

# DISKRETNE SLUČAJNE VARIJABLE

# **Diskretne slučajne varijable**

**UVOD**

**DISKRETNE SLUČAJNE VARIJABLE**

**BERNOULLIJEVI POKUSI**

**BINOMNA RASPODJELA**

**POISSONOVA RASPODJELA**

**HIPERGEOMETRIJSKA RASPODJELA**

## UVOD

- **slučajna varijabla** je veličina čije vrijednosti ovise o ishodu slučajnog pokusa, tj. ovisno o pojedinom slučaju dobiva različite vrijednosti
- slučajnoj varijabli je pridružena neka **raspodjela vjerojatnosti**

**primjer: bacanje novčića**

prostor elementarnih događaja

$$\Omega = \{G, P\}$$

slučajna varijabla

$$X(\omega) = \begin{cases} 0, & \omega = G \\ 1, & \omega = P \end{cases}$$

## DISKRETNE SLUČAJNE VARIJABLE

- slučajne varijable mogu biti **diskretne ili kontinuirane**
- **diskretna slučajna varijabla** može poprimati konačno ili prebrojivo mnogo vrijednosti
- diskretna slučajna varijabla **karakterizirana** je svojom **raspodjelom**, odnosno **vrijednostima**  $x_1, x_2, \dots$  koje može poprimiti i **odgovarajućim vjerojatnostima**  $p(x_1), p(x_2)$ , općenito  $p_i = P(X = x_i)$ , koje te vrijednosti imaju
- skup svih parova  $\{x_i, p(x_i)\}$  tvori **razdiobu (distribuciju) slučajne varijable  $x$**
- **funkcija vjerojatnosti diskretne slučajne varijable** je jednoznačno preslikavanje skupa  $x_i$  u skup  $p_i$ , a opisuje kako se vjerojatnost ishoda mijenja s njegovom brojčanom vrijednošću

## DISKRETNE SLUČAJNE VARIJABLE

- za diskretnu slučajnu varijablu koja može poprimiti vrijednosti  $x_1, x_2, \dots$  **funkcija vjerojatnosti** je funkcija za koju vrijedi:

$$f(x_i) \geq 0$$

$$\sum_{i=1}^n f(x_i) = 1$$

$$f(x_i) = P(X = x_i)$$

- **kumulativna funkcija raspodjele** diskretne slučajne varijable  $X$  je funkcija sa sljedećim svojstvima

$$F(x_0) = \sum_{x_i \leq x_0} p(x_i)$$

$$F(x) = P(X \leq x) = \sum_{x_i \leq x} f(x_i)$$

$$0 \leq F(x) \leq 1$$

$$x \leq y \Rightarrow F(x) \leq F(y)$$

ta funkcija pokazuje kolika je vjerojatnost da slučajna varijabla  $x$  poprimi bilo koju vrijednost manju od  $x_0$  ili jednako  $x_0$

## DISKRETNE SLUČAJNE VARIJABLE

- **srednja ili očekivana vrijednost** diskretne slučajne varijable je

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad \bar{x} = \sum_{i=1}^r f_i x_i$$

- zbroj udaljenosti svih slučajnih varijabli od njihove srednje ili očekivane vrijednosti jednak je nuli (*analogija sa osnovama statistike i srednjom vrijednosti gdje smo rekli da je srednja vrijednost ona za koju vrijedi da je oko nje suma odstupanja nula*)

$$\sum_{i=1}^r f_i (x_i - \bar{x}) = 0$$

Teorem  $\bar{y} = a \cdot \bar{x} + b$

## PRIMJER.

Označimo s  $x$  ishod bacanja kocke. Tada slučajna varijabla  $x$  može poprimiti vrijednosti 1, 2, 3, 4, 5, 6, svaka ima vjerojatnost  $1/6$ .

Kolika je očekivana vrijednost?

$$\bar{x} = \sum_i x_i \cdot p(x_i) = 1 \cdot 1/6 + 2 \cdot 1/6 + 3 \cdot 1/6 + 4 \cdot 1/6 + 5 \cdot 1/6 + 6 \cdot 1/6 = 3,5$$

Očekivana vrijednost je 3,5.

