

### **Normalna ili Gaussova razdioba**

Ako je područje vrijednosti kontinuirane slučajne varijable  $X$  čitav skup  $\mathbb{R}$ , a funkcija gustoće je dana sa

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-m}{\sigma}\right)^2}, \quad \sigma, m \in \mathbb{R}, \quad \sigma > 0,$$

onda kažemo da  $X$  ima **Normalnu razdiobu**. Normalna razdioba je potpuno određena s parametrima  $\sigma, m$ , pa pišemo

$$X : \mathcal{N}(m, \sigma^2).$$

Može se pokazati da je u ovom slučaju

$$\mu = E[X] = m \quad (\text{očekivanje}),$$

$$V[X] = \sigma^2 \quad (\text{varijanca}),$$

$$\sqrt{V[X]} = \sigma \quad (\text{standardna devijacija}).$$


**Primjer 2.22** Ako je  $X : \mathcal{N}(5, 9)$ , to znači da je  $x \in (-\infty, +\infty)$  i

$$f(x) = \frac{1}{3\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-5}{3}\right)^2}.$$

Ako je  $X : \mathcal{N}(0, 1)$  kažemo da kontinuirana slučajna varijabla  $X$  ima jedinčnu Normalnu razdiobu, tj.  $x \in (-\infty, +\infty)$  i

$$f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2}.$$


Ova funkcija je parna pa joj je graf simetričan s obzirom na  $y$ -os



Općenito, ako je  $X : \mathcal{N}(m, \sigma^2)$  onda je funkcija gustoće

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-m}{\sigma}\right)^2}$$

simetrična s obzirom na pravac  $x = m$  (pomak), a o  $\sigma$  ovisi spljoštenje.



Za  $X : \mathcal{N}(m, \sigma^2)$  imamo

$$\begin{aligned} \mathcal{P}\{x_1 < X < x_2\} &= \int_{x_1}^{x_2} \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-m}{\sigma}\right)^2} dx, \\ \mathcal{P}\{X < x_2\} &= \int_{-\infty}^{x_2} \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-m}{\sigma}\right)^2} dx, \\ \mathcal{P}\{x_1 < X\} &= \int_{x_1}^{\infty} \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-m}{\sigma}\right)^2} dx. \end{aligned}$$

Međutim ovi integrali nisu elemetarno rješivi. Ako uvedemo supstituciju

$$u = \frac{x-m}{\sigma},$$

onda je  $u_1 = \frac{x_1 - m}{\sigma}$ ,  $u_2 = \frac{x_2 - m}{\sigma}$  i  $du = \frac{1}{\sigma}dx$ , pa je


$$\begin{aligned}\mathcal{P}\{x_1 < X < x_2\} &= \frac{1}{\sqrt{2\pi}} \int_{u_1}^{u_2} e^{-\frac{1}{2}u^2} du = \mathcal{P}\{u_1 < U < u_2\}, \\ \mathcal{P}\{X < x_2\} &= \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{u_2} e^{-\frac{1}{2}u^2} du = \mathcal{P}\{U < u_2\}, \\ \mathcal{P}\{x_1 < X < x_2\} &= \frac{1}{\sqrt{2\pi}} \int_{u_1}^{\infty} e^{-\frac{1}{2}u^2} du = \mathcal{P}\{u_1 < U\},\end{aligned}$$

gdje je slučajna varijabla  $U : \mathcal{N}(0, 1)$ .

Funkciju oblika

$$\Phi(u) = \frac{1}{\sqrt{2\pi}} \int_0^u e^{-\frac{1}{2}u^2} du, \quad u > 0,$$

nazivamo **Gaussov integral** (vrijednosti za  $\Phi(u)$  nalazimo u tablicama).



$$y = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}u^2}, \quad \Phi(u) = \int_0^u \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}u^2} du$$

Očito vrijedi:  $\Phi(-u) = \Phi(u)$  za svaki  $u > 0$ .

