

# Wykład IV: Wnioskowanie statystyczne - podstawy

Alicja Janic

Politechnika Wroclawska [alicja.janic@pwr.edu.pl](mailto:alicja.janic@pwr.edu.pl)

4 grudzień 2020

# Prosta próba losowa

## Definicja

**Prostą próbą losową** o licznosci  $n$  nazywamy ciąg niezależnych zmiennych losowych  $X_1, X_2, \dots, X_n$  określonych na przestrzeni  $\Omega$  i takich, że każda z nich ma ten sam rozkład

Konkretny ciąg wartości  $x_1, x_2, \dots, x_n$  próby losowej  $X_1, X_2, \dots, X_n$  będziemy nazywać **realizacją próby losowej**.

Jak wybierać reprezentatywną grupę elementów populacji?

Wybór  $n$  elementów populacji powinien być dokonany w taki sposób, żeby każdy podzbiór populacji, składających się z  $n$  elementów miał taką samą szansę wybrania

# Średnia w prostej próbie losowej

## Definicja

**Średnią w prostej próbie losowej**  $X_1, \dots, X_n$  o liczności  $n$  nazywamy statystykę

$$\bar{X} = \frac{(X_1 + X_2 + \dots + X_n)}{n}$$

Powyższa definicja jest szczególnym przypadkiem ogólnej definicji statystyki dla funkcji  $T$  zdefiniowanej w sposób następujący:

$$T(X_1, X_2, \dots, X_n) = \frac{X_1 + X_2 + \dots + X_n}{n}$$

Jaki jest cel przeniesienia definicji średniej z poziomu próby wartości na poziom prostej próby losowej? Badając rozkład średniej  $\bar{X}$ , jesteśmy w stanie przeanalizować jej zachowanie dla potencjalnej próby w terminach rachunku prawdopodobieństwa

## Prawo wielkich liczb

### Twierdzenie

Niech  $X$  będzie zmienną losową o skończonej wariancji,  $\sigma_X^2 < \infty$  i niech  $X_1, \dots, X_n$  będzie prostą próbą losową z rozkładu zmiennej losowej  $X$ . Wówczas dla dowolnie małej dodatniej liczby  $\epsilon$  prawdopodobieństwo

$$P(\bar{X} \in [\mu_X - \epsilon, \mu_X + \epsilon])$$

jest bliskie 1 dla dużych licznosci próby  $n$

Prawo wielkich liczb uzasadnia słuszność użycia średniej  $\bar{X}$  jako oszacowania wartości średniej  $\mu_X$

## Wskaźniki rozkładu średniej w prostej próbie losowej

### Stwierdzenie

Niech  $\bar{X}$  będzie średnią w prostej próbie losowej o licznosci  $n$  z rozkładu o wartości średniej  $m$  i wariancji  $\sigma^2$ . Wówczas

$$E(\bar{X}) = \mu_{\bar{X}} = m \quad \text{oraz} \quad \text{Var}(\bar{X}) = \sigma_{\bar{X}}^2 = \frac{\sigma^2}{n}$$

Jeżeli rozkład próby prostej jest normalny z parametrami  $m$  i  $\sigma$  to

$$\bar{X} \sim \mathcal{N}\left(m, \frac{\sigma}{\sqrt{n}}\right)$$

## Przykłady

### Przykład 1

Stwierdzono, że wzrost dorosłych Polaków jest cechą o rozkładzie normalnym o wartości średniej  $m = 176\text{cm}$  i odchyleniu standardowym  $\sigma = 6,5\text{cm}$ . Obliczyć prawdopodobieństwo, że średnia  $\bar{X}$  dla prostej próby losowej o licznosci 100 różni od prawdziwej wartości  $m$  o więcej niż  $1,5\text{cm}$

## Centralne twierdzenie graniczne dla średniej

### Twierdzenie

Niech  $X_1, \dots, X_n$  będzie prostą próbą losową z rozkładu o średniej  $m$  i skończonej wariancji  $\sigma^2$ . Wówczas dla dużych licznosci próby  $n$  rozkład standaryzowanej średniej  $\frac{\bar{X} - m}{\sigma/\sqrt{n}}$  jest bliski standardowemu rozkładowi normalnemu  $\mathcal{N}(0, 1)$ . Mianowicie, dla dowolnych liczb  $a$  i  $b$ ,  $a \leq b$ , i zmiennej losowej  $Z$  o standardowym rozkładzie normalnym

$$P\left(a \leq \frac{\bar{X} - m}{\sigma/\sqrt{n}} \leq b\right) \longrightarrow P(a \leq Z \leq b) = \Phi(b) - \Phi(a)$$

dla  $n$  dążących do nieskończoności. Równoważnie, rozkład średniej  $\bar{X}$  jest w przybliżeniu równy rozkładowi normalnemu  $\mathcal{N}\left(m, \frac{\sigma}{\sqrt{n}}\right)$