Uvedemo novi varijablu  $y$  koju definiramo kao  $y = 2x + 1$ .

Kolika je njena očekivana vrijednost?

$$\bar{y} = 3 \cdot 1/6 + 5 \cdot 1/6 + \dots + 13 \cdot 1/6 = 8$$

Isti rezultat dobijemo koristeći relaciju

$$\bar{y} = 2 \cdot \bar{x} + 1$$

## DISKRETNE SLUČAJNE VARIJABLE

- **medijan** diskretne slučajne varijable
- ukoliko je broj podataka neparan, za medijan se uzima vrijednost srednjeg podatka
- ukoliko je broj podataka paran, za medijan se uzima srednja vrijednost dva srednja podatka

20 19 17 **15** 3 2 1

10 9 **8** 4 3 2

**6**



## DISKRETNE SLUČAJNE VARIJABLE

**varijanca** diskretne slučajne varijable

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$

$$\sigma^2 = \sum_{i=1}^r f_i (x_i - \bar{x})^2$$

**varijanca** govori o raspršenju slučajnih varijabli oko njihove srednje vrijednosti, a naziva se još i srednji kvadrat odstupanja

## DISKRETNE SLUČAJNE VARIJABLE

**standardna devijacija** je drugi korijen varijance

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} = \sqrt{\sum_{i=1}^r f_i (x_i - \bar{x})^2}$$

standardna devijacija je dimenzijski jednaka diskretnoj slučajnoj varijabli  $x$

## BERNOULLIJEVI POKUSI

- ***Bernoullijevi pokusi*** - **neovisni pokusi** koji se ponavljaju i kod kojih postoje **samo dva moguća ishoda** za svaki pokus te se vjerojatnosti tih ishoda **ne mijenjaju** tijekom pokusa (npr. niz neovisnih bacanja novčića, npr. bacanje kocke uz pitanje “dobivam 6”, ...)
- vjerojatnost koja odgovara povoljnom ishodu pokusa se označava s  **$p$** , vjerojatnost koja odgovara nepovoljnom ishodu pokusa se označava s  **$q$**
- $p$  i  $q$  moraju biti neke **nenegativne vrijednosti** te mora vrijediti:  $p + q = 1$ ,  $q = 1 - p$

## BERNOULLIJEVI POKUSI

- **prostor elementarnih događaja** za svaki pojedini pokus se sastoji od ukupno **dvije točke** (povoljni ishod, engl. *success (S)* i nepovoljni ishod, engl. *Failure (F)*)
- prostor elementarnih događaja za **ukupno  $n$  Bernoullijevih pokusa** sastoji od ukupno  **$2^n$  točaka**, a budući da su **pokus** međusobno **neovisni**, ukupna vjerojatnost je **umnožak njihovih pojedinih vjerojatnosti**

$$P\{(S,S,F,S)\} = ppqp = pp(1-p)p = p^3(1-p)^1$$

$$\begin{aligned} P\{(F,S,F,S,F,S)\} &= qpqpqp = (1-p)p(1-p)p(1-p)p \\ &= p^3(1-p)^3 \end{aligned}$$

## BERNOULLIJEVI POKUSI

Općenito, za Bernoullijev pokus vrijedi da je vjerojatnost nastupanja povoljnog ishoda  $x$  puta u  $n$  Bernoullijevih pokusa (ALI S TOČNO ZADANIM REDOSLIJEDOM NASTUPANJA POVOLJNIH I NEPOVOLJNIH ISHODA) dana izrazom:

$$P_{x,n-x}^n = p^x q^{n-x} = p^x (1-p)^{n-x}$$

Bernoullijeva shema pokusa je samo teorijski model i jedino iskustvo može pokazati da li je takva shema prikladna za opis određenih opažanja.

## BERNOULLIJEVI POKUSI

Primjer.