Koristeći definiciju Gaussovog integrala, sada vjerojatnost da slučajna varijabla  $X : \mathcal{N}(m, \sigma^2)$  poprimi vrijednost iz bilo kojeg intervala, možemo izraziti pomoću njega.

Uočimo: ako je  $U : \mathcal{N}(0, 1)$  onda je očito, iz geometrijske interpretacije,

$$\mathcal{P}\{0 < U\} = \frac{1}{\sqrt{2\pi}} \int_0^{\infty} e^{-\frac{1}{2}u^2} du = 0.5,$$

tj. površina između osi  $u$  i grafa funkcije gustoće  $y = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}u^2}$  za  $u > 0$ , je, zbog simetričnosti, jednaka 0.5. Slično,  $\mathcal{P}\{U < 0\} = 0.5$ .

**Primjer 2.23** Imamo:

a)

$$\begin{aligned}\mathcal{P}\{x_1 < X < x_2\} &= \left[ u = \frac{x - m}{\sigma}, \quad U : \mathcal{N}(0, 1) \right] = \\ &= \frac{1}{\sqrt{2\pi}} \int_{u_1}^{u_2} e^{-\frac{1}{2}u^2} du = \mathcal{P}\{u_1 < U < u_2\} = (*)\end{aligned}$$

a1)  $0 \leq u_1 \leq u_2 \implies (*) = \Phi(u_2) - \Phi(u_1);$

a2)  $u_1 \leq 0, 0 \leq u_2 \implies (*) = \Phi(-u_1) + \Phi(u_2);$

a3)  $u_1 \leq u_2 \leq 0 \implies (*) = \Phi(-u_1) - \Phi(-u_2);$

b)

$$\begin{aligned}\mathcal{P}\{X < x_2\} &= \left[ u = \frac{x - m}{\sigma}, \quad U : \mathcal{N}(0, 1) \right] = \\ &= \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{u_2} e^{-\frac{1}{2}u^2} du = \mathcal{P}\{U < u_2\} = (**)\end{aligned}$$

b1)  $0 \leq u_2 \implies (**) = 0.5 + \Phi(u_1);$

b2)  $u_2 \leq 0 \implies (**) = 0.5 - \Phi(-u_1);$

c)

$$\begin{aligned}\mathcal{P}\{x_1 < X\} &= \left[ u = \frac{x - m}{\sigma}, \quad U : \mathcal{N}(0, 1) \right] = \\ &= \frac{1}{\sqrt{2\pi}} \int_{u_1}^{\infty} e^{-\frac{1}{2}u^2} du = \mathcal{P}\{u_1 < U\} = (***)\end{aligned}$$

c1)  $0 \leq u_1 \implies (*** ) = 0.5 - \Phi(u_1);$

$$\mathbf{c2)} \quad u_1 \leq 0 \implies (***) = 0.5 + \Phi(-u_1);$$

**Primjer 2.24** Ako je  $X : \mathcal{N}(20, 16)$  odredite očekivanje  $E[X]$ , varijancu  $V[X]$ , te  $\mathcal{P}\{X < 15\}$ .

Rješenje: Imamo  $m = 20$ ,  $\sigma^2 = 16$ , pa je  $\sigma = 4$ ,  $\mu = E[X] = m = 20$ ,  $V[X] = \sigma^2 = 16$ . Odredimo  $\mathcal{P}\{X < 15\}$ . Uvedimo supstituciju

$$\begin{aligned} \mathcal{P}\{X < 15\} &= \left[ u = \frac{x - 20}{4}, \quad u_2 = \frac{15 - 20}{4} = -1.25, \quad U : \mathcal{N}(0, 1) \right] = \\ &= \mathcal{P}\{U < -1.25\} = 0.5 - \Phi(1.25) = 0.5 - 0.3964 = 0.1054. \end{aligned}$$

