



Rozkłady prawdopodobieństwa

Statystyka i analiza danych 2019

Jurek Błaszczński

17 marca 2019

Rozkład normalny

Zmienna losowa $X \sim N(\mu, \sigma^2)$ ma następującą gęstość prawdopodobieństwa (PDF):

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

można pokazać, że:

$$E[X] = \mu, D^2[X] = \sigma^2$$

Rodzina rozkładów normalnych ma przydatną własność

Dowolna kombinacja liniowa zmiennych losowych o rozkładzie normalnym ma rozkład normalny

Przykład całkowania metodą Monte Carlo

Metodą Monte Carlo można obliczyć pole figury zdefiniowanej nierównością:

$$x^2 + y^2 \leq r^2,$$

czyli koła o promieniu r i środka w punkcie $(0, 0)$.

1. Losuje się n punktów z opisanego na tym kole kwadratu – dla koła o $r = 1$ współrzędne wierzchołków $(-1, -1)$, $(-1, 1)$, $(1, 1)$, $(1, -1)$.
2. Po wylosowaniu każdego z tych punktów trzeba sprawdzić czy jego współrzędne spełniają powyższą nierówność (tj. czy punkt należy do koła).

Wynikiem losowania jest informacja, że z n wszystkich prób k było trafionych, zatem (dla $r = 1$) pole koła wynosi:

$$P_k = P \times \frac{k}{n},$$

gdzie P jest polem kwadratu opisanego na tym kole ($P = 4$).

Jak wylosować liczbę z rozkładu normalnego mając do dyspozycji tylko generator liczb z zakresu $[0, 1]$ (jednostajnie)?

$$Unif[0, 1] \rightarrow 0 \dots 1,$$

$$X \sim Unif[0, 1],$$

$$Z = \Phi^{-1}(X),$$

gdzie Φ^{-1} jest kwantylem rozkładu $N(0, 1)$. To znaczy:

$$Z \sim N(0, 1), \Phi(z) = P(Z < z) = p, \Phi^{-1}(p) = z.$$

- **Dwupunktowy** $B_1(p)$, dla zmiennej losowej $X \in \{0, 1\}$ o funkcji prawdopodobieństwa, wartości oczekiwanej i wariancji:

$$P(X = 1) = 1 - P(X = 0) = p, \quad E[X] = p, \quad D^2[X] = p(1 - p).$$

- **Dwumianowy** $B_n(p)$:

$$X = \sum_{k=1}^n X_k, \quad \text{gdzie } X_k \sim B_1(p).$$

Suma n niezależnych zmiennych dwupunktowych. Zachodzi:

$$E[X] = np, \quad D^2[X] = np(1 - p).$$

Użyteczne własności

Niech X_1, \dots, X_n – **i.i.d.**¹ oraz $E[X_k] = \mu$, $D^2[X_k] = \sigma^2$.

- Dla sumy $X = \sum_{k=1}^n X_k$:

$$E[X] = E[X_1] + \dots + E[X_n] = n\mu,$$

$$D^2[X] = D^2[X_1] + \dots + D^2[X_n] = n\sigma^2.$$

- Dla średniej $\bar{X} = \frac{1}{n} \sum_{k=1}^n X_k = \frac{1}{n}X$:

$$E[\bar{X}] = \frac{1}{n}E[X] = \mu,$$

$$D^2[\bar{X}] = \frac{1}{n^2}D^2[X] = \frac{\sigma^2}{n}, \quad \text{czyli } D[\bar{X}] = \frac{\sigma}{\sqrt{n}}.$$

¹i.i.d.: *independent and identically distributed* – niezależne zmienne losowe o tym samym rozkładzie

X_1, \dots, X_n – **i.i.d.**², $E[X_k] = \mu$, $D^2[X_k] = \sigma^2$.

$$E[\bar{X}] = \mu, \quad D[\bar{X}] = \frac{\sigma}{\sqrt{n}}.$$

Rozkład średniej **koncentruje się** wokół wartości oczekiwanej μ .

²i.i.d.: *independent and identically distributed* – niezależne zmienne losowe o tym samym rozkładzie

Centralne Twierdzenie Graniczne

Znane też jest pod nazwą **Twierdzenie Lindeberga-Lévy'ego**. Niech X_1, \dots, X_n – **i.i.d.**, $E[X_k] = \mu$, $D^2[X_k] = \sigma^2$.

Zdefiniujemy **ustandaryzowaną** średnią $Z = \frac{\bar{X} - \mu}{\sigma} \sqrt{n}$.

$$E[Z] = 0, \quad D^2[Z] = 1.$$

Zachodzi:

$$Z \xrightarrow{D} N(0, 1).$$

Zgodnie z Centralnym Twierdzeniem Granicznym rozkład normalny występuje powszechnie.