

# Rachunek prawdopodobieństwa i statystyka

Wykład 14

# Linie regresji II-go rodzaju

Liniami regresji II-go rodzaju zmiennej  $y$  ( $x$ ) względem  $x$  ( $y$ ) nazywamy zadane krzywe  $y = g(x; \theta_1, \theta_2, \dots)$  oraz  $x = h(y; \theta_1, \theta_2, \dots)$  gdy spełniają one odpowiednio warunki:

$$\mathcal{E}\left[\left(y - g(x; \theta_1, \theta_2, \dots)\right)^2\right] = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \left(y - g(x; \theta_1, \theta_2, \dots)\right)^2 f(x, y) dx dy = \min(\theta_1, \theta_2, \dots)$$

$$\mathcal{E}\left[\left(x - h(y; \theta_1, \theta_2, \dots)\right)^2\right] = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \left(x - h(y; \theta_1, \theta_2, \dots)\right)^2 f(x, y) dx dy = \min(\theta_1, \theta_2, \dots)$$

W szczególności proste regresji II-go rodzaju mają postać:

$$y = \rho \frac{\sigma_y}{\sigma_x} x - \rho \frac{\sigma_y}{\sigma_x} \mu_x + \mu_y$$

$$x = \rho \frac{\sigma_x}{\sigma_y} y - \rho \frac{\sigma_x}{\sigma_y} \mu_y + \mu_x \quad \Rightarrow \quad y = \frac{1}{\rho} \frac{\sigma_y}{\sigma_x} x - \frac{1}{\rho} \frac{\sigma_y}{\sigma_x} \mu_x + \mu_y$$

W praktyce zazwyczaj nie znamy łącznej funkcji rozkładu zmiennych, z której pochodzą zmienne (a więc także obu dyspersji i współczynnika korelacji), a krzywe regresji musimy określać z próbki dyskretnych danych.

# Metoda najmniejszych kwadratów

Założmy, że mierzymy  $N$  niezależnych wartości  $y_1, \dots, y_n$  każda z rozkładu Gaussa o nieznanej wartości oczekiwanej i znanej wariancji:

$$\mathcal{E}[y_i] = \eta(x_i; \vec{\theta}) \quad \mathcal{V}[y_i] = \sigma_i^2$$

Wielkości  $x_i$  to tzw. zmienne kontrolowane, objaśniające, które zakładamy, że są znane dokładnie.


Chcemy oszacować nieznane parametry  $\theta$  tak aby dopasowanie krzywej do punktów było możliwie najlepsze.

Konstruujemy łączną funkcję gęstości p-twa

$$g(y_1, \dots, y_n; \eta_1, \dots, \eta_n; \sigma_1^2, \dots, \sigma_n^2) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma_i^2}} \exp\left(-\frac{(y_i - \eta_i)^2}{2\sigma_i^2}\right)$$

Wówczas log funkcji wiarygodności ma postać (pomijamy wyrazy niezależne od parametrów):

$$\ln \mathcal{L}(\vec{\theta}) = -\frac{1}{2} \sum_{i=1}^n \frac{(y_i - \eta(x_i; \vec{\theta}))^2}{\sigma_i^2} + \dots$$



# Metoda najmniejszych kwadratów

Zasada najmniejszych kwadratów głosi, że parametry  $\theta_i$  należy dobrać tak, aby spełniały one warunek:

$$\mathcal{R}(\vec{\theta}) = \sum_{i=1}^n \frac{(y_i - \eta(x_i; \vec{\theta}))^2}{\sigma_i^2} = \min(\vec{\theta})$$

W przypadku skorelowanych pomiarów korzystamy z wielowymiarowego rozkładu Gaussa ze znaną macierzą kowariancji  $\mathbf{V}$ :

$$g(\vec{x}; \vec{\mu}, \mathbf{V}) = \frac{1}{(\sqrt{2\pi})^n |\mathbf{V}|^{1/2}} \exp\left(-\frac{1}{2}(\vec{x} - \vec{\mu})^T \mathbf{V}^{-1}(\vec{x} - \vec{\mu})\right)$$

Wtedy

$$\ln \mathcal{L}(\vec{\theta}) = -\frac{1}{2} \sum_{i,j=1}^n (y_i - \eta(x_i; \vec{\theta})) (\mathbf{V}^{-1})_{ij} (y_j - \eta(x_j; \vec{\theta})) + \dots$$

a zasada najmniejszych kwadratów sprowadza się do warunku

$$\mathcal{R}(\vec{\theta}) = \sum_{i,j=1}^n (y_i - \eta(x_i; \vec{\theta})) (\mathbf{V}^{-1})_{ij} (y_j - \eta(x_j; \vec{\theta})) = \min(\vec{\theta})$$

Zależność funkcyjną  $\eta(x_i; \hat{\theta})$  nazywamy krzywą regresji najlepszego dopasowania metody najmniejszych kwadratów. Parametry  $\hat{\theta}$  to estymatory MNK.

