

# 5. cvičení z PaSti – 2022-03-15

## Tahák

- *Střední hodnota* veličiny  $X$ :  $\mathbb{E}(X) = \sum_t t \cdot P(X = T)$ .
- *Linearita střední hodnoty*:  $\mathbb{E}(X + Y) = \mathbb{E}(X) + \mathbb{E}(Y)$ ,  $\mathbb{E}(\alpha X) = \alpha \mathbb{E}(X)$ .
- *Rozbor případů*:  $\mathbb{E}(X) = \mathbb{E}(X | A) \cdot P(A) + \mathbb{E}(X | A^c) \cdot P(A^c)$ .
- *LOTUS (pravidlo naivního statistika)*:  $\mathbb{E}(g(X)) = \sum_a g(a) \cdot P(X = a)$ .
- *Indikátorová náhodná veličina*  $I_A$  jevu  $A$  nabývá hodnot 0 a 1, přičemž  $I_A = 1 \Leftrightarrow A$  nastane. Platí, že  $\mathbb{E}(I_A) = P(A)$ .
- *Rozptyl*  $\text{var}(X) = \mathbb{E}((X - \mathbb{E}(X))^2) = \mathbb{E}(X^2) - (\mathbb{E}(X))^2$ .
- Veličiny  $X$  a  $Y$  jsou *nezávislé*  $\Leftrightarrow P(X = a \wedge Y = b) = P(X = a) \cdot P(Y = b)$ .
- Pro  $X, Y$  nezávislé platí  $\mathbb{E}(XY) = \mathbb{E}(X)\mathbb{E}(Y)$ .

## Na zahřátí

1. Mějme neorientovaný graf  $G = (V, E)$ . Vybereme náhodně podmnožinu vrcholů  $V' \subseteq V$  tak, že pro každý vrchol si hodíme mincí, zda ho dáme do  $V'$ . Jaká je střední hodnota počtu hran, které vedou mezi  $V'$  a  $V \setminus V'$ ?
2. Hodíme třemi kostkami a výsledek přečteme jako tříciferné číslo. Jaká je jeho střední hodnota?
3. Hodíme dvěma kostkami a výsledek přečteme jako dvojciferné číslo, přičemž kostku s větší hodnotou použijeme pro řád desítek. Jaká je teď střední hodnota?

## Zacházení se střední hodnotou a rozptylem

4. Nechť  $X, Y$  jsou diskrétní n.v. a  $\alpha \in \mathbb{R}$ .

- (a) Ukažte, že  $\text{var}(X + \alpha) = \text{var}(X)$ .
- (b) Vyjádřete  $\text{var}(\alpha X)$  pomocí  $\text{var}(X)$ .
- (c) Ukažte, že  $\text{var}(X + Y) = \text{var}(X) + \text{var}(Y)$ , pokud  $X, Y$  jsou nezávislé.

5. Dokažte:

- (a) Pokud  $\mathbb{E}(X^2) = 0$ , tak  $P(X = 0) = 1$ .
- (b) Předpokládejme, že  $\text{var}(X) = 0$ , dále že  $\mathbb{E}(X)$  existuje a je konečná. Pak  $X = \mathbb{E}(X)$  skoro jistě, neboli  $P(X = \mathbb{E}(X)) = 1$ .

## Podmíněná střední hodnota

6. V testu je 20 otázek s volbami  $\{a, b, c, d\}$ , vždy je správná právě jedna odpověď. Za správnou odpověď dostanete 1 bod, za špatnou  $-1/4$  bodu, za nevyplněnou otázku nula. Každá otázka je s pravděpodobností  $p$  jednou z těch, co se Kvído naučil, a tedy zná správnou odpověď. Pokud správnou odpověď nezná, ví o tom a může se rozhodnout, zda tipovat.

- (a) Jaká je střední hodnota počtu bodů, které Kvído získá, pokud bude odpovídat jenom na otázky, u kterých zná odpověď?
- (b) A co když bude tipovat, když nezná správnou odpověď?
- (c) Jak by se musela změnit penalizace za chybnou odpověď, aby byly odpovědi v částech a, b stejné?

7. Házíme běžnou kostkou, při šestce házíme znovu, a to i opakovaně. Spočítejte střední hodnotu součtu všech hozených čísel.

## Nezávislost

8. Ukažte, že jevy  $A, B$  jsou nezávislé, právě když jsou nezávislé jejich indikátorové veličiny.

9. Ukažte, že pro diskrétní nezávislé n.v.  $X, Y$  platí

$$P(X \leq x \wedge Y \leq y) = P(X \leq x) \cdot P(Y \leq y).$$

Pro jednoduchost můžete předpokládat, že  $\text{Im}(X) = \text{Im}(Y) = \{1, 2, \dots, n\}$  pro nějaké  $n$ .

