

Statistika i osnovna mjerenja

Binomna i Poissonova raspodjela

M. Makek
2017/2018

Raspodjele vjerojatnosti

Želimo matematički i statistički opisati raspodjele varijabli koje se javljaju u prirodi u raznim područjima fizike i izvan nje

- ❖ Diskretne raspodjele: Bernoullijeva, Binomna, Poissonova, Hipergeometrijska, idr.

- ❖ Kontinuirane raspodjele: Gaussova, Gama, idr.

Binomna raspodjela

Primjeri:

- Bacanje novčića
 - Dva moguća ishoda P i G
 - Za pošten novčić $p(P) = p(G) = 0.5$
- Galtonova daska: <http://www.geogebra.org/m/49479>
 - Kuglica pada i na svakom koraku može skrenuti lijevo ili desno
 - $p(L) = p(D) = 0.5$

Što je zajedničko ovim pokusima?

→ Imaju dva moguća ishoda

- P ili G
- L ili D
- Uspjeh ili neuspjeh

Binomna raspodjela

Binomni pokus:

1. Sastoji se od n (Bernoullijevih) pokušaja, gdje je n unaprijed zadan
2. Pokušaji imaju dva moguća ishoda: uspjeh (A) ili neuspjeh (\bar{A})
3. Vjerojatnost uspjeha (p) i neuspjeha ($q=1-p$) je jednaka za sve pokušaje
4. Pokušaji su nezavisni (ishod jednog ne utječe na drugi)

Binomna slučajna varijabla:

Za binomni pokus sa n pokušaja definiramo slučajnu varijablu:

X = broj uspjeha u n pokušaja, $X \sim \text{Bin}(n,p)$

$X = 0 \dots n$

Binomna raspodjela

- Def. **Binomna raspodjela**
 - Za binomni eksperiment i binomnu slučajnu varijablu $X \sim Bin(n, p)$, njenu raspodjelu vjerojatnosti nazivamo binomnom raspodjelom i označavamo: $b(x; n, p)$
- Uzmimo da niz od n Bernoullijevih eksperimenata završi:
 $A\bar{A}A\bar{A}\dots\bar{A}A$
 - A se pojavljuje x puta, \bar{A} $n-x$ puta
 - Koja je vjerojatnost jednog takvog ishoda? $\rightarrow p^x q^{n-x}$
 - Koliko ima takvih istih ishoda (koji su svi jednakovjerojatni)? $\rightarrow \binom{n}{x}$
 - Vjerojatnost da se pojavi bilo koji ishod koji ima x uspjeha je:

$$b(x; n, p) = \binom{n}{x} p^x q^{n-x} \quad \text{za } x=0,1,2,\dots,n$$
$$b(x; n, p) = 0 \quad \text{za sve ostale } x$$

\rightarrow vjerojatnost da u seriji od n pokusa događaj A nastupi x puta

Binomna raspodjela

- Primjer: Galtonova daska

$$b(x; 4, 0.5) = \binom{4}{x} 0.5^x 0.5^{4-x}$$

$$b(x; 4, 0.5) = \binom{4}{x} \frac{1}{16}$$

slučajna varijabla x	putevi	vjerojatnost
0	LLLL	q^4
1	LLLD LLDL LDLL DLLL	$p \cdot q^3$
2	LLDD LDLD LDDL DLLD DLDL DDLL	$p^2 \cdot q^2$
3	LDDD DLDD DDLD DDDL	$p^3 \cdot q$
4	DDDD	p^4

Binomna raspodjela

Rekurzivna formula

- Pomaže u računu, posebice kod velikih faktorijela
- Koja je vjerojatnost da varijabla poprimi vrijednost $x-1$?

$$b(x-1; n, p) = \binom{n}{x-1} p^{x-1} q^{n-x+1}$$

- Iz omjera $b(x)/b(x-1)$ dobivamo rekurzivnu formulu:

$$b(x; n, p) = \frac{n-x+1}{x} \frac{p}{q} b(x-1; n, p)$$

→ Vjerojatnost za bilo koji x možemo dobiti rekurzijom iz:

$$b(0; n, p) = q^n$$

Binomna raspodjela

Primjer korištenja rekurzije: za koju vrijednost x je $b(x)$ maksimalan?

