] = \frac{1}{100}$

- Prostor jevů $\mathcal{F} = \mathcal{P}(\Omega)$.
- Pravděpodobnost vytažení každé mince je stejná. Pravděpodobnost že spravedlivou mincí naházíme něco je stejná jako že s ní naházíme něco jiného.

$$Pr[j - ABCDEF] = \frac{1}{100 \cdot 2^6} \quad (\text{pro každé } 1 \leq j \leq 99, A, B, C, D, E, F \in \{H, O\})$$

$$Pr[100 - OOOOOO] = \frac{1}{100}$$

Handwritten note: $Pr[\text{dvouorlová} | \text{vidím } 000000] = ?$

(b) Vytáhneme náhodnou minci a šestkrát s ní hodíme, pokaždé padne orel. Jaká je pravděpodobnost, že jsme si vytáhli dvouorlovou minci? (Zkuste napřed odhadnout, pak spočítat.)

Řešení: Značme

$$O_2 = \{100 - OOOOOO\}$$

$$O_6 = \{1 - OOOOOO, 2 - OOOOOO, \dots, 100 - OOOOOO\}$$

pak píšeme

$$\begin{aligned} Pr[\text{dvouorlová} | \text{šest orlů}] &= Pr [O_2 | O_6] \\ &= \frac{Pr [O_2 \cap O_6]}{Pr [O_6]} \\ &= \frac{Pr [O_2]}{Pr [O_6]} \\ &= \frac{\frac{1}{100}}{\frac{99}{100 \cdot 2^6} + \frac{1}{100}} \\ &\approx 0.3826 \end{aligned}$$

(c) Simulujte.

Řešení:

```

from random import choice
from random import choices

class FairCoin:
    dvou_orlova = False
    def toss(self):
        return choices([True, False], k=6)

class DvouOrlova:
    dvou_orlova = True
    def toss(self):
        return [True] * 6

mince = [FairCoin()] * 99 + [DvouOrlova()]

N = 10000000
sest_orlu = 0
dvouorlovych = 0

for _ in range(N):
    m = choice(mince)
    if all(m.toss()):
        sest_orlu += 1
    if m.dvou_orlova:
        dvouorlovych += 1

exact = 0.01 / (0.01 + 0.99*2**(-6))
print(f'Pr[dvouorlova|000000] = {dvouorlovych/sest_orlu} (={exact})')

# Možný výstup:
# Pr[dvouorlova|000000] = 0.3895867899186221 (=0.39263803680981596)

```

↑
TODO?

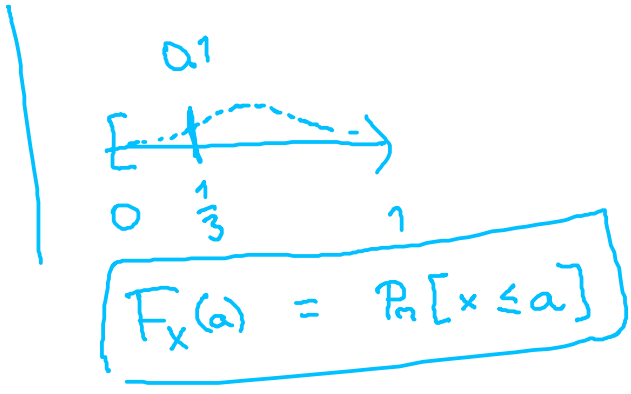
$$\rightarrow P_X(x) = P_n[X=x]$$

$$\rightarrow F_X(x) = P_n[X \leq x]$$

diskrétní pravděpodobnost
kole je nám jasně

spojitá
 $x \in [0, 1)$ unif. měloshná
 $P_n[x \in A] = \text{míra } A$
 A je interval = dílek
 A spojitě U intervalů
 $= \sum \text{dílek}$





$$F_x(a) = P_n[x \leq a]$$

mám pravděpodob. prostor (Ω, \mathcal{F}, P)

$X: \Omega \rightarrow \mathbb{R}$
 $x \in \text{Im}[X]$

je náh. veličina ... $\text{Im}[X]$ je apod. množina

$$X^{-1}(x) = \{\omega \in \Omega \mid X(\omega) = x\} \in \mathcal{F}$$

3.3. 3. CVIČENÍ

$$\mathbb{E}[X] = \sum_{x \in \text{Im}(X)} x \cdot P[X=x]$$

4. Připomeňme co je náhodná veličina a její střední hodnota.

Řešení: Například objem alkoholu.