**Primjer 2.25** Ako je  $X : \mathcal{N}(m, \sigma^2)$  odredimo:

- a)  $\mathcal{P}\{\mu - \sigma < X < \mu + \sigma\},$
- b)  $\mathcal{P}\{\mu - 2\sigma < X < \mu + 2\sigma\},$
- c)  $\mathcal{P}\{\mu - 3\sigma < X < \mu + 3\sigma\}.$

Funkcija gustoće je

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-m}{\sigma}\right)^2},$$

očekivanje  $\mu = E[X] = m$ , varijanca  $V[X] = \sigma^2$ , a  $\sigma$  standardna devijacija. Supstitucijom  $\frac{x-m}{\sigma} = u$ , dobivamo

a)

$$\begin{aligned} \mathcal{P}\{\mu - \sigma < X < \mu + \sigma\} &= [U : \mathcal{N}(0, 1), \mu = m] = \\ &= \mathcal{P}\left\{\frac{m - \sigma - m}{\sigma} < U < \frac{m + \sigma - m}{\sigma}\right\} = \mathcal{P}\{-1 < U < 1\} = \\ &= 2\Phi(1) = 2 \cdot 0.34134 = \mathbf{0.68268} \end{aligned}$$

b)

$$\begin{aligned} \mathcal{P}\{\mu - 2\sigma < X < \mu + 2\sigma\} &= [U : \mathcal{N}(0, 1), \mu = m] = \\ &= \mathcal{P}\left\{\frac{m - 2\sigma - m}{\sigma} < U < \frac{m + 2\sigma - m}{\sigma}\right\} = \mathcal{P}\{-2 < U < 2\} = \\ &= 2\Phi(2) = 2 \cdot 0.47725 = \mathbf{0.95450} \end{aligned}$$

c)

$$\begin{aligned}\mathcal{P} \{ \mu - 3\sigma < X < \mu + 3\sigma \} &= [U : \mathcal{N}(0, 1), \mu = m] = \\&= \mathcal{P} \left\{ \frac{\mu - 3\sigma - m}{\sigma} < U < \frac{\mu + 3\sigma - m}{\sigma} \right\} = \mathcal{P} \{ -3 < U < 3 \} = \\&= 2\Phi(3) = 2 \cdot 0.49865 = \mathbf{0.99730}\end{aligned}$$


Komentar: vjerojatnost da će slučajna varijabla  $X : \mathcal{N}(m, \sigma^2)$  poprimiti vrijednosti:

- a) iz intervala  $(\mu - \sigma, \mu + \sigma)$  (interval oko očekivane vrijednosti  $\mu$  širine  $2\sigma$  ( $\sigma$ -stand. dev.)) je **0.68268** ili oko **68.27%** vrijednosti od  $X$  pada u interval  $(\mu - \sigma, \mu + \sigma)$ ;
- b) iz intervala  $(\mu - 2\sigma, \mu + 2\sigma)$  (interval oko očekivane vrijednosti  $\mu$  širine  $4\sigma$ ) je **0.95450** ili oko **95.45%** vrijednosti od  $X$  pada u interval  $(\mu - 2\sigma, \mu + 2\sigma)$ ;
- c) iz intervala  $(\mu - 3\sigma, \mu + 3\sigma)$  (interval oko očekivane vrijednosti  $\mu$  širine  $6\sigma$ ) je **0.99730** ili oko **99.73%** vrijednosti od  $X$  pada u interval  $(\mu - 3\sigma, \mu + 3\sigma)$ .

Svojstva a), b), c) uočio je Gauss.

Ako kod mjerjenja nastaju pogreške koje se pokoravaju zakonu Normalne razdiobe, gdje pogreškom smatramo odstupanje od prosjeka (očekivanja)  $\mu$ , tj. veličinu  $x - \mu$ , onda su male pogreške (po absolutnoj vrijednosti), "česte",

a velike "rijetke".



