



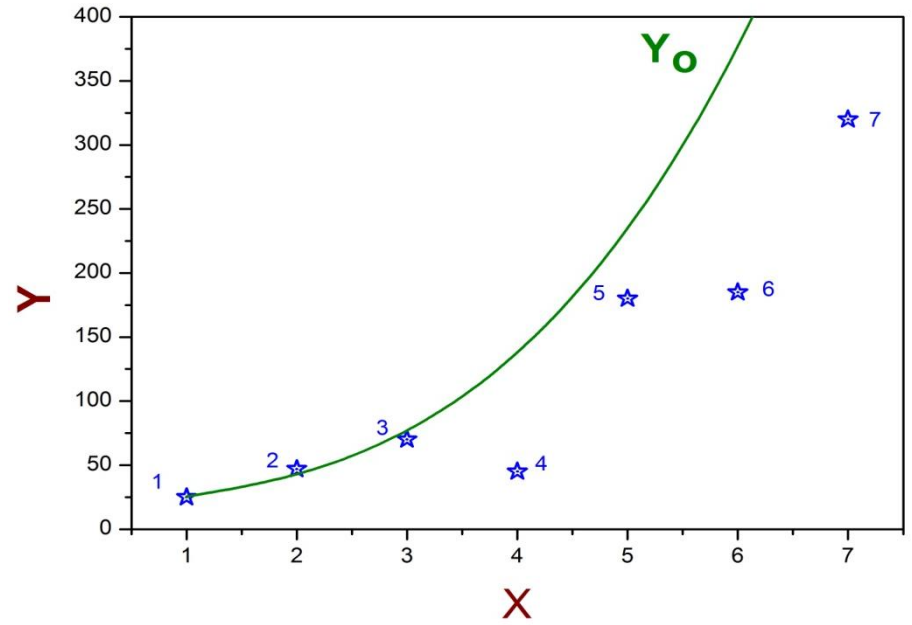

# **WYKŁAD 8**

## **ANALIZA REGRESJI**


### **Regresja**

- 1. Metoda najmniejszych kwadratów-regresja prostoliniowa**
- 2. Regresja krzywoliniowa**
- 3. Estymacja liniowej funkcji regresji**
- 4. Testy istotności współczynnika regresji liniowej**
- 5. Zamiana przypadków nieliniowych na liniowe**