from random import choice

```
alcohol_content = {
    "světlé pivo" : 0.045 * 0.5, # 4,5% 0.5 litru
    "tmavé pivo" : 0.04 * 0.5, # 4% 0.5 litru
    "slivovice" : 0.51 * 0.04, # 51% 0.04 litru
    "bílé víno" : 0.11 * 0.2, # 11% 0.2 litru
    "červené víno" : 0.11 * 0.2, # 11% 0.2 litru
    "čaj" : 0.52 * 0.04, # 52% 0.04 litru
}
```

? objem alkoholu



```
def drink():
    # Vrací jeden elementární jev z Omega.
    return choice(list(alcohol_content.keys()))
```

```
def X(drink):
    # Vrací objem vypitého alkoholu v litrech.
    # X: Omega -> R
    return alcohol_content[drink]
```

```
N = 100
alkohol = 0.0
for _ in range(N):
    alkohol += X(drink())
```

```
EX = sum(alcohol_content.values()) / len(alcohol_content)
```

```
print(f'Střední hodnota objemu alkoholu v jednom drinku je {alkohol / N} (= {EX})')
```


```
# Možný výstup:
# E[alkohol] je 0.021088999999999999 (= 0.021283333333333335)
```

$$\begin{aligned} \mathbb{E}[X] &= \sum_{x \in \text{Im}(x)} x \Pr[X = x] \\ &= \sum_{x \in \text{Im}(x)} x \Pr[\{\omega \in \Omega \mid X(\omega) = x\}] \\ &= 0.0225 \Pr[\{\text{světlé pivo}\}] \\ &\quad + 0.02 \Pr[\{\text{tmavé pivo}\}] \\ &\quad + 0.0204 \Pr[\{\text{slivovice}\}] \\ &\quad + 0.022 \Pr[\{\text{červené víno, bílé víno}\}] \\ &\quad + 0.0208 \Pr[\{\text{čaj}\}] \end{aligned}$$

Co kdyby pravděpodobnost kostky nebyla uniformní?

Řešení: Vzorec se nemění, akorát se mění pravděpodobnost jevů $\Pr[X = x]$.





$k, \ell \in \mathbb{N}$



1) mechanická volba dvěma
 $\Pr[\text{vezmu větší}] = \frac{1}{2}$
 $\mathbb{E}[\text{w ai vezmu}] = k \cdot \frac{1}{2} + \ell \cdot \frac{1}{2}$

3.3. 3. CVIČENÍ

53

5. Na stole jsou dvě obálky, v jedné je k korun, ve druhé ℓ korun ($k, \ell \in \mathbb{N}$). Můžete otevřít jednu obálku a na základě sumy v ní se rozhodnout jestli si necháte tu otevřenou nebo si vezmete tu druhou (nehledě na to, kolik je v té druhé). Umíte vymyslet způsob jak odejít s tou s větším obnosem s pravděpodobností ostře větší než jedna polovina? Určete střední hodnotu výhry.

Řešení: Uniformně náhodně zvolíme první obálku. Pokud vidíme m korun, pak házíme spravedlivou mincí, dokud nepadne hlava. Pokud celkový počet hodů je ostře menší než m , pak si obálku necháme, jinak si vezmeme tu druhou. Když $k < \ell$ tak pravděpodobnost, že vyměníme obálku s k korunami je ostře větší než pravděpodobnost, že vyměníme obálku s ℓ korunami.

Vzpomeňte na geometrické rozdělení z minulého cvičení. Pravděpodobnost, že odejdu s k korunami je

$$\begin{aligned} \Pr[\text{dostanu } k \text{ Kč}] &= \frac{1}{2}(1 - 0.5^{k-1}) + \frac{1}{2}0.5^{\ell-1} \\ &= \frac{1}{2} - 0.5^k + 0.5^\ell \\ &= \frac{1}{2} + (0.5^\ell - 0.5^k) \end{aligned}$$