Kolika je vjerojatnost da u tri bacanja novčića padne grb, a zatim dva pisma?

$$P_{x,n-x}^n = p^x q^{n-x} = p^x (1-p)^{n-x}$$

GPP

$$P=0,5^1 * 0,5^2 = 0,125$$

**ŠTO AKO NAS NE ZANIMA REDOSLIJED DOGAĐAJA, NEGO SAMO ISHOD?**

Primjer.

Kolika je vjerojatnost da u tri bacanja novčića padne grb i dva pisma?

GPP   PGP   PPG

- svaka od tih kombinacija ima istu vjerojatnost od 0,125

$$P=0,125*3=0,375$$

## BINOMNA RASPODJELA

Ukoliko nas **ne zanima** redoslijed nastupanja povoljnih i nepovoljnih ishoda, onda je vjerojatnost nastupanja povoljnog ishoda  **$x$**  puta u  **$n$  Bernoullijevih pokusa** dana izrazom:

$$P_{x,n-x}^n = \binom{n}{x} p^x q^{n-x}$$

$\binom{n}{x}$  predstavlja broj načina na koji se dana kombinacija uspjeha i neuspjeha može ostvariti

**$n$**  – broj Bernoullijevih pokusa

**$x$**  – broj pokusa s uspješnim ishodom

**$n-x$**  – broj pokusa s neuspješnim ishodom

## BINOMNA RASPODJELA

### primjer:

Ako se simetrični novčić baca 4 puta zaredom, koliko puta se u tih 4 bacanja može dogoditi da novčić padne na grb točno 2 puta (poredak nije bitan)?

Rješenje:

Rješenje:

(G,G,P,P) (G,P,G,P) (G,P,P,G)

(P,G,G,P) (P,G,P,G) (P,P,G,G)

-imamo 6 kombinacija

$$\binom{4}{2} = \frac{4!}{(4-2)!2!} = 6$$



## BINOMNA RASPODJELA

### primjer:

Ako se simetrični novčić baca 4 puta zaredom, koliko je vjerojatnost da u tih 4 bacanja padne na grb točno 2 puta (poredak nije bitan)?

Rješenje:

(G,G,P,P) (G,P,G,P) (G,P,P,G)

(P,G,G,P) (P,G,P,G) (P,P,G,G)

-imamo 6 kombinacija, svaka ima vjerojatnost

$0,5^4$

- ukupna vjerojatnost je  $P=6*0,5^4 = 0,375$

Rješenje:

$$P_{x,n-x}^n = \binom{n}{x} p^x q^{n-x}$$

$$P_{2,2}^4 = \binom{4}{2} 0,5^2 \cdot 0,5^2 = 0,375$$

## BINOMNA RASPODJELA

- često se za neki događaj traži samo **vjerojatnost za ukupan broj** povoljnih ishoda u  $n$  uzastopnih Bernoullijevih pokusa, ali njihov poredak nije bitan
- **broj načina** na koji se takav događaj kod kojeg će  $n$  neovisnih pokusa rezultirati sa  $x$  povoljnih i  $n - x$  nepovoljnih ishoda može se dogoditi je:

$$\binom{n}{x}$$

## BINOMNA RASPODJELA

- budući da su svi pokusi međusobno neovisni, a vjerojatnost povoljnog događaja je  $p$  (ukupno će se dogoditi  $x$  povoljnih događaja) i vjerojatnost nepovoljnog događaja je  $q = 1 - p$  (ukupno će se dogoditi  $n - x$  nepovoljnih događaja), svaki od tih  $\binom{n}{x}$  načina imat će vjerojatnost:

$$P = p^x q^{n-x} = p^x (1-p)^{n-x}$$


- neka je vjerojatnost da  $n$  Bernoullijevih pokusa, svaki s vjerojatnošću  $p$  povoljnog ishoda i s vjerojatnošću  $q = 1 - p$  nepovoljnog ishoda, rezultira s  $x$  povoljnih ishoda i  $n - x$  nepovoljnih ishoda, tada je  $S_n$  broj povoljnih ishoda u ukupno  $n$  pokusa i predstavlja slučajnu varijablu, dok je s  $P(x; n, p)$  zadana njena **BINOMNA RASPODJELA**

