

# Statystyka opisowa

Robert Pietrzykowski

email: [robert\\_pietrzykowski@sggw.pl](mailto:robert_pietrzykowski@sggw.pl)

[www.ekonometria.info](http://www.ekonometria.info)

# Na dziś...

- Sprawy bieżące

# Na dziś...

- Wykład 5:
  - Statystyka matematyczna
  - Estymatory punktowe i przedziałowe

Model probabilistyczny:

$$(\mathcal{X}, \mathcal{P}_\theta)$$

np.

$$\{0, 1\}, P_\theta(x) = \theta^x (1 - \theta)^{1-x}$$

gdzie  $\theta = p$  jest znaną liczbą.

Model statystyczny:

$$(\mathcal{X}, \{P_\theta, \theta \in \Theta\})$$

np.

$$(\{0, 1\}, \{P_\theta(x) = \theta^x (1 - \theta)^{1-x}, \theta \in (0, 1)\})$$

gdzie  $\theta = p$

# Estymacja parametrów rozkładu cechy

Estymujemy parametr  $\theta$  rozkładu cechy  $X$

Próba:  $X_1, X_2, \dots, X_n$

**Estymator (punktowy)** jest funkcją próby

$$\hat{\theta} = \hat{\theta}(X_1, X_2, \dots, X_n)$$

przybliżającą wartość parametru  $\theta$

# METODY WYZNACZANIA ESTYMATORÓW

Metoda największej wiarygodności.

Metoda najmniejszych kwadratów.

Przykład: zadania.pdf

## Podstawowe charakterystyki estymatorów:

1. Obciążenie estymatora  $\hat{\theta}(\mathbf{X})$  parametru  $\theta$ :

$$E(\hat{\theta}(\mathbf{X})) = \theta$$

2. Błąd średniokwadratowy estymatora  $\hat{\theta}(\mathbf{X})$  parametru  $\theta$ :

$$\begin{aligned} \text{BSK}_{\theta}(\hat{\theta}(\mathbf{X})) &= E[(\hat{\theta}(\mathbf{X}) - \theta)^2] \\ &= D^2[\hat{\theta}(\mathbf{X})] + [E(\hat{\theta}(\mathbf{X})) - \theta]^2 \end{aligned}$$

# Pożądane własności estymatora:

## 1. Nieobciążoność

$$E(\hat{\theta}(\mathbf{X})) = \theta, \text{ dla każdego } \theta \in \Theta$$

## 2. Zgodność

$$\lim_{n \rightarrow \infty} P\{|\hat{\theta}(\mathbf{X}) - \theta| > \varepsilon\} = 0, \text{ dla dowolnego } \varepsilon > 0.$$

## 3. Efektywność

Spośród zbioru wszystkich estymatorów nieobciążonych  $\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_r$  najefektywniejszym nazywamy estymator o **najmniejszej wariancji**.

Estymator nazywamy estymatorem nieobciążonym o minimalnej wariancji **ENMW**, jeżeli wśród wszystkich estymatorów nieobciążonych parametru  $\theta$  nie istnieje estymator, którego wariancja byłaby mniejsza dla dowolnej wartości parametru  $\theta \in \Theta$ .



# ROZKŁAD DWUMIANOWY

$p$  — frakcja, wskaźnik struktury

Próba:  $X_1, \dots, X_n$  ( $X_i = 0$  lub  $= 1$ )

$k = \sum_{i=1}^n X_i$  — ilość jedynek (sukcesów)

**Estymator punktowy:**

$$\hat{p} = \frac{k}{n}$$

$$\hat{p} \sim AN \left( p, \frac{1}{n} p(1 - p) \right)$$

# ROZKŁAD POISSONA

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

$$n\hat{\lambda} \sim \text{Poisson}(n\lambda)$$

$$\hat{\lambda} \sim AN \left( \lambda, \frac{\lambda}{n} \right)$$

# ROZKŁAD NORMALNY

Estymator średniej  $\mu$  — średnia arytmetyczna

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

Estymator wariancji  $\sigma^2$  — wariancja próbkowa

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

Estymator odchylenia standardowego  $\sigma$

$$S = \sqrt{S^2}$$

$$\hat{\mu} = \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \quad \bar{X} \sim N\left(\mu, \frac{\sigma^2}{n}\right)$$