# MNK - przypadek liniowy

Rozważmy sytuację kiedy związek pomiędzy parametrami  $\theta_i$ , a wielkością mierzoną  $\eta$  przyjmuje postać liniową:

$$\eta(x; \vec{\theta}) = \varphi_1(x)\theta_1 + \varphi_2(x)\theta_2 + \dots + \varphi_m(x)\theta_m$$

Dla  $n$  punktów pomiarowych  $(x_i, y_i)$   $i = 1, \dots, n$  otrzymujemy układ  $n$  równań:

$$\begin{cases} \eta_1 = \varphi_1(x_1)\theta_1 + \varphi_2(x_1)\theta_2 + \dots + \varphi_m(x_1)\theta_m \\ \eta_2 = \varphi_1(x_2)\theta_1 + \varphi_2(x_2)\theta_2 + \dots + \varphi_m(x_2)\theta_m \\ \vdots \\ \eta_n = \varphi_1(x_n)\theta_1 + \varphi_2(x_n)\theta_2 + \dots + \varphi_m(x_n)\theta_m \end{cases} \Leftrightarrow \vec{\eta} = \Phi \vec{\theta}$$

gdzie:

$$\vec{\eta} = \begin{pmatrix} \eta_1 \\ \eta_2 \\ \vdots \\ \eta_n \end{pmatrix} \quad \Phi = \begin{bmatrix} \varphi_1(x_1) & \varphi_2(x_1) & \cdots & \varphi_m(x_1) \\ \varphi_1(x_2) & \varphi_2(x_2) & \cdots & \varphi_m(x_2) \\ \vdots & \vdots & \ddots & \vdots \\ \varphi_1(x_n) & \varphi_2(x_n) & \cdots & \varphi_m(x_n) \end{bmatrix} \quad \vec{\theta} = \begin{pmatrix} \theta_1 \\ \theta_2 \\ \vdots \\ \theta_m \end{pmatrix}$$

Macierz  $\Phi$  nazywamy macierzą konstrukcyjną.

# MNK - przypadek liniowy

Zasada najmniejszych kwadratów przyjmuje postać (oznaczenie  $\mathbf{Q} \equiv \mathbf{V}^{-1}$ ):

$$\mathcal{R} = (\vec{y} - \Phi\vec{\theta})^T \mathbf{Q} (\vec{y} - \Phi\vec{\theta}) = (\vec{y}^T - \vec{\theta}^T \Phi^T) \mathbf{Q} (\vec{y} - \Phi\vec{\theta}) = \min(\vec{\theta})$$

Wypiszemy wielkość  $\mathcal{R}$  w jawnej postaci:

$$\begin{aligned} \mathcal{R} &= \sum_{i,j=1}^n \left( y_i - \sum_{k=1}^m \varphi_k(x_i) \theta_k \right) Q_{ij} \left( y_j - \sum_{l=1}^m \varphi_l(x_j) \theta_l \right) = \sum_{i,j=1}^n y_i Q_{ij} y_j - \\ &\quad - \sum_{i,j=1}^n \sum_{k=1}^m \varphi_k(x_i) \theta_k Q_{ij} y_j - \sum_{i,j=1}^n \sum_{l=1}^m y_i Q_{ij} \varphi_l(x_j) \theta_l + \sum_{i,j=1}^n \sum_{k,l=1}^m \varphi_k(x_i) \theta_k Q_{ij} \varphi_l(x_j) \theta_l = \\ &= \sum_{i,j=1}^n y_i Q_{ij} y_j - 2 \sum_{i,j=1}^n \sum_{k=1}^m \varphi_k(x_i) \theta_k Q_{ij} y_j + \sum_{i,j=1}^n \sum_{k,l=1}^m \varphi_k(x_i) \theta_k Q_{ij} \varphi_l(x_j) \theta_l \end{aligned}$$

Różniczkujemy względem parametru  $\theta_p$ :

$$\begin{aligned} \frac{\partial \mathcal{R}}{\partial \theta_p} &= -2 \sum_{i,j=1}^n \sum_{k=1}^m \varphi_k(x_i) \delta_{kp} Q_{ij} y_j + \sum_{i,j=1}^n \sum_{k,l=1}^m \varphi_k(x_i) \delta_{kp} Q_{ij} \varphi_l(x_j) \theta_l + \\ &\quad + \sum_{i,j=1}^n \sum_{k,l=1}^m \varphi_k(x_i) \theta_k Q_{ij} \varphi_l(x_j) \delta_{lp} = \\ &= -2 \sum_{i,j=1}^n \varphi_p(x_i) Q_{ij} y_j + \sum_{i,j=1}^n \sum_{l=1}^m \varphi_p(x_i) Q_{ij} \varphi_l(x_j) \theta_l + \sum_{i,j=1}^n \sum_{k=1}^m \varphi_k(x_i) \theta_k Q_{ij} \varphi_p(x_j) \end{aligned}$$

