



Rodzina przekształceń Boxa-Coxa (dla $x > 0$)

$$h_p(x) = \begin{cases} \frac{x^p - 1}{p} & p \neq 0 \\ \ln x & p = 0 \end{cases}$$



Box-Cox dla $p=1,2,3$



Box-Cox dla $p=1,0,-1,-2$

$$h'_p(x) = x^{p-1}$$

Zadanie. Znaleźć p takie, że $\gamma(\alpha, h_p(x)) \simeq 0$ dla wszystkich $\alpha < 0.5$

Niech $x_{(n+1-k)} > x_{(k)}$ dla $k \leq \frac{n+1}{2}$

Dla $\alpha_k = \frac{2k-1}{2n+1}$ kwantyl $q(\alpha_k) = x_{(k)}$

Dla n nieparzystych

$$\gamma(\alpha_k, h_p(x)) = \begin{cases} \frac{x_{(n+1-k)}^p + x_{(k)}^p - 2 * x_{(r)}^p}{x_{(n+1-k)}^p - x_{(k)}^p} & p \neq 0 \\ \frac{\ln(x_{(n+1-k)}) + \ln(x_{(k)}) - 2 * \ln(x_{(r)})}{\ln(x_{(n+1-k)}) - \ln(x_{(k)})} & p = 0 \end{cases}, r = \frac{n+1}{2}$$

Dla n parzystych, dane uzupełniamy o dodatkowy wyraz, równy $\tilde{x} = \frac{x_{(\frac{n}{2})} + x_{(\frac{n}{2}+1)}}{2}$.

Niech

$$u_k^- \stackrel{df}{=} \frac{\tilde{x}}{x_{(k)}} > 1, u_k^+ \stackrel{df}{=} \frac{x_{(n+1-k)}}{\tilde{x}} > 1,$$

Wtedy dla ustalonego k przyjmując na chwilę dla uproszczenia oznaczenie

$$u_k^- = u_-, u_k^+ = u_+$$

$$f(p) \stackrel{df}{=} \gamma(\alpha_k, h_p(x)) = \begin{cases} \frac{u_+^p + u_-^p - 2}{u_+^p - u_-^p} & p \neq 0 \\ \frac{\ln u_+ - \ln u_-}{\ln u_+ + \ln u_-} & p = 0 \end{cases}$$

oraz $f(p)$ jest ciągłą funkcją p .

Zadanie sprowadza się do rozwiązania równania $f(p) = 0$.


Zadanie to ma rozwiązanie, gdyż

$$\lim_{p \rightarrow \infty} f(p) = \lim_{p \rightarrow \infty} \frac{u_+^p - 2}{u_+^p} = 1,$$

$$\lim_{p \rightarrow -\infty} f(p) = \lim_{p \rightarrow -\infty} \frac{u_-^{-p} - 2}{-u_-^{-p}} = -1$$

Prosta, przechodząca przez punkty $(-1, f(-1))$ i $(1, f(1))$ ma równanie

$$\frac{f(1) - f(-1)}{2}(p - 1) + f(1)$$



Z metody siecznych przybliżone rozwiązanie równania

$$f(p) = 0$$

jest rozwiązaniem równania

$$\frac{f(1) - f(-1)}{2}(p - 1) + f(1) = 0$$

skąd

$$\begin{aligned} p &\simeq \frac{f(-1) + f(1)}{f(-1) - f(1)} = \\ &= \frac{\frac{u_+^{-1} + u_- - 2}{u_+^{-1} - u_-} + \frac{u_+ + u_-^{-1} - 2}{u_+ - u_-^{-1}}}{\frac{u_+^{-1} + u_- - 2}{u_+^{-1} - u_-} - \frac{u_+ + u_-^{-1} - 2}{u_+ - u_-^{-1}}} = \frac{\frac{1 + u_+ u_- - 2u_+}{1 - u_- u_+} + \frac{u_+ u_- + 1 - 2u_-}{u_+ u_- - 1}}{\frac{1 + u_+ u_- - 2u_+}{1 - u_- u_+} - \frac{u_+ u_- + 1 - 2u_-}{u_+ u_- - 1}} \\ &= \frac{(1 + u_+ u_- - 2u_+) - (u_+ u_- + 1 - 2u_-)}{(1 + u_+ u_- - 2u_+) + (u_+ u_- + 1 - 2u_-)} \\ &= \frac{2(u_- - u_+)}{2(1 + u_+ u_- - u_+ - u_-)} \\ &= \frac{1}{u_+ - 1} - \frac{1}{u_- - 1} \end{aligned}$$

Przykład 1.

k	1	2	3	4	5	6	7
$x^{(k)}$	1	4	9	16	25	36	49

Dane są kwadratami kolejnych liczb naturalnych.

k	1	2	3
u_-	$\frac{16}{1} = 16$	$\frac{16}{4} = 4$	$\frac{16}{9} = 1.78$
u_+	$\frac{49}{16} = 3.06$	$\frac{36}{16} = 2.25$	$\frac{25}{16} = 1.56$
p	$\frac{1}{3.06-1} - \frac{1}{16-1} = 0.42$	$\frac{1}{2.25-1} - \frac{1}{4-1} = 0.47$	$\frac{1}{1.56-1} - \frac{1}{1.78-1} = 0.50$

Wartości p są w pobliżu $1/2$. Pierwiastek symetryzuje te dane - co było jasne od początku.

Przykład 2.

Odległości planet od Słońca w jednostkach astronomicznych (odległość Ziemi=1)

1	2	3	4	5	6	7	8	9
0.4	0.7	1.0	1.5	5.2	9.5	19.2	30.0	39.4

	1	2	3	4	5
u_-	13.0	7.43	5.20	3.47	
u_+	7.58	5.77	3.69	1.83	
p	0.07	0.05	0.13	0.80	

Mediana wartości p , równa 0.10 jest najlepszym oszacowaniem p . Wybierając najbliższą wartość całkowitą otrzymać można skalę, symetryzującą dane o planetach. Jest to skala logarytmiczna. ■

Poniższy diagram ilustruje tezę, że gdy dane dadzą się zszytyzować, to najlepszą miarą typowości jest mediana

$$\begin{array}{ccc}
 x & \xrightarrow{h_p} & y \\
 \downarrow & & \downarrow \\
 \tilde{x} & \xleftarrow{h_p^{-1}} & \tilde{y}
 \end{array}$$