$$P(x; n, p) = \binom{n}{x} p^x q^{n-x} = P(S_n = k)$$


## BINOMNA RASPODJELA

- opisuju je dva parametra: broj jedinki u uzorku ili broj ponavljanja pokušaja -  $n$ , i vjerojatnost uspjeha za svaku jedinku ili za svaki pokušaj -  $p$
- **srednja ili očekivana vrijednost** kod binomne raspodjele je vrijednost slučajne varijable koju očekujemo ako promatrano  $n$  pokušaja i iznosi  $n \cdot p$ ;
- **varijanca** kod binomne distribucije iznosi  $n \cdot p \cdot (1-p)$ ;
- binomna raspodjela je **simetrična** za  $p=q=0,5$ , pozitivno asimetrična za  $p < q$ , negativno asimetrična za  $p > q$
- kada  $n$  raste u beskonačnost, asimetričnost se smanjuje bez obzira na odnos  $p$  i  $q$
- upotrebljava se pri zaključivanju o proporcijama, značajna je od statističkih testova, postoje tablice binomne raspodjele (računanje binomnih koeficijenta za velike  $n$  i  $x$ ), **izvod za rekurzivnu formulu, ...**

## BINOMNA RASPODJELA



## BINOMNA RASPODJELA



## BINOMNA RASPODJELA

TEOREM: Pri binomnoj raspodjeli  $P(x; n, p)$  najveća vjerojatnost pripada onoj vrijednosti  $x_0$  varijable  $x$  koja zadovoljava nejednakost:

$$np - q \leq x_0 \leq np + p$$

*DOKAZ*

*OBJAŠNJENJE*

Primjer:

Bacamo istovremeno 7 novčića. Broj grbova koji će pasti na novčićima označimo s  $x$ . Koji broj grbova ima najveća vjerojatnost ?

Rješenje:

$$P(3) = P(4) = 0,273$$

*n.b. Očekivana vrijednost je  $n \cdot p = 3,5!$*

## POISSONOVA RASPODJELA


- do Poissonove raspodjele možemo doći graničnim prijelazom na binomnoj raspodjeli
- pustimo neka  $n$  teži u beskonačnosti, uz uvjet da je produkt  $np$  konstantan!
- zbog navedenog uvjeta,  $p$  će težiti nuli (jedino u tom slučaju će produkt  $np$  ostati konstantan)
- u tom slučaju, navedena raspodjela bit će određena izrazom:

$$P(x; m) = \frac{m^x}{x!} e^{-m}$$

- Poissonova raspodjela određena je parametrom  $m$  ( $m=np$ ) i njen će oblik i karakteristike ovisiti o njemu
- sa slike se vidi da Poissonova raspodjela za svaki  $m$  pozitivno asimetrična, ali porastom  $m$  se smanjuje njena asimetričnost
- *n.b.  $m > 0$  (jer je  $m=np$ )!*



## POISSONOVA RASPODJELA



## POISSONOVA RASPODJELA

- IZVOD POISSONOVE RASPODJELE IZ BINOMNE
- IZVOD ZA OČEKIVANU VRIJEDNOST
- računanje vjerojatnosti po Poissonovoj raspodjeli je **jednostavnije** nego po binimonoj raspodjeli te se u situacijama u kojima je kod binomne raspodjele  **$p$**  malen, a  **$n$**  velik, može načiniti **aproksimacija** i računati po Poissonovoj raspodjeli (aproksimacija je to bolja što je  **$p$**  manji i što je  **$n$**  veći!)

## POISSONOVA RASPODJELA

- računanje vjerojatnosti po Poissonovoj raspodjeli je jednostavnije nego po binomnoj raspodjeli te se u situacijama u kojima je kod binomne raspodjele  **$p$  malen**, a  **$n$  velik**, može načiniti aproksimacija i računati po Poissonovoj raspodjeli (aproksimacija je to bolja što je  **$p$**  manji i što je  **$n$**  veći!)