Drugim riječima, pogreške koje su veće od  $2\sigma$  imaju vjerojatnost manju od 0.05 (5%), a one veće od  $3\sigma$  imaju vjerojatnost manju od 0.003 (0.3%). Ovo bi značilo da npr. u 1000 mjerena pogreška (po absolutnoj vrijednosti) premašuje veličinu  $3\sigma$  samo u 3 mjerena. praktički skoro sve pogreške će se nalaziti između  $-3\sigma$  i  $3\sigma$ . Ova osobina Normalne razdiobe naziva se pravilo tri sigme.

### Aproksimacija Binomne razdiobe Normalnom

Neka je  $X : \mathcal{B}(n, p)$ . Tada je

$$R(X) = \{0, 1, 2, \dots, n\},$$

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

$$E[X] = np, \quad V[X] = npq.$$

Ako je  $n$  jako velik ( $n \gg 0$ ) i  $p \approx 0.5$ , onda je moguće Binomnu razdiobu

aproksimirati Normalnom razdiobom  $\mathcal{N}(m, \sigma^2)$ , gdje je  $m = np$  i  $\sigma^2 = npq$ , tj. tada je

$$\mathcal{B}(n, p) \approx \mathcal{N}(np, npq).$$

Aproksimacija će biti dobra ako je:

$$1) \frac{1}{n+1} < p < \frac{n}{n+1},$$

$$2) npq > 9.$$

Ako su zadovoljeni uvjeti 1) i 2), onda je

$$p(x) = \binom{n}{x} p^x q^{n-x} \approx \mathcal{P}_{\mathcal{N}}\{x - 0.5 < X < x + 0.5\},$$

$$\mathcal{P}_{\mathcal{B}}\{x_1 \leq X \leq x_2\} = \sum_{x=x_1}^{x_2} \binom{n}{x} p^x q^{n-x} \approx \mathcal{P}_{\mathcal{N}}\{x_1 - 0.5 < X < x_2 + 0.5\},$$

$$\mathcal{P}_{\mathcal{B}}\{x_1 \leq X\} = \sum_{x=x_1}^n \binom{n}{x} p^x q^{n-x} \approx \mathcal{P}_{\mathcal{N}}\{x_1 - 0.5 < X\},$$

$$\mathcal{P}_{\mathcal{B}}\{X \leq x_2\} = \sum_{x=0}^{x_2} \binom{n}{x} p^x q^{n-x} \approx \mathcal{P}_{\mathcal{N}}\{X < x_2 + 0.5\}.$$

**Primjer 2.26** Neka je  $X : \mathcal{B}(100, 0.3)$ . Odredite:

- a)  $\mathcal{P}\{20 \leq X \leq 40\},$
- b)  $\mathcal{P}\{20 < X < 40\},$
- c)  $\mathcal{P}\{20 < X \leq 40\},$
- d)  $\mathcal{P}\{30 < X\},$
- e)  $\mathcal{P}_{\mathcal{B}}\{X < 25\}.$

Rješenje:

a)

$$\begin{aligned}\mathcal{P}_{\mathcal{B}}\{20 \leq X \leq 40\} &= \mathcal{P}_{\mathcal{B}}\{X = 20\} + \mathcal{P}_{\mathcal{B}}\{X = 21\} + \dots + \mathcal{P}_{\mathcal{B}}\{X = 40\} = \\ &= \binom{100}{20} (0.3)^{20} (0.7)^{100-20} + \dots + \binom{100}{40} (0.3)^{40} (0.7)^{100-40} = \\ &= \sum_{x=20}^{40} \binom{100}{x} (0.3)^x (0.7)^{100-x}\end{aligned}$$