# MNK - przypadek liniowy

Zamieniając indeks  $l$  na  $k$  oraz zmieniając między sobą nazwy indeksów  $i$  oraz  $j$  otrzymujemy (macierz  $Q=V^{-1}$  jest symetryczna):

$$\frac{\partial \mathcal{R}}{\partial \theta_p} = -2 \underbrace{\sum_{i,j=1}^n \varphi_p(x_i) Q_{ij} y_j}_{(\Phi^T Q y)_p} + 2 \underbrace{\sum_{i,j=1}^n \sum_{k=1}^m \varphi_p(x_i) Q_{ij} \varphi_k(x_j) \theta_k}_{(\Phi^T Q \Phi \vec{\theta})_p} = 0 \quad p = 1, 2, \dots, m$$

Otrzymaliśmy układ liniowych równań (zwanymi normalnymi) na nieznane parametry  $\theta_i$  w postaci macierzowej:

$$\Phi^T Q \Phi \vec{\theta} = \Phi^T Q y$$

o rozwiązaniach liniowo zależnych od mierzonych wielkości:

$$\hat{\vec{\theta}} = (\Phi^T Q \Phi)^{-1} \Phi^T Q \vec{y} = \underbrace{(\Phi^T V^{-1} \Phi)^{-1}}_{\equiv W} \Phi^T V^{-1} \vec{y} = \underbrace{W \Phi^T V^{-1}}_{\equiv \Psi} \vec{y} = \Psi \vec{y}$$

Jeśli wielkości mierzone są nieobciążone, to również nieobciążone są estymatory parametrów:

$$\mathcal{E}[\hat{\vec{\theta}}] = \mathcal{E}[\Psi \vec{y}] = \Psi \mathcal{E}[\vec{y}] = \Psi \vec{\eta} = (\Phi^T V^{-1} \Phi)^{-1} \Phi^T V^{-1} \Phi \vec{\theta} = \vec{\theta}$$

# MNK - przypadek liniowy

Macierz kowariancji estymatorów parametrów ma postać:

$$\begin{aligned} \mathbf{V}[\hat{\boldsymbol{\theta}}] &= \mathcal{E}[(\boldsymbol{\Psi}(\bar{\mathbf{y}} - \bar{\boldsymbol{\eta}}))(\boldsymbol{\Psi}(\bar{\mathbf{y}} - \bar{\boldsymbol{\eta}}))^T] = \mathcal{E}[\boldsymbol{\Psi}(\bar{\mathbf{y}} - \bar{\boldsymbol{\eta}})(\bar{\mathbf{y}} - \bar{\boldsymbol{\eta}})^T \boldsymbol{\Psi}^T] = \boldsymbol{\Psi} \mathcal{E}[(\bar{\mathbf{y}} - \bar{\boldsymbol{\eta}})(\bar{\mathbf{y}} - \bar{\boldsymbol{\eta}})^T] \boldsymbol{\Psi}^T = \\ &= \mathbf{W} \boldsymbol{\Phi}^T \mathbf{V}^{-1} \mathcal{E}[(\bar{\mathbf{y}} - \bar{\boldsymbol{\eta}})(\bar{\mathbf{y}} - \bar{\boldsymbol{\eta}})^T] \mathbf{V}^{-1} \boldsymbol{\Phi} \mathbf{W} = \mathbf{W} \boldsymbol{\Phi}^T \mathbf{V}^{-1} \mathbf{V} \mathbf{V}^{-1} \boldsymbol{\Phi} \mathbf{W} = \mathbf{W} \underbrace{\boldsymbol{\Phi}^T \mathbf{V}^{-1} \boldsymbol{\Phi}}_{\mathbf{W}^{-1}} \mathbf{W} = \mathbf{W} \end{aligned}$$

a więc:  $\mathbf{V}[\hat{\boldsymbol{\theta}}] = \mathbf{W} = (\boldsymbol{\Phi}^T \mathbf{V}^{-1} \boldsymbol{\Phi})^{-1}$

Dysponując estymatami parametrów możemy wykorzystać je do interpolacji bądź ekstrapolacji, konstruując krzywą najlepszego dopasowania:

$$\hat{\eta}(x) = \varphi_1(x)\hat{\theta}_1 + \varphi_2(x)\hat{\theta}_2 + \dots + \varphi_m(x)\hat{\theta}_m = \vec{\varphi}^T(x)\hat{\boldsymbol{\theta}}$$