## Bonusy

10. Velký hon:  $n$  myslivců se snaží ulovit  $n$  lišek. Míří náhodně: každý myslivec strefí rovnoměrně náhodně vybranou lišku. Spočítejte střední počet lišek, které hon přežijí (nikdo je netrefil).

11. Mějme náhodnou permutaci  $\pi$  na množině  $\{1, \dots, n\}$ . Prvek  $i$  je *levým maximem*, pokud  $\pi(j) < \pi(i)$  pro všechna  $j < i$ . Jaká je střední hodnota počtu levých maxim? Analogie: různě vysokí lidé stojí ve frontě, kolik z nich vidí na začátek fronty?

12. Připomeňte si definici indikátorové náhodné veličiny  $I_A$ .

- (a) Necht  $A = A_1 \cup A_2 \cup \dots \cup A_n$ . Ověřte rovnost

$$1 - I_A = \prod_{i=1}^n (1 - I_{A_i}).$$

- (b) Roznásobte a použijte větu o linearitě střední hodnoty, abyste získali princip inkluze a exkluze.

## Pravděpodobnostní rozdělení v Pythonu

```
import scipy.stats as stats

# Pořídíme si binomiální rozdělení s danými parametry
n = 20
p = 0.3
b = stats.binom(n, p)

# Necháme si vygenerovat náhodný vzorek
print('RVS:', b.rvs(size=20))

# Pravděpodobnostní funkce (Probability Mass Function)
print('PMF:', [b.pmf(x) for x in range(0, n+1)])

# Distribuční funkce (Cumulative Distribution Function)
print('CDF:', [b.cdf(x) for x in range(0, n+1)])

# Kvantily ("inverze" k CDF, Percent Point Function)
print('Quantile 0.1:', b.ppf(0.1))
print('Quantile 0.9:', b.ppf(0.9))

# Střední hodnota, rozptyl a směrodatná odchylka
print('Mean:', b.mean())
print('Variance:', b.var())
print('Std deviation:', b.std())

# Také se jde přímo zeptat na vlastnosti rozdělení s konkrétními
# parametry, aniž bychom ho explicitně konstruovali.
print(stats.binom.rvs(n, p, size=20))
```

## Kreslíme obrázky


```
import numpy as np
import scipy.stats as stats
import matplotlib.pyplot as plt

# Rozdělení
n = 20
p = 0.3
b = stats.binom(n, p)


# Jeden obrázek
fig, ax = plt.subplots(1, 1)
x = np.arange(0, n+1)
ax.plot(x, b.pmf(x), 'bo', ms=8, label='binom pmf')
ax.vlines(x, 0, b.pmf(x), colors='b', lw=5, alpha=0.5)
ax.legend()
plt.show()

# Nebo více obrázků pohromadě
fig, ax = plt.subplots(1, 2)
x = np.arange(0, n+1)
ax[0].set_ylim(0, 1)
ax[0].plot(x, b.pmf(x), 'bo', ms=8, label='binom pmf')
ax[0].vlines(x, 0, b.pmf(x), colors='b', lw=5, alpha=0.5)
ax[0].legend()
ax[1].plot(x, b.cdf(x), 'r', label='binom cdf')
ax[1].legend()
plt.show()
```


Binomial( $n=30$ ,  $p=0.3$ )







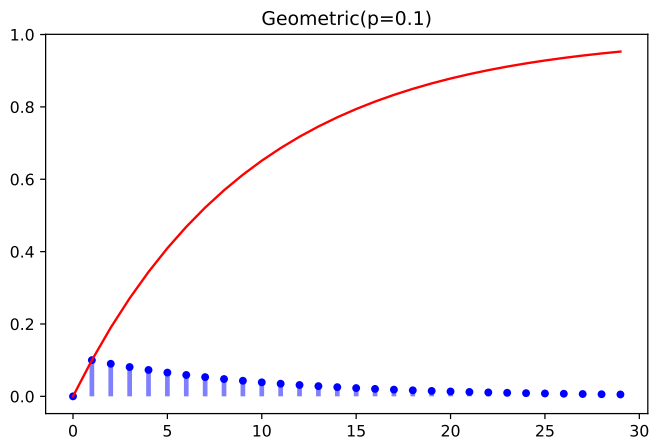

Binomial( $n=30$ ,  $p=0.5$ )




Binomial( $n=30$ ,  $p=0.9$ )








Poisson( $\mu=1$ )



Poisson( $\mu=5$ )



Poisson( $\mu=30$ )