Vidimo da je ovo vrlo "naporno" za računati. Budući je:

$$1) \frac{1}{n+1} = \frac{1}{101} \approx 0.00999 < 0.3 < \frac{100}{101} \approx 0.99,$$

$$2) npq = 100 \cdot 0.3 \cdot 0.7 = 21 > 9,$$

onda je moguće Binomnu razdiobu aproksimirati Normalnom razdiobom. Budući je  $np = 30$  i  $npq = 21$  onda je  $\mathcal{B}(100, 0.3) \approx \mathcal{N}(30, 21)$ , pa imamo:

a)

$$\begin{aligned}\mathcal{P}_{\mathcal{B}} \{20 \leq X \leq 40\} &\approx \mathcal{P}_{\mathcal{N}} \{20 - 0.5 < X < 40 + 0.5\} = \\&= \mathcal{P}_{\mathcal{N}} \{19.5 < X < 40.5\} = \left[ u = \frac{x - 30}{\sqrt{21}}, \quad U : \mathcal{N}(0, 1) \right] = \\&= \mathcal{P}_{\mathcal{N}} \left\{ \frac{19.5 - 30}{\sqrt{21}} < U < \frac{40.5 - 30}{\sqrt{21}} \right\} = \mathcal{P}_{\mathcal{N}} \{-2.2913 < U < 2.2913\} = \\&\approx \mathcal{P}_{\mathcal{N}} \{-2.29 < U < 2.29\} = 2 \cdot \Phi(2.29) = 2 \cdot 0.48899 = 0.97798.\end{aligned}$$

b)

$$\begin{aligned}\mathcal{P}_{\mathcal{B}} \{20 < X < 40\} &= \mathcal{P}_{\mathcal{B}} \{21 \leq X \leq 39\} \approx \\&\approx \mathcal{P}_{\mathcal{N}} \{21 - 0.5 < X < 39 + 0.5\} = \left[ u = \frac{x - 30}{\sqrt{21}}, \quad U : \mathcal{N}(0, 1) \right] = \\&= \mathcal{P}_{\mathcal{N}} \left\{ \frac{20.5 - 30}{\sqrt{21}} < U < \frac{39.5 - 30}{\sqrt{21}} \right\} = \mathcal{P}_{\mathcal{N}} \{-2.0731 < U < 2.0731\} = \\&\approx \mathcal{P}_{\mathcal{N}} \{-2.07 < U < 2.07\} = 2 \cdot \Phi(2.07) = 2 \cdot 0.48077 = 0.96154.\end{aligned}$$

c)

$$\begin{aligned}\mathcal{P}_{\mathcal{B}} \{20 < X \leq 40\} &= \mathcal{P}_{\mathcal{B}} \{21 \leq X \leq 40\} \approx \\&\approx \mathcal{P}_{\mathcal{N}} \{21 - 0.5 < X < 40 + 0.5\} = \left[ u = \frac{x - 30}{\sqrt{21}}, \quad U : \mathcal{N}(0, 1) \right] = \\&= \mathcal{P}_{\mathcal{N}} \left\{ \frac{20.5 - 30}{\sqrt{21}} < U < \frac{40.5 - 30}{\sqrt{21}} \right\} = \mathcal{P}_{\mathcal{N}} \{-2.0731 < U < 2.2913\} = \\&\approx \mathcal{P}_{\mathcal{N}} \{-2.07 < U < 2.29\} = \Phi(2.07) + \Phi(2.29) = 0.48077 + 0.49861 = 0.97938.\end{aligned}$$

d)

$$\begin{aligned}\mathcal{P}_{\mathcal{B}} \{30 < X\} &= \mathcal{P}_{\mathcal{B}} \{31 \leq X\} \approx \mathcal{P}_{\mathcal{N}} \{31 - 0.5 < X\} = \\&= \left[ u = \frac{x - 30}{\sqrt{21}}, \quad U : \mathcal{N}(0, 1) \right] = \mathcal{P}_{\mathcal{N}} \left\{ \frac{30.5 - 30}{\sqrt{21}} < U \right\} = \mathcal{P}_{\mathcal{N}} \{0.10911 < U\} \approx \\&= \mathcal{P}_{\mathcal{N}} \{0.11 < U\} = 0.5 - \Phi(0.11) = 0.5 - 0.04380 = 0.4562\end{aligned}$$