Błąd takiej operacji wynosi:

$$\begin{aligned} \mathcal{V}[\hat{\eta}(x)] &= \mathcal{E}[(\hat{\eta}(x) - \eta(x))^2] = \mathcal{E}\left[\left(\vec{\varphi}^T(x)(\hat{\boldsymbol{\theta}} - \bar{\boldsymbol{\theta}})\right)\left(\vec{\varphi}^T(x)(\hat{\boldsymbol{\theta}} - \bar{\boldsymbol{\theta}})\right)^T\right] = \\ &= \mathcal{E}\left[\vec{\varphi}^T(x)(\hat{\boldsymbol{\theta}} - \bar{\boldsymbol{\theta}})(\hat{\boldsymbol{\theta}} - \bar{\boldsymbol{\theta}})^T \vec{\varphi}(x)\right] = \vec{\varphi}^T(x) \mathbf{W} \vec{\varphi}(x) \end{aligned}$$

**Twierdzenie Gaussa-Markowa:** Pośród wszystkich nieobciążonych estymatorów, które są liniowymi kombinacjami wielkości mierzonych, estymatory metody najmniejszych kwadratów mają najmniejszą wariancję.



# Ocena jakości dopasowania

Ocena jakości dopasowania na podstawie resztkowej różnicy w minimum:

$$\vec{\varepsilon}_{\min} = \vec{y} - \hat{\eta}$$

Wartość oczekiwana i macierz kowariancji są odpowiednio równe:

$$\mathcal{E}[\vec{\varepsilon}_{\min}] = \mathcal{E}[\vec{y} - \hat{\eta}] = \mathcal{E}[\vec{y}] - \mathcal{E}[\hat{\eta}] = \vec{\eta} - \mathcal{E}[\Psi\hat{\theta}] = \vec{\eta} - \Psi\vec{\theta} = \vec{\eta} - \vec{\eta} = \mathbf{0}$$

$$\mathbf{V}[\vec{\varepsilon}_{\min}] = \mathcal{E}\left[(\vec{y} - \hat{\eta})(\vec{y} - \hat{\eta})^T\right] = \dots = \mathbf{V}[\vec{y}] - \mathbf{V}[\hat{\eta}]$$

Ocena błędów systematycznych – wpływ:

$$z_i = \frac{y_i - \hat{\eta}_i}{\sqrt{\mathcal{V}[y_i] - \mathcal{V}[\hat{\eta}_i]}}$$

Ocena jakości dopasowania na podstawie wartości  $\mathcal{R}_{\min}$ :

- porównanie modeli – im mniejsze  $\mathcal{R}_{\min}$  tym lepsza zgodność (uwaga: dopasowując wielomian  $n-1$  stopnia do  $n$  punktów dostaniemy  $\mathcal{R}_{\min}=0$ )
- gdy mierzone wielkości pochodzą z rozkładu normalnego, wówczas estymatory parametrów mają rozkłady normalne, natomiast wielkość  $\mathcal{R}_{\min}$  jest statystyką  $\chi^2$  wylosowaną z rozkładu o  $(n-m)$  stopniach swobody  $\mathcal{R}_{\min} = \chi^2_{n-m}$  o ile postulowana zależność  $\eta(x; \theta_1, \dots, \theta_m)$  jest słuszna.

(Prawda jeśli macierz  $\mathbf{V}(y)$  jest macierzą kowariancji, a nie jej estymat.)

# MNK - dopasowanie linii prostej

Rozważmy dopasowanie linii prostej do danych doświadczalnych:

$$\vec{\eta} = \Phi \vec{\theta} \quad \Leftrightarrow \quad \begin{bmatrix} \eta_1 \\ \eta_2 \\ \vdots \\ \eta_n \end{bmatrix} = \begin{bmatrix} 1 & x_1 \\ 1 & x_2 \\ \vdots & \vdots \\ 1 & x_n \end{bmatrix} \begin{bmatrix} \theta_1 \\ \theta_2 \end{bmatrix}$$

Zakładamy, że pomiary nie są skorelowane:

$$\mathbf{V} = \begin{bmatrix} s_1^2 & 0 & \dots & 0 \\ 0 & s_2^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & s_n^2 \end{bmatrix} \quad \Rightarrow \quad \mathbf{V}^{-1} = \begin{bmatrix} \frac{1}{s_1^2} & 0 & \dots & 0 \\ 0 & \frac{1}{s_2^2} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \frac{1}{s_n^2} \end{bmatrix}$$

Wprowadzamy oznaczenia:

$$\begin{aligned} S &= \sum_{i=1}^n \frac{1}{s_i^2} & S_x &= \sum_{i=1}^n \frac{x_i}{s_i^2} & S_{xx} &= \sum_{i=1}^n \frac{x_i^2}{s_i^2} & S_{xy} &= \sum_{i=1}^n \frac{x_i y_i}{s_i^2} \\ S_y &= \sum_{i=1}^n \frac{y_i}{s_i^2} & S_{yy} &= \sum_{i=1}^n \frac{y_i^2}{s_i^2} & \Delta &= \frac{1}{SS_{xx} - S_x^2} \end{aligned}$$

