

Rysunek 10: Przykłady rozkładu Poissona dla różnych wartości parametru μ

Definicja 13.4 (Proces Poissona).

Proces Poissona o intensywności λ jest zbiorem X_1, X_2, \dots punktów losowych o własnościach:

-

$$N_A = \text{Poi}(\mu = \lambda|A|)$$

gdzie N_A jest ilością punktów losowych zawartych w zbiorze A , λ jest intensywnością procesu a $|A|$ jest miarą zbioru A .

- Dla rozłącznych zbiorów A_1, A_2, \dots, A_n zmienne losowe $N_{A_1}, N_{A_2}, \dots, N_{A_n}$ są niezależne.

Proces Poissona modeluje **najbardziej losowy** sposób dystrybucji punktów losowych w czasie lub przestrzeni (długości, powierzchni, objętości,...).

Definicja 13.5 (Rozkład jednostajny).

Jeśli X ma gęstość prawdopodobieństwa:

$$f(x) = \frac{1}{\beta - \alpha} \quad x \in [\alpha, \beta]$$

to mówimy, że ma rozkład **jednostajny** na przedziale $[\alpha, \beta]$

- oznaczmy go jako $\text{unif}(\alpha, \beta)$;
- X opisuje **losowy** wybór liczby z przedziału $[\alpha, \beta]$

Twierdzenie 13.5 (Rozkład jednostajny).

Niech $X \sim \text{unif}(\alpha, \beta)$

$$E[X] = \frac{\alpha + \beta}{2}$$


$$\text{Var}[X] = \frac{(\beta - \alpha)^2}{12}$$

Definicja 13.6 (Rozkład wykładniczy).

Jeśli X ma gęstość prawdopodobieństwa:


$$f(x) = \lambda e^{-\lambda x} \quad x > 0$$

to mówimy, że ma rozkład **wykładniczy** o parametrze $\lambda (\lambda > 0)$



Rysunek 11: Porównanie rozkładu dwumianowego (histogram) z rozkładem Poissona (punkty) dla różnych wartości parametru p

- oznaczmy go jako $\exp(\lambda)$;
- X opisuje **czas życia** obiektów które się **nie starzeją**
- λ jest **odwrotnością średniego czasu życia** obiektu.



Rysunek 12: Przykłady rozkładu wykładniczego dla różnych wartości parametru λ

Twierdzenie 13.6 (Rozkład wykładniczy).

Niech $X \sim \exp(\lambda)$

$$E[X] = \frac{1}{\lambda}; \quad \text{Var}[X] = \frac{1}{\lambda^2}$$


Definicja 13.7 (Rozkład normalny(Gaussa)).

Jeśli X ma gęstość prawdopodobieństwa:

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

to mówimy, że ma rozkład **normalny** o parametrach μ, σ^2 ($|\mu| < \infty; \sigma \neq 0$)

- oznaczmy go jako $N(\mu, \sigma^2)$;
- X opisuje wiele sytuacji w których wielkość o wartości μ ulega "rozmyciu" z powodu np. błędów pomiarowych, fluktuacji statystycznych, szumów, ...



Rysunek 13: Przykłady rozkładu normalnego dla różnych wartości parametrów μ i σ

Twierdzenie 13.7 (Rozkład normalny).

Niech $X \sim N(\mu, \sigma^2)$

$$E[X] = \mu; \quad \text{Var}[X] = \sigma^2$$

Twierdzenie 13.8.

Niech $X \sim N(\mu, \sigma^2)$ a $Z = \frac{X - \mu}{\sigma}$. Wtedy

$$Z \sim N(0, 1)$$

Rozkład $N(0, 1)$ nazywamy **standardowym rozkładem normalnym**

Dowód.

$$\begin{aligned}
F_Z(z) = P(Z < z) &= P\left(\frac{X - \mu}{\sigma} < z\right) \\
&= P(X < \mu + z\sigma) \\
&= \int_{-\infty}^{\mu + z\sigma} \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2}\left(\frac{t-\mu}{\sigma}\right)^2} dt \\
&\quad y = \frac{t - \mu}{\sigma} \\
&= \int_{-\infty}^z \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(y)^2} dy = \Phi(z)
\end{aligned}$$

$\Phi(z)$ jest dystrybuantą $N(0, 1)$ □

Twierdzenie 13.9 (Rozkład normalny standardowy).