e)

$$\begin{aligned}
\mathcal{P}_{\mathcal{B}} \{X < 25\} &= \mathcal{P}_{\mathcal{B}} \{X \leq 24\} \approx \mathcal{P}_{\mathcal{N}} \{X < 24 + 0.5\} = \\
&= \left[ u = \frac{x - 30}{\sqrt{21}}, \quad U : \mathcal{N}(0, 1) \right] = \mathcal{P}_{\mathcal{N}} \left\{ U < \frac{24.5 - 30}{\sqrt{21}} \right\} = \mathcal{P}_{\mathcal{N}} \{U < -1.2002\} \approx \\
&\approx \mathcal{P}_{\mathcal{N}} \{U < -1.2\} = 0.5 - \Phi(0.12) = 0.5 - 0.38493 = 0.11507
\end{aligned}$$

**Primjer 2.28** Vjerojatnost rođenja dječaka je približno jednaka 0.515. Kolika je vjerojatnost da među 10000 novorođene djece bude više (ili jednako) djevojčica?

Rješenje: Definirajmo događaj  $A$ : rođen je dječak. Onda je događaj  $\bar{A}$ : nije rođen je dječak, tj. rođena je djevojčica. Sada se, 10000 novorođene djece može predočiti nizom

$$\underbrace{A, \bar{A}, \bar{A}, A, \dots, A, \bar{A}}_{10000}$$

Definirajmo slučajnu varijablu  $X$ : broj rođenih dječaka među 10000 novorođene djece. Tada je  $X : \mathcal{B}(10000, 0.515)$ . Tražena vjerojatnost onda je

$$\mathcal{P}_{\mathcal{B}} \{X < 5000\} = \mathcal{P}_{\mathcal{B}} \{X \leq 4999\} = \sum_{x=0}^{4999} \binom{10000}{x} (0.515)^x \cdot (0.485)^{10000-x}.$$

Vidimo da je ovo vrlo "naporno" za računati.

Budući je:

$$1) \frac{1}{n+1} = \frac{1}{10001} \approx 9.999 \times 10^{-5} < 0.515 < \frac{10000}{10001} \approx 0.9999,$$

$$2) npq = 10000 \cdot 0.515 \cdot 0.485 = 2497.75 > 9,$$

onda je moguće Binomnu razdiobu aproksimirati Normalnom razdiobom. Budući je  $np = 5150$  i  $npq = 2497.75$  onda je

$$\mathcal{B}(10000, 0.515) \approx \mathcal{N}(5150, 2497.75),$$

pa imamo:

$$\begin{aligned}
\mathcal{P}_{\mathcal{B}} \{X \leq 4999\} &\approx \mathcal{P}_{\mathcal{N}} \{X < 4999 + 0.5\} = \mathcal{P}_{\mathcal{N}} \{X < 4999.5\} = \\
&= \left[ u = \frac{x - 30}{\sqrt{21}}, \quad U : \mathcal{N}(0, 1) \right] = \mathcal{P}_{\mathcal{N}} \left\{ U < \frac{4999.5 - 5150}{\sqrt{2497.75}} \right\} \\
&= \mathcal{P}_{\mathcal{N}} \{U < -3.0114\} \approx \mathcal{P}_{\mathcal{N}} \{U < -3.01\} = 0.5 - \Phi(3.01) = 0.5 - 0.49869 = 0.00131.
\end{aligned}$$

## **Prilagođavanje teoretske razdiobe empiričkim podacima**

Statistički podaci koje dobivamo mjeranjem veličine  $X$  (numeričkog statističkog obilježja) čine skup **empiričkih podataka**, a njihova distribucija je **empirička distribucija** (raspodjela frekvencija).