Primjer:

Pri proizvodnji pipeta nastaje 4% neispravnih pipeta. Kolika je vjerojatnost da u uzorku od 10 pipeta ne nađemo niti jednu ili samo jednu neispravnu pipetu?

BIONOMNA RASPODJELA:

$$P(x \leq 1) = P(0) + P(1) = 0,6648 + 0,2270 = 0,9418$$

POISSONOVA RASPODJELA:

$$P(x \leq 1) = P(0) + P(1) = e^{-0,4} + 0,4 * e^{-0,4} = 0,9384$$

- rezultati se ne razlikuju JAKO puno, iako je  $n$  relativno malen!

## HIPERGEOMETRIJSKA RASPODJELA

- u osnovnom skupu imamo  $N$  elemenata
- njih  $M$  ima neko obilježje  $A$ , što implicira da preostalih  $N-M$  elementa to obilježje nema
- uzmemo iz osnovnog skupa  $n$  elemenata slučajnim odabirom
- među tim elementima naći će se i onih koji imaju i onih koji nemaju obilježje  $A$
- broj elemenata koji imaju obilježje  $A$  u novom skupu elemenata označit ćemo s  $x$
- očito,  $x$  može poprimiti bilo koju vrijednost između 0 i  $n$  (ako je  $n \leq M$ )
- Kolika je vjerojatnost da  $x$  poprimi neku vrijednost (odnosno, koja je vjerojatnost da u nasumično izabranom uzorku elemenata imamo  $x$  elemenata s obilježjem  $A$ )?

## HIPERGEOMETRIJSKA RASPODJELA

- općenito, uzorak od  $n$  elemenata od ukupno  $N$  elemenata moguće je složiti na slijedeći broj načina:

$$K_n^{(N)} = \binom{N}{n}$$

- nadalje,  $x$  elemenata s obilježjem  $A$  (od ukupno njih  $M$ ) moguće je složiti na slijedeći broj načina:

$$K_x^{(M)} = \binom{M}{x}$$

- ostalih  $n-x$  elemenata u ukupnom uzorku nemaju obilježje  $A$ , te je njih moguće složiti na slijedeći broj načina:

$$K_{n-x}^{(N-M)} = \binom{N-M}{n-x}$$

## HIPERGEOMETRIJSKA RASPODJELA

- svaka grupa od  $x$  elemenata s obilježjem  $A$ , ujedinjena s bilo kojom grupom od  $n-x$  elemenata koji nemaju obilježje  $A$ , također čini traženi uzorak (uzorak koji sadrži  $x$  elemenata s obilježjem  $A$ , čiju vjerojatnost tražimo)
- vjerojatnost takvog uzorka je dana slijedećim izrazom:

$$P(x) = \frac{K_x^{(M)} \cdot K_{n-x}^{(N-M)}}{K_n^{(N)}} = \frac{\binom{M}{x} \cdot \binom{N-M}{n-x}}{\binom{N}{n}}$$

## HIPERGEOMETRIJSKA RASPODJELA

- skup uređenih parova  $\{x, P(x)\}$  tvori **hipergeometrijsku raspodjelu** koja je jednoznačno određena parametrima:  **$N, M, n$**
- očekivana vrijednost:  **$n \cdot (M/N)$** ; varijanca:  **$n \cdot (M/N) \cdot ((N-M)/N) \cdot ((N-n)/(N-1))$**
- rekurzivna formula može se izvesti na sličan način kao i kod binomne raspodjele
- ukoliko  **$N$**  teži beskonačnosti, ali na način da pri tome  **$M/N$**  teži realnom, nenegativnom broju manjem od 1 (**vjerojatnosti  $p$** ), i uz uvjet da  **$n$**  ostane **konstantan**, hipergeometrijska raspodjela **teži binomnoj raspodjeli (IZVOD)**
  
- problem kojim se bavi hipergeometrijska raspodjela sličan je Bernoullijevom pokusu, razlika je u tome da svako pojedino izvlačenje mijenja sastav skupa iz kojeg se vrši sljedeće izvlačenje (shodno tome mijenja se i vjerojatnost “uspješnog” izvlačenja)