Niech $X \sim N(\mu, \sigma^2)$ dla dowolnych $a, b \in \mathbb{R}$ zachodzi

$$\begin{aligned}
F_X(x) = P(X \leq x) &= \Phi\left(\frac{x - \mu}{\sigma}\right) \\
P(a \leq X \leq b) &= \Phi\left(\frac{b - \mu}{\sigma}\right) - \Phi\left(\frac{a - \mu}{\sigma}\right)
\end{aligned}$$

Dowód.

$$\begin{aligned}
F_X(x) = P(X \leq x) &= P(X - \mu \leq x - \mu) \\
&= P\left(\frac{X - \mu}{\sigma} \leq \frac{x - \mu}{\sigma}\right) \\
&= \Phi\left(\frac{x - \mu}{\sigma}\right)
\end{aligned}$$

□

Twierdzenie 13.10 (Rozkład normalny standardowy).

Dla $x \in \mathbb{R}$

$$\Phi(-x) = 1 - \Phi(x)$$

Dowód.

$$\begin{aligned}
\Phi(-x) &= \int_{-\infty}^{-x} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(t)^2} dt \\
&= \int_x^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(t)^2} dt \\
&= \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(t)^2} dt - \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(t)^2} dt \\
&= 1 - \Phi(x)
\end{aligned}$$

□

Twierdzenie 13.11 (Kombinacja liniowa rozkładu normalnego).

Niech $X \sim N(\mu, \sigma^2)$ a $a, b \in \mathbb{R}$ oraz $Y = aX + b$. Wtedy

$$Y \sim N(a\mu + b, a^2\sigma^2)$$

Przykład 13.1 (Rozkład normalny).

Przyjmuje się, że iloraz inteligencji, $IQ \sim N(100, 15^2)$. Jakie jest pr., że losowo wybrany osobnik ma $IQ > 130$? Dla jakiej wartości x 99% populacji ma IQ przynajmniej x ?

Rozwiązanie.

$$\begin{aligned} P(IQ > 130) &= 1 - P(IQ \leq 130) \\ &= 1 - \Phi\left(\frac{130 - 100}{15}\right) \\ &= 1 - \Phi(2) \approx 1 - 0,9772 \approx 0,023 \end{aligned}$$

Rozwiązanie.

$$\begin{aligned} 0,99 = P(IQ > x) &= 1 - P(IQ \leq x) \\ &= 1 - \Phi\left(\frac{x - 100}{15}\right) \\ \Phi\left(\frac{x - 100}{15}\right) = 0,01 &\Rightarrow \frac{x - 100}{15} = \Phi^{-1}(0,01) \\ x = 100 + 15\Phi^{-1}(0,01) &\approx 100 + 15(-2,31) \approx 65,4 \end{aligned}$$

14 Twierdzenia graniczne

- Twierdzenia graniczne dotyczą własności funkcji zmiennych losowych

$$f(X_1, X_2, \dots, X_n) \text{ dla } n \rightarrow \infty$$

- W praktyce korzystamy z granicy do przybliżenia dokładnej wartości którą trudno jest policzyć

$$f(X_1, X_2, \dots, X_k) \approx \lim_{n \rightarrow \infty} f(X_1, X_2, \dots, X_n) \text{ dla } 1 \ll k < \infty$$

- Często praktyką jest powtarzanie pomiaru wielokrotnie w tych samych warunkach i prezentowanie wyniku jako wartość średnią z uzyskanych pomiarów.