Proučavanjem empiričkih distribucija pokazalo se da postoje zakoni, tj. analitički izrazi, koji, u nekim slučajevima sasvim dobro aproksimiraju dane empiričke podatke. Takav analitički izraz, ako postoji za neku empiričku distribuciju, predstavlja onda **teoretsku distribuciju**.

Prilagoditi teoretsku distribuciju frekvenciju empiričkim podacima zapravo znači naći analitički izraz na osnovi kojeg svakoj numeričkoj vrijednosti statističkog obilježja  $X$ , odnosno svakom razredu, s empiričkom frekvencijom  $f_x$ , možemo izračunati pripadnu teoretsku frekvenciju  $f_{tx}$ . Pri tome ćemo slučajnu varijablu tretirati kao statističko obilježje, a matematičko očekivanje kao aritmetičku sredinu.

Napomena: Za sve empiričke podatke nije moguće naći odgovarajuće teoretske zakone. Mi ćemo pokazati kako se Binomna, Poissonova i Normalna razdioba prilagođavaju empiričkim podacima.

## **Prilagođavanje Binomne razdiobe**

Binomna razdioba  $\mathcal{B}(n, p)$  je jednoznačno određena parametrima  $n$  i  $p$ . Zbog toga najprije, iz statističkih podataka, određujemo ta dva parametra. Iz definicije Binomne razdiobe vidimo da je  $n$  najveća moguća vrijednost koju može poprimiti slučajna varijabla  $X$  ( $R(X) = \{0, 1, \dots, n\}$ ). Dakle,  $n$  je teoretski najveća vrijednost koju može poprimiti diskretno statističko obilježje  $X$ , pa se  $n$  ne mora podudarati s najvećom vrijednošću za  $X$  empiričkih podataka. Budući je očekivanje kod Binomne razdiobe  $E[X] = np$ , onda, zamjenom  $E[X]$  s aritmetičkom sredinom  $\bar{x}$ , imamo:

$$\bar{x} = np \implies p = \frac{\bar{x}}{n}.$$

Nakon što smo odredili veličine  $n$  i  $p$ , teoretske frekvencije računamo po formuli

$$f_{tx} = N \cdot p(x),$$

gdje je  $N$  ukupan broj statističkih podataka, a  $p(x)$  vjerojatnost po Binomnoj razdiobi  $\mathcal{B}(n, p)$ , tj.

$$p(x) = \binom{n}{x} p^x q^{n-x}, \quad q = 1 - p.$$

**Primjer 2.29** Kontrolor kontrolira proizvodnju tako što u jednakim vremenskim razmacima uzima uzorak od 20 proizvoda i zabilježi broj neispravnih proizvoda u uzorku. Nakon 100 kontrola dobio je sljedeće podatke:

broj neispravnih proizvoda u uzorku $x$	0	1	2	3	4	5	6
frekvencija $f_x$	14	25	27	23	7	3	1

Prilagodite Binomnu razdiobu empiričkim podacima i nađite teoretske frekvencije. Za koju vrijednost  $x$ -a imamo najveće odstupanje teoretske od empiričke frekvencije.

Rješenje: Definirajmo događaj  $A$ : proizvod je neispravan. Onda je događaj  $\bar{A}$  : proizvod nije neispravan. Sada se, uzorak od 20 proizvoda može se predložiti nizom

$$\underbrace{A, \bar{A}, \bar{A}, A, \dots, A, \bar{A}}_{20}.$$

Definirajmo slučajnu varijablu  $X$  : broj neispravnih proizvoda u uzorku. Sada je teoretski

$$R(X) = \{0, 1, 2, \dots, 20\} \implies n = 20.$$

Treba nam  $\bar{x} = \frac{1}{N} \sum_{x=0}^6 x f_x$ .