# METODA NAJMNIJSZYCH KWADRATÓW




# METODA NAJMNIEJSZYCH KWADRATÓW



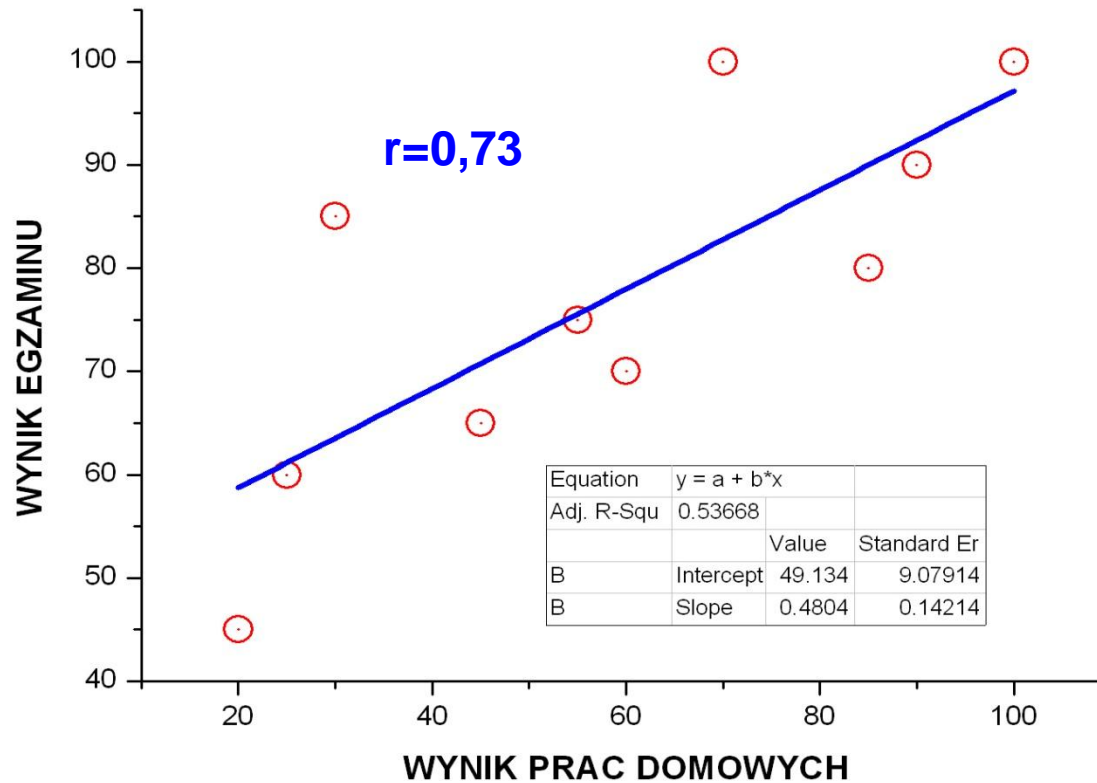
# METODA NAJMNIEJSZYCH KWADRATÓW



# METODA NAJMNIJSZYCH KWADRATÓW



# WSPÓŁCZYNNIK KORELACJI LINIOWEJ



# METODA NAJMNIEJSZYCH KWADRATÓW

$$y=A+Bx \quad (1)$$

Zakładamy, że: a) niepewność w określaniu  $x$  jest zaniedbywalna ; b) każdy wynik pomiaru  $y_i$  podlega rozkładowi normalnemu; c) niepewności wszystkich wartości  $y$  mają tę samą wartość:  $\sigma_y$ .

Prawdziwa wartość  $y_i=A+Bx_i$  (2)

Wynik pomiaru  $y_i$  podlega rozkładowi normalnemu wyśrodkowanemu wokół swojej prawdziwej wartości z odchyleniem  $\sigma_y$ , więc prawdopodobieństwo zmierzonej wartości  $y_i$  wynosi:

$$P_{A,B}(y_i) \propto \frac{1}{\sigma_y} \exp \left[ -\frac{(y_i - A - Bx_i)^2}{2\sigma_y^2} \right] \quad (3)$$

Prawdopodobieństwo otrzymania kompletnego zbioru wyników  $y_1, \dots, y_N$  jest iloczynem:

$$P_{A,B}(y_1, \dots, y_N) = P_{A,B}(y_1) \cdots P_{A,B}(y_N) \propto \frac{1}{\sigma_y^N} \exp \left[ -\frac{\chi^2}{2} \right] \quad (4)$$

gdzie:

$$\chi^2 = \sum_{i=1}^N \frac{(y_i - A - Bx_i)^2}{\sigma_y^2} \quad (5)$$

# METODA NAJMNIEJSZYCH KWADRATÓW

Najlepsze przybliżenie nieznanymi stałymi A, B uzyskamy, gdy prawdopodobieństwo  $P_{A,B}(y_1, \dots, y_N)$  jest największe, co odpowiada:

$$\chi^2 = \min:$$

$$\frac{\partial \chi^2}{\partial A} = -\frac{2}{\sigma_y^2} \sum_{i=1}^N (y_i - A - Bx_i) = 0 \quad (6)$$

$$\frac{\partial \chi^2}{\partial B} = -\frac{2}{\sigma_y^2} \sum_{i=1}^N x_i (y_i - A - Bx_i) = 0 \quad (7)$$

stąd otrzymujemy tzw. *równania normalne* o niewiadomych A i B:

$$AN + B \sum x_i = \sum y_i \quad (8)$$

$$A \sum x_i + B \sum x_i^2 = \sum x_i y_i \quad (9)$$

rozwiązanie tego układu równań daje:



# METODA NAJMNIEJSZYCH KWADRATÓW

$$A = \frac{(\sum x_i^2)(\sum y_i) - (\sum x_i)(\sum x_i y_i)}{\Delta} \quad (10)$$

$$B = \frac{N(\sum x_i y_i) - (\sum x_i)(\sum y_i)}{\Delta} \quad (11)$$

gdzie:

$$\Delta = N(\sum x_i^2) - (\sum x_i)^2 \quad (12)$$

lub, w równoważnej formie:

$$B = \frac{\sum_{i=1}^N x_i y_i - N\bar{x}\bar{y}}{\sum_{i=1}^N x_i^2 - N\bar{x}^2} \quad (11')$$

$$A = \bar{y} - B\bar{x} \quad (10')$$

# METODA NAJMNIEJSZYCH KWADRATÓW

$$P_{A,B}(y_1, \dots, y_N) = P_{A,B}(y_1) \cdots P_{A,B}(y_N) \propto \frac{1}{\sigma_y^N} \exp \left[ -\frac{\chi^2}{2} \right] \quad (4)$$

Różniczkując równanie (4) względem  $\sigma_y$ , a następnie przyrównując uzyskaną pochodną do zera, ponadto uwzględniając fakt, że liczba stopni swobody wynosi w tym przypadku  $N-2$  ( $N$ - niezależnych pomiarów minus dwa wyznaczone parametry:  $A$  i  $B$ ), uzyskujemy następujące wyrażenie na niepewność pomiarów  $y$ :

$$\sigma_y^2 = \frac{1}{N-2} \sum_{i=1}^N (y_i - A - Bx_i)^2 \quad (13)$$

# METODA NAJMNIEJSZYCH KWADRATÓW

## DEFINICJA

W obliczeniach statystycznych **LICZBA STOPNI SWOBODY** wynosi:  
liczba **niezależnych pomiarów (N)** minus liczba parametrów  
**obliczonych z tych pomiarów**  
z prawa przenoszenia błędów otrzymujemy:

$$\sigma_A^2 = \sigma_y^2 \sum \frac{x_i^2}{\Delta} \quad (14)$$

$$\sigma_B^2 = N \frac{\sigma_y^2}{\Delta} \quad (15)$$

gdzie  $\Delta$  dane jest równaniem (12)  $\Delta = N(\sum x_i^2) - (\sum x_i)^2$  (12)