# MNK - dopasowanie linii prostej

Konstruujemy macierze  $W$  i  $\Psi$ :

$$\Phi^T V^{-1} \Phi = \begin{bmatrix} \mathbf{1} & \dots & \mathbf{1} \\ x_1 & \dots & x_n \end{bmatrix} \begin{bmatrix} \frac{1}{s_1^2} & \dots & \mathbf{0} \\ \vdots & \ddots & \vdots \\ \mathbf{0} & \dots & \frac{1}{s_n^2} \end{bmatrix} \begin{bmatrix} \mathbf{1} & x_1 \\ \vdots & \vdots \\ \mathbf{1} & x_n \end{bmatrix} = \begin{bmatrix} \frac{1}{s_1^2} & \dots & \frac{1}{s_n^2} \\ \frac{x_1}{s_1^2} & \dots & \frac{x_n}{s_n^2} \end{bmatrix} \begin{bmatrix} \mathbf{1} & x_1 \\ \vdots & \vdots \\ \mathbf{1} & x_n \end{bmatrix} = \begin{bmatrix} S & S_x \\ S_x & S_{xx} \end{bmatrix}$$

$$W = (\Phi^T V^{-1} \Phi)^{-1} = \Delta \begin{bmatrix} S_{xx} & -S_x \\ -S_x & S \end{bmatrix}$$

$$\Psi = W \Phi^T V^{-1} = \Delta \begin{bmatrix} S_{xx} & -S_x \\ -S_x & S \end{bmatrix} \begin{bmatrix} \frac{1}{s_1^2} & \dots & \frac{1}{s_n^2} \\ \frac{x_1}{s_1^2} & \dots & \frac{x_n}{s_n^2} \end{bmatrix} = \Delta \begin{bmatrix} \frac{S_{xx} - x_1 S_x}{s_1^2} & \dots & \frac{S_{xx} - x_n S_x}{s_n^2} \\ \frac{x_1 S - S_x}{s_1^2} & \dots & \frac{x_n S - S_x}{s_n^2} \end{bmatrix}$$

# MNK - dopasowanie linii prostej

Wyznaczamy estymatory parametrów linii prostej

$$\hat{\theta} = \Psi \bar{y} \Rightarrow \begin{bmatrix} \hat{\theta}_1 \\ \hat{\theta}_2 \end{bmatrix} = \Delta \begin{bmatrix} \frac{S_{xx} - x_1 S_x}{s_1^2} & \dots & \frac{S_{xx} - x_n S_x}{s_n^2} \\ \frac{S x_1 - S_x}{s_1^2} & \dots & \frac{S x_n - S_x}{s_n^2} \end{bmatrix} \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} = \Delta \begin{bmatrix} S_{xx} S_y - S_{xy} S_x \\ S S_{xy} - S_x S_y \end{bmatrix}$$

Z macierzy  $W = V[\hat{\theta}]$  odczytujemy:

$$\begin{aligned} \mathcal{V}[\hat{\theta}_1] &= S_{xx} \Delta & \text{cov}[\hat{\theta}_1, \hat{\theta}_2] &= -S_x \Delta & \rho(\hat{\theta}_1, \hat{\theta}_2) &= -\frac{S_x}{\sqrt{S S_{xx}}} \\ \mathcal{V}[\hat{\theta}_2] &= S \Delta \end{aligned}$$

Obliczamy wartość statystyki  $\mathcal{R}$  w minimum:

$$\mathcal{R}_{\min} = S_{yy} - S_y \hat{\theta}_1 - S_{xy} \hat{\theta}_2$$

Ponieważ parametry są liniowymi funkcjami wielkości mierzonych, więc poziomice stałej wartości  $\mathcal{R}$  (czyli  $\chi^2$ ) są elipsami:

$$\frac{1}{1 - \rho^2} \left[ \frac{(\theta_1 - \hat{\theta}_1)^2}{\mathcal{D}^2[\hat{\theta}_1]} + \frac{(\theta_2 - \hat{\theta}_2)^2}{\mathcal{D}^2[\hat{\theta}_2]} - 2\rho \left( \frac{\theta_1 - \hat{\theta}_1}{\mathcal{D}[\hat{\theta}_1]} \right) \left( \frac{\theta_2 - \hat{\theta}_2}{\mathcal{D}[\hat{\theta}_2]} \right) \right] = \mathcal{R} - \mathcal{R}_{\min}$$

