



Statystyki Opisowe

Statystyka i analiza danych 2019

Jurek Błaszczński

10 marca 2019

Miary położenia (tendencji centralnej)

- Dominanta (moda)
- Średnia arytmetyczna ($\mu, \bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$)
- Mediana ($x_{med} = x_{(n+1)/2}$; gdy rozmiar próby n jest nieparzysty)
- Percentyle (k -tym percentylem nazywamy wartość należącą do próby, poniżej której znajduje się $k\%$ obserwacji z tej próby)
- Kwartyle (pierwszy kwartył Q_1 to 25 percentyl, drugi kwartył Q_2 (mediana) to 50 percentyl, trzeci kwartył Q_3 to 75 percentyl)
- Średnia geometryczna ($\bar{x}_G = \sqrt[n]{\prod_{i=1}^n x_i}$)
- Średnia harmoniczna ($\bar{x}_H = \frac{n}{\sum_{i=1}^n \frac{1}{x_i}}$)

Średnia a mediana

- Czy średnia i/lub mediana należą do zbioru wartości przyjmowanych przez dane?
- Która z miar jest bardziej odporna na wartości odstające?
- Według Facebooka (2011), średnia liczba znajomych użytkowników portalu wynosi 190, a połowa użytkowników ma więcej niż 100 znajomych. Dlaczego?
- Domy w pewnej okolicy mają średnią wartość 1mln PLN, ale mediana wynosi tylko 600 tys. PLN. Skąd ta różnica?
- Ile wynosi suma odchyleń od średniej $\sum_{i=1}^n (x_i - \bar{x})$?

- Rozstęp ($R = x_{\max} - x_{\min}$)
- Wariancja ($\sigma^2, S^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$)
- Odchylenie standardowe ($\sigma, S = \sqrt{S^2}$)
- Rozstęp międzykwartylowy ($IQR = Q_3 - Q_1$)

Wariancja i odchylenie standardowe

- Jak zmienia się wariancja gdy do wszystkich obserwacji w próbie dodamy stałą?
- Co się stanie z wariancją gdy wszystkie obserwacje w próbie przemnożymy przez stałą?
- Po co nam odchylenie standardowe?

- Moment centralny (rzędu k : $M_k = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^k$)
- Współczynnik asymetrii lub skośności ($\frac{M_3}{S^3}$)
- Współczynnik koncentracji lub kurtoza ($\frac{M_4}{S^4}$)

Nierówność Markowa

Założmy, że średnia pewnych nieujemnych wartości (liczb) x_i wynosi \bar{x} .

Wtedy stosunek wartości większych lub równych od wybranego x' jest mniejszy lub równy $\frac{\bar{x}}{x'}$.

Formalnie

Niech X będzie nieujemną zmienną losową i założmy, że istnieje $\mathbb{E}(X)$.

Wtedy, dla każdego $x' > 0$:

$$P(X \geq x') \leq \frac{\mathbb{E}(X)}{x'}.$$

Nierówność Czebyszewa

Założmy, że średnia pewnych wartości (liczb) x_i wynosi \bar{x} a odchylenie standardowe wynosi S .

Wtedy stosunek wartości oddalonych od średniej \bar{x} o wybrane k lub więcej odchyłeń standardowych jest mniejszy lub równy $\frac{1}{k^2}$.

Formalnie

Niech $\mu = \mathbb{E}(X)$, $\sigma^2 = \mathbb{D}^2(X)$ i $Z(X) = \frac{X - \mathbb{E}(X)}{\mathbb{D}(X)} = \frac{X - \mu}{\sigma}$.

Wtedy:

$$P(|X - \mu| \geq x') \leq \frac{\sigma^2}{x'^2},$$

$$P(|Z| \geq k) \leq \frac{1}{k^2}.$$