## Centralne twierdzenie graniczne dla sumy

### Twierdzenie

Niech  $X_1, \dots, X_n$  będzie prostą próbą losową z rozkładu o średniej  $m$  i skończonej wariancji  $\sigma^2$ . Wówczas dla dużych licznosci próby  $n$  rozkład standaryzowanej sumy  $\frac{\sum_{i=1}^n X_i - nm}{\sigma\sqrt{n}}$  jest bliski standardowemu rozkładowi normalnemu  $\mathcal{N}(0, 1)$ . Mianowicie, dla dowolnych liczb  $a$  i  $b$ ,  $a \leq b$ , i zmiennej losowej  $Z$  o standardowym rozkładzie normalnym

$$P\left(a \leq \frac{\sum_{i=1}^n X_i - nm}{\sigma\sqrt{n}} \leq b\right) \longrightarrow P(a \leq Z \leq b) = \Phi(b) - \Phi(a)$$

dla  $n$  dążących do nieskończoności. Równoważnie, rozkład sumy  $\sum_{i=1}^n X_i$  jest w przybliżeniu równy rozkładowi normalnemu  $\mathcal{N}(nm, \sigma\sqrt{n})$



# Poprawka w przybliżeniu normalnym

## Poprawka w przybliżeniu normalnym

w Centralnym Twierdzeniu Granicznym nie założyliśmy ciągłości rozkładu zmiennych  $X_i$ . W przypadku gdy zmienne  $X_i$  w prostej próbie losowej przyjmują wartości całkowite, dokonuje się poprawki w przybliżeniu normalnym, opartej na następującym rozumowaniu. Jeśli każda wartość w próbie jest liczbą całkowitą, to suma  $\sum_{i=1}^n X_i$  przyjmuje tylko wartości będące liczbami całkowitymi i dlatego dla dowolnych liczb całkowitych  $a$  i  $b$  możemy napisać

$$P(a \leq \sum_{i=1}^n X_i \leq b) = P(a - 0.5 \leq \sum_{i=1}^n X_i \leq b + 0.5)$$

## Przykłady

### Przykład 2

Komputer dodaje 1200 liczb rzeczywistych i każdą zaokrągla do najbliższej liczby całkowitej. Błędy zaokrągleń są niezależne i mają rozkład jednostajny na przedziale  $[-0.5, 0.5]$ . Obliczyć prawdopodobieństwo, że błąd w obliczeniu sumy przekroczy 10

## Rozwiązanie

Wprowadzając oznaczenia:  $X_i$  - błąd zaokrąglenia  $i$ -tej liczby otrzymujemy:

$$E(X_i) = 0 = m, \quad \text{Var}(X_i) = \frac{1}{12} = \sigma^2 \quad \text{oraz}$$
$$\text{Var}\left(\sum_{i=1}^{1200} X_i\right) = 1200 \cdot \frac{1}{12} = 100 = n\sigma^2$$

Zatem

$$P\left(\sum_{i=1}^{1200} X_i > 10\right) = P\left(\frac{\sum_{i=1}^{1200} X_i - 0}{10} > \frac{10-0}{10}\right) \approx P(Z > 1)$$
$$= 1 - \Phi(1) = 0.1587$$

## Przykłady

### Przykład 3

Czas pracy diody ma rozkład wykładniczy o wartości oczekiwanej  $m = 900h$ . Zgromadzono zapas 100 diod. Obliczyć prawdopodobieństwo, że wystarczy ich na 100.000 godzin pracy, jeżeli każdą diodę włączamy natychmiast po uszkodzeniu poprzedniej. Ile diod trzeba mieć w zapasie, by z prawdopodobieństwem większym niż 0,99 wystarczyło ich na 99.000 godzin pracy urządzenia.

# Rozwiązanie

## Przykłady

### Przykład 4

Rzucamy 30 razy kostką. Oszacujmy prawdopodobieństwo, że suma wyrzuconych oczek jest liczbą między 100 a 110

# Rozwiązanie

# Częstość

## Częstość

Częstością w prostej próbie losowej nazywamy statystykę

$$\hat{p} = \frac{\sum_{i=1}^n X_i}{n}$$

gdzie  $X_1, X_2, \dots, X_n$  jest prostą próbą losową z rozkładu dwupunktowego o wartościach 0 i 1. Statystykę  $\hat{p}$  obliczoną dla konkretnych wartości w próbie nazywamy wartością częstości

## Stwierdzenie

Częstość  $\hat{p}$  pomnożona przez licznosc próby  $n$  ma rozkład dwumianowy  $Bin(n, p)$ . Ponadto

$$E(\hat{p}) = p \quad \text{oraz} \quad Var(\hat{p}) = \frac{p(1-p)}{n}$$



## Twierdzenie Moivre'a-Laplace'a

### Twierdzenie

*Dla dowolnych rzeczywistych  $a$  i  $b$*

$$P\left(a \leq \frac{\hat{p} - p}{\sqrt{p(1-p)/n}} \leq b\right) \longrightarrow \Phi(b) - \Phi(a)$$

*gdy  $n$  dąży do nieskończoności*

*Analogicznie, jeśli  $S_n = n\hat{p}$*

$$P\left(a \leq \frac{S_n - np}{\sqrt{np(1-p)}} \leq b\right) \longrightarrow \Phi(b) - \Phi(a)$$

*gdy  $n$  dąży do nieskończoności*

Przybliżenie normalne uznajemy za zadowalające, gdy  $np \geq 5$  i  $n(1-p) \geq 5$

## Przykłady

### Przykład 5

W populacji dorosłych Polaków 39% ma kłopoty ze snem. Oszacujmy prawdopodobieństwo, że w prostej próbie losowej dorosłych Polaków o licznosci 100, częstość osób mających kłopoty ze snem nie przekroczy 0,33

# Rozwiązanie