# Dopasowanie linii prostej - dygresja

Dopasowanie linii prostej z pominięciem rachunku macierzowego:

$$\eta(x) = f(x; \vec{\theta}) = \theta_1 + \theta_2 x$$

Znajdujemy wartości parametrów dla których  $\mathcal{R}$  osiąga minimum:

$$\begin{cases} \frac{\partial \mathcal{R}}{\partial \theta_1} = -2 \sum_{i=1}^n \left( \frac{y_i - \theta_1 - \theta_2 x_i}{s_i^2} \right) = -2 \left( \sum_{i=1}^n \frac{y_i}{s_i^2} - \theta_1 \sum_{i=1}^n \frac{1}{s_i^2} - \theta_2 \sum_{i=1}^n \frac{x_i}{s_i^2} \right) \\ \frac{\partial \mathcal{R}}{\partial \theta_2} = -2 \sum_{i=1}^n x_i \left( \frac{y_i - \theta_1 - \theta_2 x_i}{s_i^2} \right) = -2 \left( \sum_{i=1}^n \frac{x_i y_i}{s_i^2} - \theta_1 \sum_{i=1}^n \frac{x_i}{s_i^2} - \theta_2 \sum_{i=1}^n \frac{x_i^2}{s_i^2} \right) \end{cases}$$

wprowadzając oznaczenia:  $S = \sum_{i=1}^n \frac{1}{s_i^2}$   $S_x = \sum_{i=1}^n \frac{x_i}{s_i^2}$   $S_{xx} = \sum_{i=1}^n \frac{x_i^2}{s_i^2}$   $S_{xy} = \sum_{i=1}^n \frac{x_i y_i}{s_i^2}$

dostajemy:  $S_y = \sum_{i=1}^n \frac{y_i}{s_i^2}$   $S_{yy} = \sum_{i=1}^n \frac{y_i^2}{s_i^2}$   $\Delta = \frac{1}{SS_{xx} - S_x^2}$

$$\begin{cases} S_y - \hat{\theta}_1 S - \hat{\theta}_2 S_x = 0 \\ S_{xy} - \hat{\theta}_1 S_x - \hat{\theta}_2 S_{xx} = 0 \end{cases} \Rightarrow \begin{cases} \hat{\theta}_1 = (S_{xx} S_y - S_x S_{xy}) \Delta \\ \hat{\theta}_2 = (SS_{xy} - S_x S_y) \Delta \end{cases}$$

# MNK - dopasowanie linii prostej

Linia prosta najlepszego dopasowania pozwala dokonać interpolacji lub ekstrapolacji:

$$\hat{\eta}(x) = \hat{\theta}_1 + \hat{\theta}_2 x$$

Błąd tej operacji dany jest przez:

$$\begin{aligned} \mathcal{V}[\hat{\eta}] &= \varphi^T(x) W \varphi(x) = \Delta \begin{bmatrix} 1 & x \end{bmatrix} \begin{bmatrix} S_{xx} & -S_x \\ -S_x & S \end{bmatrix} \begin{bmatrix} 1 \\ x \end{bmatrix} = \Delta \begin{bmatrix} S_{xx} - x S_x & -S_x + x S \end{bmatrix} \begin{bmatrix} 1 \\ x \end{bmatrix} = \\ &= \Delta (S_{xx} - x S_x - x S_x + x^2 S) = \Delta S \left( \frac{SS_{xx} - S_x^2}{S^2} + \left( x - \frac{S_x}{S} \right)^2 \right) = \frac{1}{S} + \mathcal{V}[\hat{\theta}_2] \left( x - \frac{S_x}{S} \right)^2 \end{aligned}$$

Problem dopasowania do danych wielu nieliniowych funkcji można sprowadzić do problemu dopasowania linii prostej:

$$y = ab^x \quad \Rightarrow \quad y' = \ln a + x \ln b = a' + b'x$$

$$y = ax^b \quad \Rightarrow \quad y' = \ln a + b \ln x = a' + bx'$$


$$y = a e^{bx} \quad \Rightarrow \quad y' = \ln a + bx = a' + bx$$

$$y = \frac{x}{a + bx} \quad \Rightarrow \quad y' = b \frac{1}{x} + a = a + bx'$$

# Dopasowanie linii prostej

**Przykład:** Wykonano badania wpływu kofeiny na sprawność wykonywania prostych czynności manualnych. Trzydziestu studentów podzielono losowo na trzy grupy po dziesięć osób i każdej grupie podano różne ilości kofeiny: 0 mg, 100 mg i 200 mg. Po dwóch godzinach poproszono ich o wykonanie z maksymalną szybkością czynności polegającej na stukaniu palcami po stole. Wyniki pomiarów przedstawia tabela.