Handwritten notes:
 $\rightarrow 0$
 $\frac{1}{2} > \ell$
 $\frac{1}{2} > k$

Střední hodnota výhry

$$\mathbb{E}[\text{win}] = k \left(\frac{1}{2} + (0.5^\ell - 0.5^k) \right) + \ell \left(\frac{1}{2} + (0.5^k - 0.5^\ell) \right)$$

```
from random import randint
from random import random
```

```
def geometric(pr: float = 0.5) -> int:
    """pr is success probability, return the number of tosses until
    the first success."""
    assert pr > 0
    sample = 1
    fail_pr = 1 - pr
    while random() < fail_pr:
        sample += 1
    return sample
```

```
# Our unknown amounts.
envelopes = [5, 10]
```

```
N = 1000000 # Number of samples.
total_amount = 0 # Total sum that we got during all samples.
got_larger = 0 # Number of times we walked away with the larger sum.
```

```
for _ in range(N):
    # Pick the first envelope at random.
    chosen = randint(0, 1)
    if geometric() < envelopes[chosen]:
        # Keep this one.
        pass
    else:
```

```
# Choose the other.
chosen = 1 - chosen
if envelopes[chosen] >= envelopes[1 - chosen]:
    got_larger += 1
    total_amount += envelopes[chosen]

print(f'Pr[selected larger] = {got_larger / N}')
print(f'E[win] = {total_amount / N}')

# Possible outcome:
# Pr[selected larger] = 0.530087
# E[win] = 7.650435
```


+ 3%
+ 15 milia

6. Spočítejte střední počet porovnání quick-sortu:

```
from random import randint
```

```
def partition(arr, begin, end):
    pivot_i = randint(begin, end - 1)
    (arr[pivot_i], arr[end-1]) = (arr[end-1], arr[pivot_i])
    pivot = arr[end - 1]
    i = begin
    for j in range(begin, end):
        if arr[j] < pivot:
            (arr[i], arr[j]) = (arr[j], arr[i])
            i += 1
    (arr[i], arr[end-1]) = (arr[end-1], arr[i])
    return i
```

```
def quick_sort(arr, begin, end):
    if end <= begin:
        return
    p = partition(arr, begin, end)
    quick_sort(arr, begin, p)
    quick_sort(arr, p+1, end)
```



- (a) Uvědomte si, že každá dvě čísla porovnáte nejvýš jednou (pokud se žádné číslo neopakuje). Pro jednoduchost budeme předpokládat, že se čísla neopakují (jinak bychom museli mluvit o jejich pozici v utříděném poli).
- (b) Vytvořte vhodný pravděpodobnostní prostor.

14, náhodná volba alg.

Řešení: Tohle je příklad ne příliš pěkného pravděpodobnostního prostoru. Uvidíte, že daleko lépe se bude pracovat s náhodnými proměnnými.

Ale běh algoritmu je dán permutací na vstupu a volbami pivotů. Tedy například můžeme vzít jako jeden elementární jev vstupní permutaci a stack-trace algoritmu (na které intervaly se rekurzí a jaké pivoty se volí).

Prostor jevů bude potenční množina (množina elementárních jevů je konečná).

Navrhnout pravděpodobnost není tak jednoduché (zkuste). Počítat s ní není nic moc příjemného.

I kdybychom si uvědomili, že doba běhu naší implementace nezávisí na vstupní permutaci (místo výběru pivota někde bychom ho vybrali jinde), tak tento pravděpodobnostní prostor není žádný med.


$$C = \sum_{i=1}^n \sum_{j=i+1}^n C_{i,j}$$

$C_{i,j}$... indikátor $\begin{cases} 1 & \text{pokud } i, j \text{ se porovnaly} \\ 0 & \text{jinak} \end{cases}$ i -tý nejmenší j -tý největší


- (c) Definujte náhodnou proměnnou určující počet porovnaných dvojic, vyjádřete ji jako součet jednodušších a použijte větu o linearitě střední hodnoty.

Řešení: Zajímá nás střední hodnota C , což je počet porovnání. Každé dva prvky výsledku potenciálně mohou být porovnány. Tedy volme $C_{i,j}$ náhodnou proměnnou, která je rovna jedné pokud i -té nejmenší číslo je porovnáno s j -tým nejmenším číslem (kde bereme $1 \leq i < j \leq n$) a nule jinak. Takovým $C_{i,j}$ říkáme *indikátorová proměnná*.