- Koristimo rekurzivnu formulu
Mora biti zadovoljeno:

$$b(x - 1; n, p) \leq b(x; n, p) \geq b(x + 1; n, p)$$

Nakon raspisivanja (**domaća zadaća**) po rekurzivnoj formuli slijedi:

$$np - q \leq x_{max} \leq np + p$$

Binomna raspodjela

- Vrijedi binomni poučak:

$$(a + b)^n = \sum_{k=0}^n \binom{n}{k} a^k b^{n-k}$$

Funkcija raspodjele diskretne slučajne varijable sa binomnom raspodjelom:

$$F(x) = \begin{cases} \sum_{k=0}^x \binom{n}{k} p^k q^{n-k}, & 0 \leq x < n \\ 1, & x = n \end{cases}$$

Binomna raspodjela

Očekivanje diskretnе slučajne varijable sa binomnom raspodjelom je: $E(X) = np$

- To možemo pokazati na sljedeći način:

- Definiramo funkciju $g(t) = (q + pt)^n$

- Razvoj po binomnom poučku:

$$(q + pt)^n = \sum_{x=0}^n \binom{n}{x} p^x q^{n-x} t^x = \sum_{x=0}^n b(x) t^x$$

- Deriviranjem po t dobivamo:

$$np(q + pt)^{n-1} = \sum_{x=0}^n x b(x) t^{x-1}$$

- Za $t=1$:

$$np(q + p)^{n-1} = \sum_{x=0}^n x b(x)$$

- Što po definiciji daje:

$$np = E(X)$$

Funkcija izvodnica

- Općenito za diskretnu slučajnu varijablu definiramo funkciju izvodnicu:

$$g(t) = \sum_{x \in D} e^{tx} p(x)$$

- Iz definicije slijedi:

$$g'(t = 0) = \sum_{x \in D} x \cdot p(x) = m_1$$

$$g''(t = 0) = \sum_{x \in D} x^2 \cdot p(x) = m_2$$

$$g^{(r)}(t = 0) = \sum_{x \in D} x^r \cdot p(x) = m_r$$

→ pomoću funkcije izvodnice mogu se dobiti svi pomoćni, a posredno i centralni momenti slučajne varijable

Binomna raspodjela

- Drugi način da odredimo očekivanje (a i varijancu) je pomoću funkcije izvodnice
- **Funkcija izvodnica za binomnu raspodjelu:**

$$\begin{aligned}g_X(t) &= E(e^{tX}) = \sum_{x=0}^n e^{tx} \binom{n}{x} p^x q^{n-x} \\&= \sum_{x=0}^n \binom{n}{x} (pe^t)^x q^{n-x}\end{aligned}$$

- Prema binomnom poučku slijedi:

$$g_X(t) = (pe^t + q)^n$$

Binomna raspodjela

- Prva derivacija funkcije izvodnice:

$$g'_X(t) = npe^t(pe^t + q)^{n-1}$$

$$g'_X(0) = npe^0(pe^0 + q)^{n-1} = np \quad (= m_1)$$

 \$E(X) = np\$

- Druga derivacija funkcije izvodnice:

$$\begin{aligned} g''_X(t) &= npe^t(pe^t + q)^{n-1} \\ &\quad + n(n-1)(pe^t)^2(pe^t + q)^{n-2} \end{aligned}$$

$$g''_X(0) = np + n(n-1)p^2 \quad (= m_2)$$

Binomna raspodjela

- Varijanca je jednaka centralnom momentu drugog reda
- Otprije imamo: $M_2 = m_2 - m_1^2$
- Slijedi **Varijanca** diskretne slučajne varijable sa binomnom raspodjelom:

$$\begin{aligned}V(X) &= np + n(n - 1)p^2 - (np)^2 \\&= np(1 + (n - 1)p - np) \\&= np(1 - p)\end{aligned}$$

$$\rightarrow V(X) = npq$$

Treba još primijetiti da se za $n=1$ binomna raspodjela svodi na Bernoullijevu, što je i za očekivati budući da ona opisuje Bernoullijev pokus koji se ponavlja n puta!

Binomna raspodjela

Primjer: kontrola uzorka

- Neki uređaj izrađuje 8% neispravnih proizvoda. Proizvodi se pakiraju u kutije od 50 komada.

Koja je vjerojatnost da se u kutiji nađe 2 defektna komada?

- $n=50, p=0.08$
- $b(2) = \binom{50}{2} p^2 q^{50-2}$
 $\rightarrow b(2) = 0.14$

Koji je najvjerojatniji broj defektnih komada u kutiji?