$$\hat{\sigma}^2 = S^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2, \text{ EMM, ENW}$$

$$\hat{\sigma}^2 = S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2, \text{ ENMW, EMNK}$$

$$\frac{\sum_{i=1}^n (X_i - \bar{X})^2}{\sigma^2} \sim \chi_{n-1}^2$$

# Estymator przedziałowy

**Przedział ufności (estymator przedziałowy)** jest przedziałem o końcach zależnych od próby, który z pewnym z góry zadany prawdopodobieństwem pokrywa nieznaną wartość parametru  $\theta$

$$P\{\theta \in (\underline{\theta}(X_1, \dots, X_n), \bar{\theta}(X_1, \dots, X_n))\} = 1 - \alpha$$

**Poziom ufności:** prawdopodobieństwo  $1 - \alpha$

Przykład:

przedziały.xls

wykład2\_estymacja.xls

1. Rozkład dwupunktowy, przedział asymptotyczny:

$$p \in \left( \hat{p} - \sqrt{\frac{\hat{p}(1 - \hat{p})}{n}} U_{(1-\alpha/2)}, \hat{p} + \sqrt{\frac{\hat{p}(1 - \hat{p})}{n}} U_{(1-\alpha/2)} \right)$$

gdzie:  $U_{(1-\alpha/2)}$  jest kwantylem standardowego rozkładu normalnego  $N(0, 1)$  rzędu  $1 - \alpha/2$ .

2. Rozkład Poissona, przedział asymptotyczny:

$$\lambda \in \left( \hat{\lambda} - \sqrt{\frac{\hat{\lambda}}{n}} U_{(1-\alpha/2)}, \hat{\lambda} + \sqrt{\frac{\hat{\lambda}}{n}} U_{(1-\alpha/2)} \right)$$



### 3. Rozkład normalny:

$$\mu \in \left( \bar{X} - \frac{S}{\sqrt{n}} t_{(\alpha, n-1)}, \bar{X} + \frac{S}{\sqrt{n}} t_{(\alpha, n-1)} \right)$$

gdzie  $S = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2}$  oraz  $t_{(\alpha, n-1)}$  to wartość krytyczna z rozkładu t-Studenta o  $n-1$  stopniach swobody.

$$\sigma^2 \in \left( \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{\chi_{(1-\alpha/2, n-1)}^2}, \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{\chi_{(\alpha/2, n-1)}^2} \right)$$

gdzie:  $\chi_{(\alpha, n-1)}^2$  to kwantyl z rozkładu Chi-kwadrat o  $n - 1$  stopniach swobody rzędu  $\alpha$ .

Co wpływa na długość przedziału ufności?

$$[10.00 - 1.25 = 8.75; 10.00 + 1.25 = 11.25]$$

$d =$

- Liczebność próby
- Poziom ufności
- Wariancja

# PYTANIA

1. Co wpływa na długość przedziału ufności?
2. Podaj wzór na przedział ufności dla średniej w rozkładzie normalnym.
3. Podaj wzór na przedział ufności dla wariancji w rozkładzie Poissona.
4. Wyjaśnij pojęcie poziom ufności.
5. Czy można powiedzieć o informacji podawanej dla pewnego modelu samochodu, że średnie zużycie paliwa wynosi 6 litrów na 100 km. Mając informację o zużyciu paliwa dla tego modelu samochodu w postaci przedziału ufności (5,82; 7,48) na poziomie ufności 95% .
6. Wymień znane Ci sposoby uzyskiwania estymatorów.
7. Co jest estymatorem  $\mu$  w rozkładzie normalnym. Jaki rozkład ma ten estymator.
8. W jakim rozkładzie prawdopodobieństwa estymator średniej jest taki sam jak estymator wariancji.
9. Z jakich elementów skład się model statystyczny.
10. Jaki rozkład ma asymptotyczny estymator  $p$  w rozkładzie dwumianowym.