Dawka x [mg]	Liczba stuknięć palcami na minutę y										$\bar{y} \pm \sigma_{\bar{y}}$
0	242	245	244	248	247	248	242	244	246	242	244.8 ± 0.76
100	248	246	245	247	248	250	247	246	243	244	246.4 ± 0.65
200	246	248	250	252	248	250	246	248	245	250	248.3 ± 0.70



Prosta dopasowana MNK:

$$y = (\underbrace{244.7 \pm 0.7}_{\hat{\theta}_1 \pm \hat{\sigma}_{\theta_1}}) + (\underbrace{0.017 \pm 0.005}_{\hat{\theta}_2 \pm \hat{\sigma}_{\theta_2}})x$$

Kowariancja i współczynnik korelacji  
pomiędzy estymatorami parametrów:

$$\text{cov}[\hat{\theta}_1, \hat{\theta}_2] = -0.0028$$

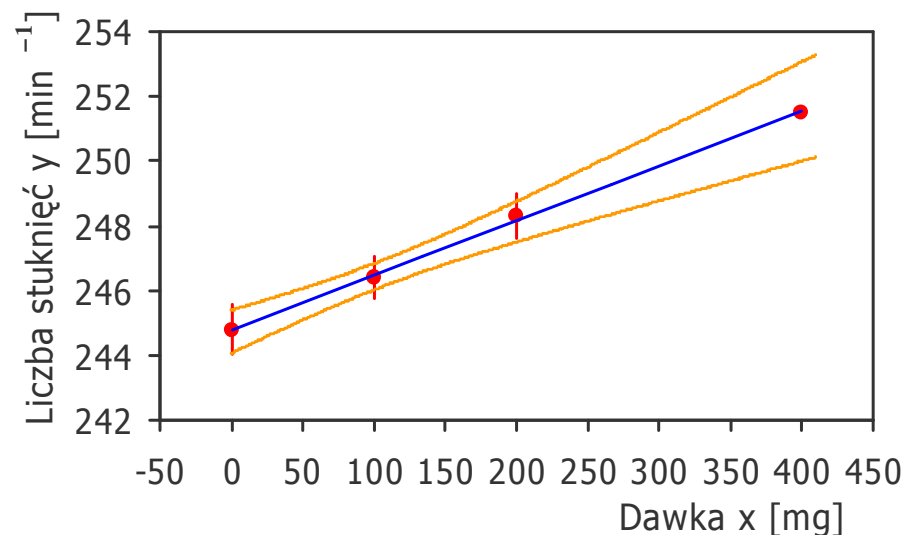
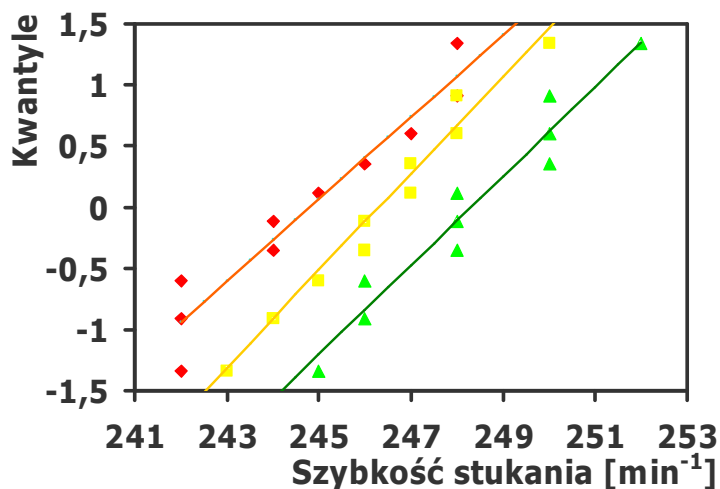
$$\rho(\hat{\theta}_1, \hat{\theta}_2) = -0.8$$

# Dopasowanie linii prostej

$$S = 6.139 \quad S_x = 644.85$$

$$\hat{\eta}(x) = \hat{\theta}_1 + \hat{\theta}_2 x \pm \sqrt{\frac{1}{S} + \mathcal{V}[\hat{\theta}_2] \left( x - \frac{S_x}{S} \right)^2}$$

$$\eta(400) = 251.5 \pm 1.5$$



$$\hat{F}(x) = \begin{cases} 0 & x < x_1 \\ \frac{i}{n+1} & x_i \leq x < x_{i+1} \\ \frac{n}{n+1} & x \geq x_n \end{cases}$$

$$x < x_1$$

$$x_i \leq x < x_{i+1}$$

$$x \geq x_n$$

$$F(q_i) = \frac{i}{n+1} = \frac{i}{11}$$

$$q = \frac{x - \mu}{\sigma}$$

F(q <sub>i</sub> )	0.091	0.182	0.273	0.364	0.455	0.546	0.636	0.727	0.818	0.909
q <sub>i</sub>	-1.335	-0.908	-0.605	-0.349	-0.114	0.114	0.349	0.605	0.908	1.335