Uvědomme si, že pokud nějaké k -té nejmenší číslo kde $i < k < j$ je zvoleno jako pivot před tím, než se pivotem stane i nebo j , tak $C_{i,j} = 0$, ale jinak je rovna jedné. Tedy



$E[C] = ?$



$C_{i,j} = 1 \Leftrightarrow \text{se porovnaly}$

$$\Pr[C_{i,j} = 1] = \frac{2}{j-i+1}$$

$E[C_{i,j}] = ?$

Nás zajímá střední hodnota

$$\begin{aligned} E[C_{i,j}] &= 1 \cdot \frac{2}{j-i+1} + 0 \cdot \left(1 - \frac{2}{j-i+1}\right) \\ &= \frac{2}{j-i+1} \end{aligned}$$

$= \Pr[C_{i,j} = 1]$
↑ první indikátorové n.r.

Ve skutečnosti nás ale zajímá střední hodnota počtu všech porovnání

$\forall X, Y$ n.r. $\forall a, b \in \mathbb{R}$
 $E[a \cdot X + b \cdot Y] = a \cdot E[X] + b \cdot E[Y]$
(distributivita)

$$E[C] = E\left[\sum_{i=1}^{n-1} \sum_{j=i+1}^n C_{i,j}\right]$$

$$= \sum_{i=1}^{n-1} \sum_{j=i+1}^n E[C_{i,j}] \quad \text{(linearita střední hodnoty)}$$

$$= \sum_{i=1}^{n-1} \sum_{j=i+1}^n \frac{2}{j-i+1}$$

$$= \sum_{i=1}^{n-1} \sum_{d=1}^{n-i} \frac{2}{d+1}$$

$d = j - i$
 $H_n = \sum_{j=1}^n \frac{1}{j}$ harmonické číslo

$$\begin{aligned} &= \sum_{i=1}^{n-1} 2(H_{n-i+1} - 1) \\ &\leq \sum_{i=1}^{n-1} 2 \ln(n) \\ &= 2n \ln(n) \end{aligned}$$

= střední hodnota počtu porovnání quick-sortu je $2n \ln(n)$

(d) S jakou pravděpodobností provede quick-sort aspoň $10n \ln(n)$ porovnání?

- Sčítáme n kladných reálných čísel $a_1, a_2, \dots, a_n \in [0, \infty)$. Víme, že

$$\sum_{i=1}^n a_i = S$$

Pro kolik z těch čísel platí $a_j \geq 5S/n$?

$$0 + 0 + \dots + \frac{5S}{n} + \frac{5S}{n} + \dots + \frac{5S}{n} \leq \frac{5S}{n}$$

Řešení: Nejvýš pro $n/5$ z těch čísel. I kdyby ostatní byla nulová a tato velká byla přesně tolik, pak $(n/5)(5S/n) = S$.

- Co kdybychom ta čísla sčítali váženě? Tedy formálně: mějme náhodnou proměnnou o které víme $\Pr[X = j]$ pro $j \in \{1, 2, \dots, m\}$ (kde pro jednoduchost předpokládáme $\sum_{j=1}^m \Pr[X = j] = 1$, tedy že X má hodnoty $1, 2, \dots, m$). Víme $E[X] = \sum_{j=1}^m j \Pr[X = j] = S$. Jaká je pravděpodobnost $\Pr[X \geq 5S]$?

Řešení: Obdobně

$$S = E[X]$$

$$\begin{aligned}
&= \sum_{j=1}^m j \Pr[X = j] && \text{(protože } \text{Im}(X) = \{1, 2, \dots, m\}\text{)} \\
&\geq \sum_{j=5S}^m j \Pr[X = j] \\
&\geq \sum_{j=5S}^m 5S \Pr[X = j] \\
\text{S} &\geq \underbrace{= 5S \Pr[X \geq 5S]} && \Pr[X \geq 5S] \leq \frac{1}{5} \\
\text{tedy} &
\end{aligned}$$

$$\Pr[X \geq 5S] \leq 1/5$$

- Gratuluji, vymysleli jste Markovovu nerovnost.
- Často bývá mnohem jednodušší použít Markovovu nerovnost než přímo počítat pravděpodobnost. Občas můžeme dostat i silnější odhady pomocí Čebyševovy nebo Černovovy nerovnosti. Na to budeme potřebovat rozptyl a další znalosti o náhodných proměnných.