- $n=50, p=0.08$
- $np-q \leq x_M \leq np+p \rightarrow 3.08 \leq x_M \leq 4.08$
 $\rightarrow x_M = 4$

Poissonova raspodjela

- Uzmimo da je vjerojatnost uspjeha pojedinog Bernoullijevog pokušaja u binomnom pokusu jako mala, te taj pokus ponavljamo jako puno puta ($n \gg, p \ll$)
pri tome očekivana vrijednost konstantna $E(x)=np= \text{const.}$
- Primjer: raspad radioaktivnog uzorka:
 - Vjerojatnost pojedinog raspada je iznimno mala
 - Uzorak sadrži jako puno izotopa koji se nezavisno mogu raspasti
→ Srednji broj raspada u nekom vremenskom intervalu je konstantan.

Poissonova raspodjela

- Kao granični slučaj binomne:

$$\begin{aligned} b(x; n, p) &= \binom{n}{x} p^x q^{n-x} \\ &= \frac{n(n-1)\dots(n-x+1)}{x!} p^x q^{n-x} \\ &= \frac{n(n-1)(n-x+1)}{x!} \frac{\lambda^x}{n^x} \left(1 - \frac{\lambda}{n}\right)^{n-x} \\ &= \frac{\left(1 - \frac{1}{n}\right) \left(1 - \frac{2}{n}\right) \dots \left(1 - \frac{x-1}{n}\right)}{x!} \lambda^x \left(1 - \frac{\lambda}{n}\right)^n \left(1 - \frac{\lambda}{n}\right)^{-x} \end{aligned}$$

$$p(x) = \lim_{n \rightarrow \infty} b(x) = \frac{\lambda^x}{x!} \lim_{n \rightarrow \infty} \left(1 - \frac{\lambda}{n}\right)^n$$

➡ $p(x) = \frac{\lambda^x}{x!} e^{-\lambda}$

Poissonova raspodjela

- Očekivanje je prema definiciji:

$$\begin{aligned} E(X) &= \sum_{x=0}^{\infty} x \frac{\lambda^x}{x!} e^{-\lambda} \\ &= \lambda e^{-\lambda} \sum_{x=0}^{\infty} \frac{\lambda^{x-1}}{(x-1)!} = \lambda e^{-\lambda} e^{\lambda} \\ \rightarrow & \boxed{E(X) = \lambda} \end{aligned}$$

- Prema definiciji varijance također izlazi da je:

$$\boxed{V(X) = \lambda} \text{ odn. } \boxed{\sigma_X = \sqrt{\lambda}}$$

- Normiranost raspodjele slijedi iz definicije:

$$\sum_{x=0}^{\infty} p(x; \lambda) = e^{-\lambda} \sum_{x=0}^{\infty} \frac{\lambda^x}{x!} = e^{-\lambda} e^{\lambda} = 1$$

Poissonova raspodjela

- Funkcija izvodnica:

$$g(t) = \sum_{x=0}^{\infty} e^{tx} e^{-\lambda} \frac{\lambda^x}{x!} = e^{-\lambda} e^{\lambda e^t} = e^{\lambda(e^t - 1)}$$

- Pomoćni momenti:

$$g'(t) = \lambda e^t e^{\lambda(e^t - 1)} \rightarrow m_1 = \lambda$$

$$g''(t) = \lambda e^t (1 + \lambda e^t) e^{\lambda(e^t - 1)} \rightarrow m_2 = \lambda^2 + \lambda$$

→ $E(X)$ i $V(X)$ možemo elegantno dobiti preko funkcije izvodnice

Poissonova raspodjela


- Rekurzija
 - Iz omjera $p(x)/p(x-1)$ slijedi:

$$p(x) = \frac{\lambda}{x} p(x - 1)$$

- Najvjerojatnija vrijednost
 - Iz uvjeta: $p(x_M - 1) \leq p(x_M) \geq p(x_M + 1)$
 - Slijedi: $\lambda - 1 \leq x_M \leq \lambda$

Poissonova raspodjela

- P.r. je potpuno određena parametrom λ



Suma dvije nezavisne Poissonove varijable

- Za dvije slučajne varijable X i Y s Poissonovim raspodjelama $p(x,m)$ i $p(y,n)$ vrijedi da je raspodjela slučajne varijable $Z=X+Y$ jednaka $p(z, m+n)$