# Dopasowanie linii prostej

Jeśli hipoteza o zależności liniowej jest prawdziwa, to statystyka  $\mathcal{R}$  ma rozkład  $\chi^2$  o  $n-m = 3 - 2 = 1$  stopniach swobody.


$$\mathcal{R}_{\min} = S_{yy} - S_y \hat{\theta}_1 - S_{xy} \hat{\theta}_2 = 0.033 \quad \Rightarrow \quad P(\chi^2 > \mathcal{R}_{\min}) = \int_{\mathcal{R}_{\min}}^{\infty} \chi_1(u) du = 0.857$$

Jeśli zażądamy  $P(\chi^2 > \mathcal{R}_{\min}) = \int_{\mathcal{R}_{\min}}^{\infty} \chi_1(u) du = 0.99 \quad \Rightarrow \quad \mathcal{R}_{\min} = 0.00015$

Oznacza to, że średnie odchylenie każdego punktu od dopasowanej linii wynosi w jednostkach typowej niepewności wynosi tylko

$$\sqrt{0.00015/3} \cong 0.007$$

Ponieważ parametry są liniowymi funkcjami wielkości mierzonych, więc poziomicie stałej wartości  $\mathcal{R}$  (czyli  $\chi^2$ ) są elipsami:



$$\frac{1}{1-\rho^2} \left[ \frac{(\theta_1 - \hat{\theta}_1)^2}{\mathcal{D}^2[\hat{\theta}_1]} + \frac{(\theta_2 - \hat{\theta}_2)^2}{\mathcal{D}^2[\hat{\theta}_2]} - 2\rho \left( \frac{\theta_1 - \hat{\theta}_1}{\mathcal{D}[\hat{\theta}_1]} \right) \left( \frac{\theta_2 - \hat{\theta}_2}{\mathcal{D}[\hat{\theta}_2]} \right) \right] = \mathcal{R} - \mathcal{R}_{\min}$$

# Dopasowanie krzywej eksponencjalnej

**Przykład:** W tabeli podane są dane o liczbie  $n_k$  liści rzęsy wodnej jako funkcji czasu  $k$  liczonego w tygodniach.


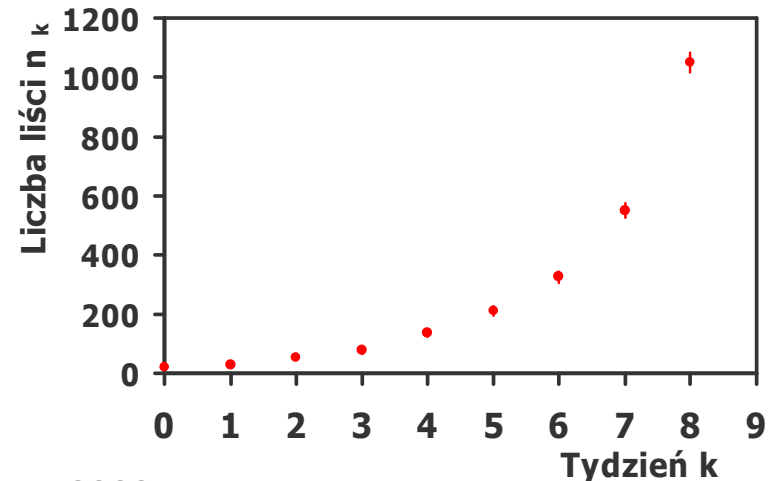
k	0	1	2	3	4	5	6	7	8
$n_k$	20	30	52	77	135	211	326	550	1052

$$y = a e^{bx} \quad \Rightarrow \quad \underbrace{\ln y = \ln a + bx}_{z = a' + bx}$$

**Uwagi:**

- oznaczenia:  $x \equiv k$   $y \equiv n_k$
- zanedbujemy ewidentne korelacje,
- zakładamy, że niepewności zliczeń podlegają rozkładowi Poissona:

$$z = \ln y \quad \Rightarrow \quad \sigma_z^2 = \left( \frac{\partial z}{\partial y} \right)^2 \sigma_y^2 = \frac{\sigma_y^2}{y^2} = \frac{1}{y}$$



# Dopasowanie krzywej eksponencjalnej

$$z = \underbrace{(2.81 \pm 0.08)}_{a' \pm \sigma_{a'}} + \underbrace{(0.51 \pm 0.01)x}_{b \pm \sigma_b}$$

$$\text{cov}[a', b] = -0.0009 \quad \rho = -0.97$$

$$\mathcal{R}_{\min} = 11.83 \quad \Rightarrow \quad P(\chi^2 > \mathcal{R}_{\min}) = 0.106$$

$$a' = \ln a \quad \Rightarrow \quad a = e^{a'} \quad \Rightarrow \quad \sigma_a = e^{a'} \sigma_{a'}$$

$$y = (16.5 \pm 1.3) \exp[(0.51 \pm 0.01)x]$$