$$\bar{X} = \frac{X_1 + X_2 + \dots + X_n}{n} = \frac{\sum_{i=1}^n X_i}{n}$$

- Niech X_k będą niezależnymi zmiennymi losowymi o średniej μ i wariancji σ^2

$$E[\bar{X}] = E\left[\frac{1}{n} \sum_{i=1}^n X_i\right] = \sum_{i=1}^n \frac{E[X_i]}{n} = \mu$$

$$Var[\bar{X}] = Var\left[\frac{1}{n} \sum_{i=1}^n X_i\right] = \sum_{i=1}^n \frac{Var[X_i]}{n^2} = \frac{\sigma^2}{n}$$

•

$$Var[\bar{X}] = \frac{\sigma^2}{n} \rightarrow 0 \text{ dla } n \rightarrow \infty$$

$$E[\bar{X}] = \mu \Rightarrow \bar{X} \rightarrow \mu \text{ dla } n \rightarrow \infty$$

- dla liczb

$$a_n \rightarrow a \Rightarrow \epsilon > 0, |a_n - a| < \epsilon \text{ dla } n > n_0$$

- dla zmiennych losowych nie można tak napisać

$$\bar{X} \rightarrow \mu \not\Rightarrow \epsilon > 0, |\bar{X} - \mu| < \epsilon \text{ dla } n > n_0$$

$$\bar{X} \rightarrow \mu \Rightarrow \epsilon > 0, P(|\bar{X} - \mu| > \epsilon) \rightarrow 0 \text{ dla } n \rightarrow \infty$$

Twierdzenie 14.1 (Prawo wielkich liczb).

Niech X_1, X_2, \dots będą niezależnymi zmiennymi losowymi o wartości oczekiwanej μ a \bar{X} będzie ich średnią. Wtedy dla dowolnego $\epsilon > 0$ zachodzi:


$$P(|\bar{X} - \mu| > \epsilon) \rightarrow 0 \text{ dla } n \rightarrow \infty$$

$$\bar{X} \xrightarrow{P} \mu \text{ dla } n \rightarrow \infty$$

Zbieżność w sensie prawdopodobieństwa

W szczególności w eksperymencie gdzie zdarzenie A zachodzi z prawdopodobieństwem $P(A)$ powtarzanym niezależnie n razy zdarzenie A zaszło k razy to

$$\frac{k}{n} \rightarrow P(A) \text{ dla } n \rightarrow \infty$$



Symulacja rzutów kostką do gry

Prawo wielkich liczb nie określa jak dokładne jest przybliżenie

$$\bar{X} \approx \mu \text{ dla } n \gg 1$$

Kolejne twierdzenia określa dokładność tego przybliżenia

Twierdzenie 14.2 (Centralne twierdzenie graniczne).

Niech X_1, X_2, \dots będą niezależnymi zmiennymi losowymi o wartości oczekiwanej μ i wariancji $\sigma^2 < \infty$. Wtedy dla dowolnego z zachodzi:

$$P\left(\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} < z\right) \rightarrow \Phi(z) \text{ dla } n \rightarrow \infty$$

gdzie Φ jest dystrybuantą standardowego rozkładu normalnego.

$$P\left(\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} < z\right) = P\left(\frac{\sum_{i=1}^n X_i - n\mu}{\sigma\sqrt{n}} < z\right)$$

Wnioski z centralnego twierdzenia granicznego:

$$P\left(\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} < z\right) \approx \Phi(z)$$

$$\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \xrightarrow{D} N(0, 1)$$

Zbieżność w sensie rozkładu.

$$\bar{X} \xrightarrow{D} N(\mu, \sigma^2/n)$$
$$\sum_{i=1}^n X_i \xrightarrow{D} N(n\mu, n\sigma^2)$$

W szczególności dla X o rozkładzie dwumianowym $\text{bin}(n, p)$

$$X \xrightarrow{D} N(\mu, \sigma^2) = N(np, np(1-p))$$