- Dokaz:
$$\begin{aligned} P(Z = z) &= \sum_{k=0}^z P(X = k)P(Y = z - k) \\ &= \sum_{k=0}^z e^{-m} \frac{m^k}{k!} e^{-n} \frac{n^{z-k}}{(z-k)!} \\ &= \frac{e^{-(m+n)}}{z!} \sum_{k=0}^z \binom{z}{k} m^k n^{z-k} \\ &= \frac{e^{-(m+n)}}{z!} (m + n)^z = p(z, m + n) \end{aligned}$$

Poissonova raspodjela (primjene)

Primjer: Poissonova raspodjela kao granični slučaj binomne

- Serija proizvoda sadrži 4% loših
 - Kolika je vjerojatnost da u seriji od 10 proizvoda nadjemo najviše jedan loš proizvod?
 - $N=10$
 - $P=0.04$
 - $Np = 0.4$
- $b(0;10,0.04) + b(1;10,0.04) = 0.9418$
- $p(0;0.4) + p(1;0.4) = 0.9384$

→ Poissonova r. je dobra aproksimacija binomne!



Poissonova raspodjela (primjene)

Primjer: Poissonova raspodjela za proučavanje rijetkih događaja

- Konstanta raspada nekog izotopa je $\lambda = 7,3 \cdot 10^{-10} \text{ s}^{-1}$
- Uzorak sadrži $4,8 \cdot 10^{22}$ radioaktivnih atoma
- Treba odrediti raspodjelu vjerojatnosti k raspada u 1 s.
- Zakon radioaktivnog raspada daje broj atoma u vremenu:

$$N(t) = N_0 e^{-t/\tau}$$

- Aktivnost uzorka: $a = \left| \frac{dN}{dt} \right| = \frac{N}{\tau}$
- Slijedi da je vjerojatnost k raspada u intervalu Δt :
$$P_k(\Delta t) = b(k; N, \frac{N\Delta t}{\tau}, \frac{1}{N}) = p(k; a\Delta t)$$
- Vjerojatnost događaja proporcionalna je **veličini intervala**


→ Takve procese nazivamo **Poissonovim procesima!**

Prilagodba empiričkim podacima

- Primjer Poissonova raspodjela
- Mjeren je broj beta raspada x iz nekog uzorka u intervalu od 10 sekundi. Broj slučajeva u kojima je emitirano točno x čestica je označen kao f_x
→ smatramo da bi broj opaženih čestica trebao slijediti Poiss. raspodjelu.

x	f_x	$p(x)$	f_{tx}
0	57	0,0209	54,4
1	203	0,0807	210,5
2	383	0,1562	407,4
3	525	0,2015	525,5
4	532	0,1949	508,4
5	408	0,1509	393,5
6	273	0,0973	253,8
7	139	0,0538	140,3
8	45	0,0260	67,9
9	27	0,0112	29,2
10	10	0,0043	11,3
11	4	0,0015	4,0
12	2	0,0005	1,3

- Očekivanje raspodjele možemo aproksimirati aritmetičkom sredinom uzorka: $\lambda = \bar{x} = 3,87$
- Teorijske frekvencije računamo prema: $f_{tx} = Np(x; \lambda)$




Čebiševljev teorem

- Za slučajnu varijablu X sa raspodjelom vjerojatnosti $P(x)$ i očekivanjem $E(X)=\mu$ i varijancom $V(X)=\sigma^2$ vrijedi teorem:

Vjerojatnost da X poprimi vrijednost izvan intervala $(\mu-\epsilon, \mu+\epsilon)$ je manja ili jednaka σ^2/ϵ^2 , za bilo koji $\epsilon > 0$.

$$P\{|x - \mu| \geq \epsilon\} \leq \frac{\sigma^2}{\epsilon^2}$$



Dokaz: po definiciji je varijanca jednaka: $\sigma^2 = \sum_i (x_i - \mu)^2 P(x_i)$
Posebno je za sve x iz osjenčanog intervala:

$$\sigma^2 \geq \sum_{|x_i - \mu| \geq \epsilon} (x_i - \mu)^2 P(x_i)$$

Obzirom da je: $|x_i - \mu| \geq \epsilon$ onda vrijedi:

$$\sigma^2 \geq \epsilon^2 \sum_{|x_i - \mu| \geq \epsilon} P(x_i)$$

Budući da se x_i međusobno isključuju vrijedi: $\sum_{|x_i - \mu| \geq \epsilon} P(x_i) = P\{|x - \mu| \geq \epsilon\}$

