

Wnioskowanie statystyczne

21 marca 2014

Powtórzenie

x - zmienna losowa $\sim N(x_0, \sigma)$

Jakie jest prawdopodobieństwo, że

$$x_0 - z \sigma \leq x_{\text{śr}} \leq x_0 + z \sigma$$

Powtórzenie

x - zmienna losowa $\sim N(x_0, \sigma)$

Jakie jest prawdopodobieństwo, że

$$x_0 - z \sigma \leq x_{\text{śr}} \leq x_0 + z \sigma$$

Takie same jak prawdopodobieństwo, że

$$-z \leq (x_{\text{śr}} - x_0) / \sigma \leq z$$

P = poziom ufności

$$P = 2 * \text{norm.cdf}(z) - 1$$

$N(0,1)$

Powtórzenie

x - zmienna losowa $\sim N(x_0, \sigma)$

Jakie jest prawdopodobieństwo, że

$$x_0 - z \sigma \leq x_{\text{śr}} \leq x_0 + z \sigma$$

Takie same jak prawdopodobieństwo, że

$$-z \leq (x_{\text{śr}} - x_0) / \sigma \leq z$$

P = poziom ufności

$$P = 2 * \text{norm.cdf}(z) - 1$$

Jeżeli oznaczymy $\alpha = 1 - P$ = poziom istotności

$$\alpha = 2 - 2 * \text{norm.cdf}(z)$$

$$z = \text{norm.ppf}(1 - \alpha / 2)$$

$N(0,1)$

Wartość oczekiwana (1)

Założenia:

- 1) badana zmienna ma rozkład normalny
- 2) znamy wariancję σ^2 populacji

$x_{\text{śr}}$ - zmierzona wartość średniej (lub `numpy.mean(...)`)

n - liczba pomiarów

σ - znana wariancja

α - poziom istotności (np. 0.05)

$$z_{\alpha/2} = \text{scipy.stats.norm.ppf}(1-\alpha/2)$$

przedział ufności dla wartości oczekiwanej populacji:

$$x_{\text{śr}} \pm z_{\alpha/2} \sigma / \sqrt{n}$$

Dygresja: rozmiar próby

“Promień” przedziału ufności, czyli maksymalna odległość pomiędzy wartością zmierzoną i prawdziwą wynosi

$$D = z_{\alpha/2} \sigma / \sqrt{n}$$

Rozmiar próby dla ustalonego $D \square D_0$

$$z_{\alpha/2} \sigma / \sqrt{n} \square D_0$$

$$\sqrt{n} \square z_{\alpha/2} \sigma / D$$

$$z_{\alpha/2} = \text{scipy.stats.norm.ppf}(1-\alpha/2)$$

$$n = \text{math.ceil}((z_{\alpha/2} * \sigma / D) ** 2)$$

Wartość oczekiwana (2)

Założenia:

- 1) badana zmienna ma rozkład normalny
- 2) **nie** znamy wariancji populacji

$x_{\text{śr}}$ - zmierzona wartość średniej (lub `numpy.mean(pomiary)`)

n - liczba pomiarów

α - poziom istotności (np. 0.05)

```
s = numpy.std(pomiary)
```

```
t $\alpha/2$  = scipy.stats.t(n-1).ppf(1- $\alpha/2$ )
```

przedział ufności dla wartości oczekiwanej populacji:

$$x_{\text{śr}} \pm t_{\alpha/2} s / \sqrt{(n-1)}$$

Wartość oczekiwana (3)

Założenia:

- 1) badana zmienna ma rozkład normalny
- 2) nie znamy wariancji populacji
- 3) pomiarów jest bardzo dużo ($n > 30$)

$x_{\text{śr}}$ - zmierzona wartość średniej (lub `numpy.mean(pomiary)`)
 n - liczba pomiarów

α - poziom istotności (np. 0.05)

$$s = \text{numpy.std}(pomiary)$$
$$z_{\alpha/2} = \text{scipy.stats.norm.ppf}(1-\alpha/2)$$

przedział ufności dla wartości oczekiwanej populacji:

$$x_{\text{śr}} \pm z_{\alpha/2} s / \sqrt{n}$$

Wariancja

Założenia:

- 1) badana zmienna ma rozkład normalny
- 2) **nie** znamy wariancji populacji

\bar{x}_{sr} - zmierzona wartość średniej (lub `numpy.mean(pomiary)`)
n - liczba pomiarów

α - poziom istotności (np. 0.05)

$$s = \text{numpy.std}(pomiary)$$
$$x^2_L = \text{scipy.stats.chi2}(n-1).ppf(\alpha/2)$$
$$x^2_P = \text{scipy.stats.chi2}(n-1).ppf(1-\alpha/2)$$

przedział ufności dla wariancji populacji:

$$(n-1)s^2/x^2_L \leq \sigma^2 \leq (n-1)s^2/x^2_P$$

Co, jeżeli

- zmienna losowa **nie** jest z rozkładu normalnego?
- chcemy zbadać przedział ufności
np. dla **mediany** ?
- chcemy numerycznie zweryfikować wyniki?
- nie znamy wzorów?

Bootstrap

Jedna seria pomiarów → jeden wynik

Wiele serii pomiarów → wiele wyników

Jak zrobić wiele serii z jednej?

Bootstrap

Jedna seria pomiarów → jeden wynik

Wiele serii pomiarów → wiele wyników

Jak zrobić wiele serii z jednej?

Losujemy ze zwracaniem.

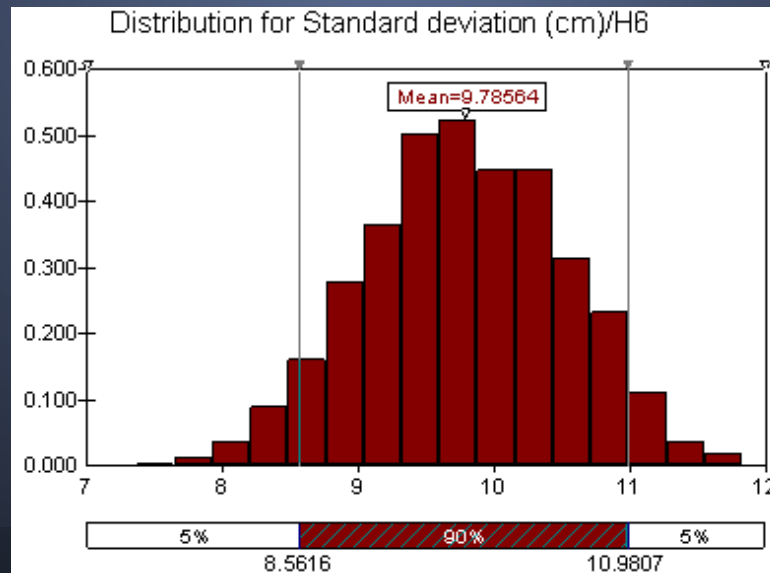
```
def randsample(old_sample) :  
    n = len(old_sample)  
    ind = numpy.random.randint(n, size = n)  
    y = old_sample[ind]  
    return y
```

lub np.

```
    n = len(old_sample)  
    numpy.random.choice(old_sample, size = n)
```

Bootstrap

1. Generujemy wiele serii pomiarów i dla każdej z nich obliczamy żadaną wartość.
2. Wyniki tworzą próbę z jakiegoś (nieznanego) rozkładu.
3. Wyciągamy z wyników odpowiedni kwantyl.



Bootstrap

1. Generujemy wiele serii pomiarów i dla każdej z nich obliczamy żadaną wartość.
2. Wyniki tworzą próbę z jakiegoś (nieznanego) rozkładu.
3. Wyciągamy z wyników odpowiedni kwantyl.

Przykład (przedział ufności dla średniej przy $\alpha=0.1$ czyli 10%):

1. Generujemy wiele serii pomiarów i dla każdej obliczamy średnią.
2. Bierzemy wyniki (tablicę średnich) i obliczamy kwantyle dla $\alpha/2$ i $1-\alpha/2$
 - $x_L = \text{scipy.stats.scoreatpercentile}(\text{wyniki}, 5.0)$
 - $x_P = \text{scipy.stats.scoreatpercentile}(\text{wyniki}, 95.0)$
3. Przedziałem ufności jest $[x_L ; x_P]$