$x$	$f_x$	$x f_x$	$p(x)$	$f_{tx} = 100 \cdot p(x)$
0	14	0	0.1216	12.16
1	25	25	0.2701	27.01
2	27	54	0.2852	28.52
3	23	69	0.1901	19.01
4	7	28	0.0898	8.98
5	3	15	0.0319	3.19
6	1	6	0.0089	0.89
	$N = \sum = 100$	$\sum = 197$	$\sum = 0.9976$	$\sum = 99.76$

Sada je, uz identifikaciju  $E[X] = np \equiv \bar{x}$ , imamo

$$\bar{x} = \frac{1}{N} \sum_{x=0}^6 x f_x = \frac{197}{100} = 1.97 \implies p = \frac{\bar{x}}{n} = \frac{1.97}{20} = 0.0985 \approx 0.1$$

Dakle,  $X : \mathcal{B}(20, 0.1)$ , pa vjerojatnosti  $p(x)$  imamo u tablicama ili ih računamo kao

$$p(x) = \binom{20}{x} (0.1)^x (0.9)^{n-x}, \quad q = 1 - 0.1 = 0.9.$$

za  $x = 0, 1, \dots, 6$ , ili pomoću rekurzivne formule.

Za vrijednost  $x = 3$  imamo najveće odstupanje

$$\Delta_3 = |f_3 - f_{t3}| = 3.99$$

teoretske od empiričke frekvencije. Ovdje je

$$E[X] = np = 1.97,$$

$$V[X] = npq = 1.97 \cdot 0.9 = 1.773.$$

### Prilagođavanje Poissonove razdiobe

Želimo li nekom empiričkom skupu podataka, za koji naslučujemo da se pokorava Poissonov zakon, prilagoditi teoretsku Poissonovu razdiobu, potrebno je odrediti veličinu  $m$  (jer je Poissonova razdioba  $\mathcal{P}_m$  jednoznačno određena s parametrom  $m$ ).

Budući je za  $X : \mathcal{P}_m$  očekivanje  $E[X] = m$ , onda za  $m$  uzimamo aritmetičku sredinu  $\bar{x}$ , tj.

$$m = \bar{x}.$$

Teoretske frekvencije računamo po formuli

$$f_{tx} = N \cdot p(x),$$

gdje je  $N$  ukupan broj podataka, a  $p(x)$  vjerojatnost po Poissonovoj razdiobi  $\mathcal{P}_m$ , tj.

$$p(x) = \frac{m^x}{x!} e^{-m}.$$

**Primjer 2.30** Empiričkim podacima zadanim u tablici

$x$	0	1	2	3	4	5
$f_x$	59	39	14	6	2	1

prilagodite Poissonovu razdiobu. Kolika je očekivana vrijednost  $E[x]$  i varianca  $V[x]$ ? Izračunajte pripadne teoretske frekvencije, te vjerojatnost da  $x$  poprimi vrijednost veću od 1.

Rješenje:

$x$	$f_x$	$xf_x$	$p(x)$	$f_{tx} = 121 \cdot p(x)$
0	59	0	0.44933	54.37
1	39	39	0.35946	43.49
2	14	28	0.14379	17.40
3	6	18	0.03834	4.64
4	2	8	0.00767	0.93
5	1	5	0.00123	0.15
	$N = \sum = 121$	$\sum = 98$		

$$\bar{x} = \frac{\sum x_i f_x}{N} = \frac{98}{121} \approx 0.80992 \approx 0.8 = m$$

$$X : \mathcal{P}_{0.8} \implies E[x] = V[x] = m = 0.8$$

Dakle,  $X : \mathcal{P}_{0.8}$ , pa vjerojatnosti  $p(x)$  imamo u tablicama ili ih računamo kao

$$p(x) = \frac{(0.8)^x}{x!} e^{-0.8},$$

za  $x = 0, 1, \dots, 5$  (ili pomoću rekurzivne formule). Sada je

$$E[x] = V[x] = m = 0.8,$$

te

$$\mathcal{P}\{x > 2\} = 1 - \mathcal{P}\{x = 0\} - \mathcal{P}\{x = 1\} = 0.19121.$$