Odavde slijedi tvrdnja

Zakon velikih brojeva

- Za Bernoullijev događaj s vjerojatnošću $P(A)=p$, koji se ponavlja u n pokusa, vjerojatnost slijedi binomnu raspodjelu sa očekivanjem $\mu=np$ i varijancom $\sigma^2=npq$. Empirijski je relativna frekvencija tog događaja: $f_{rx} = \frac{x}{n}$ (gdje je x broj nastupa u n pokušaja)

Bernoullijev teorem: ako broj pokušaja teži u beskonačno onda relativna frekvencija teži *po vjerojatnosti* stvarnoj vjerojatnosti događaja:

$$\lim_{n \rightarrow \infty} P\{|f_{rx} - p| \geq \epsilon\} = 0 \quad (\text{za bilo koji } \epsilon)$$

Dokaz

$$P\{|f_{rx} - p| \geq \epsilon\} = P\left\{\left|\frac{x}{n} - p\right| \geq \epsilon\right\} = P\{|x - np| \geq n\epsilon\}$$

Prema Čeb. Tm (uz $np=\mu$): $P\{|x - np| \geq n\epsilon\} \leq \frac{\sigma^2}{n^2\epsilon^2}$

$$P\{|f_{rx} - p| \geq \epsilon\} \leq \frac{\sigma^2}{n^2\epsilon^2} = \frac{npq}{n^2\epsilon^2} \quad \rightarrow \quad P\{|f_{rx} - p| \geq \epsilon\} \leq \frac{pq}{n\epsilon^2}$$

Za $\lim(n \rightarrow \infty)$: $P\{|f_{rx} - p| \geq \epsilon\} = 0$ (Q.E.D.)

Druge raspodjele diskretnih varijabli

- **Hipergeometrijska raspodjela**
 - Populacija od N elemenata (konačna populacija)
 - Svaki element može biti uspješan (A) ili neuspješan (\bar{A})
 - Postoji M uspješnih elemenata (fiksno!)
 - Izvlačenje bilo kojeg uzorka od n elemenata je jednako vjerojatno
 - Slučajna varijabla **$X=broj\ uspješnih\ elemenata\ u\ uzorku$**
 - $h(x)=$ broj mogućih uzoraka s x uspjeha/ukupni broj mogućih uzoraka

$$h(x; n, M, N) = \frac{\binom{M}{x} \binom{N-M}{n-x}}{\binom{N}{n}} \quad x = 0, 1, 2, \dots, \min(n, M)$$

Druge raspodjele diskretnih varijabli

- **Hipergeometrijska raspodjela**

- Očekivanje $E(X) = n \frac{M}{N}$

- Varijanca $V(X) = n \frac{M}{N} \frac{N-M}{N} \frac{N-n}{N-1}$

- Uz definicije: $p=M/N$ i $q=(N-M)/N$ slijedi:

$$E(X) = np \quad V(X) = npq \frac{N-n}{N-1}$$

- Primjer: skup ima 50 proizvoda od kojih 40 dobrih i 10 loših. Slučajno odaberemo 5 proizvoda. Koja je vjerojatnost da se u uzorku nađe x dobrih proizvoda? -> $h(x; 5, 40, 50)$

Druge raspodjele diskretnih varijabli

- **Pascalova raspodjela**

- Niz nezavnisih pokušaja
- Svaki pokušaj je Bernoullijev pokus koji može biti uspješan (A) ili neuspješan (\bar{A})
- Vjerojatnost uspjeha p jednaka je za sve pokušaje
- Pokušaji se izvode sve dok se ne opazi r uspjeha (r unaprijed određen)
- Slučajna varijabla $X = \text{broj neuspjeha koji prethode } r\text{-tom uspjehu}$
- Za razliku od binomne broj pokušaja je varijabilan, a broj uspjeha je zadan

$$nb(x; r, p) = P(r - 1 \text{ A u } x + r - 1 \text{ pokušaja})P(\text{uspjeh})$$

$$nb(x; r, p) = \binom{x + r - 1}{r - 1} p^{r-1} q^x p$$

$$nb(x; r, p) = \binom{x + r - 1}{r - 1} p^r q^x \quad x = 0, 1, 2 \dots$$