# METODA NAJMNIEJSZYCH KWADRATÓW DLA INNYCH ZALEŻNOŚCI FUNKCYJNYCH

Analogicznie można postępować w dopasowaniu innych krzywych przedstawioną metodą najmniejszych kwadratów np. w przypadku wielomianu:

$$y = A + Bx + Cx^2 + \dots + Zx^n \quad (16)$$

uzyskujemy następującą sumę kwadratów:

$$\chi^2 = \sum_{i=1}^N \frac{(y_i - A - Bx_i - Cx_i^2 - \dots - Zx_i^n)^2}{\sigma_y^2} \quad (17)$$

Następnie obliczamy pochodne cząstkowe względem A, B, C, ..., Z przyrównujemy je do zera, otrzymując układ równań normalnych na parametry A, B, C, ..., Z

Podobnie postępujemy w przypadku funkcji wielu zmiennych np.  $z = A + Bx + Cy$  (regresja wielokrotna)

# METODA NAJMNIEJSZYCH KWADRATÓW (ogólna zasada) (1)

Dana jest funkcja:

$$y = f(x; a_0, a_1, \dots, a_m) \quad (1)$$

zmienną niezależną  $x$  oraz  $m+1$  parametrów  $a_0, a_1, \dots, a_m$ . Parametry te są stałe, które należy wyznaczyć. W tym celu przeprowadza się  $n$  pomiarów  $x$  i  $y$  otrzymując  $n$  par  $(x_i, y_i)$   $i=1, 2, \dots, n$ . Wstawiając wartości  $(x_i, y_i)$  do (1) otrzymujemy:

$$y_i = f(x_i; a_0, a_1, \dots, a_m) \quad i = 1, 2, \dots, n \quad (2)$$

Jeśliby wartości  $x$  i  $y$  można było wyznaczyć bardzo dokładnie, to do znalezienia  $m+1$  parametrów wystarczyłoby przeprowadzić  $m+1$  pomiarów. W rzeczywistości wartości  $x$  i  $y$  są obarczone błędami, co nie pozwala na dokładne wyznaczenie prawdziwych wartości tych parametrów. Z reguły przeprowadza się większą liczbę pomiarów czyli  $n > m+1$ . W tym przypadku układ równań (2) jest sprzeczny.

# METODA NAJMNIJSZYCH KWADRATÓW

## (ogólna zasada) (2)

Zadaniem naszym jest dobór takich parametrów  $a_0, a_1, \dots, a_m$  aby równania (2) były spełnione w możliwie najlepszym sposobie (czyli chcemy określić najbardziej prawdopodobne wartości tych parametrów). Ponieważ równania (2) nie są ściśle spełnione, więc:

$$y_i - f(x_i; a_0, a_1, \dots, a_m) = \varepsilon_i \quad i = 1, 2, \dots, n \quad (3)$$

gdzie  $\varepsilon_i$  są odchyleniami mierzonych wartości od obliczonych ze wzoru (1).

Zasada najmniejszych kwadratów:

Najbardziej prawdopodobne parametry są takie, dla których suma kwadratów odchyleń  $\varepsilon_i$  jest najmniejsza:

$$\sum_{i=1}^n [y_i - f(x_i; a_0, a_1, \dots, a_n)]^2 = \Delta = \min \quad (4)$$

# METODA NAJMNIJSZYCH KWADRATÓW

(ogólna zasada) (3)

## Przypadek liniowy:

$$f(\mathbf{x}; \mathbf{a}_0, \mathbf{a}_1, \dots, \mathbf{a}_m) = \phi_0(\mathbf{x}) * \mathbf{a}_0 + \phi_1(\mathbf{x}) * \mathbf{a}_1 + \dots + \phi_m(\mathbf{x}) * \mathbf{a}_m \quad (5)$$

Korzystając z warunku koniecznego na minimum  $\Delta \left( \frac{\partial \Delta}{\partial a_j} = 0 \text{ dla } j = 0, 1, \dots, m \right)$   
po wstawieniu (5) do (4) mamy:

$$2 \sum_{i=1}^n [y_i - \varphi_0(x_i)a_0 - \varphi_1(x_i)a_1 - \dots - \varphi_m(x_i)a_m](-\varphi_0(x_i)) = 0$$

$$2 \sum_{i=1}^n [y_i - \varphi_0(x_i)a_0 - \varphi_1(x_i)a_1 - \dots - \varphi_m(x_i)a_m](-\varphi_1(x_i)) = 0 \quad (6)$$

.....

$$2 \sum_{i=1}^n [y_i - \varphi_0(x_i)a_0 - \varphi_1(x_i)a_1 - \dots - \varphi_m(x_i)a_m](-\varphi_m(x_i)) = 0$$





# ZMIANA NIEKTÓRYCH PRZYPADKÓW NIELINIOWYCH FUNKCJI REGRESJI NA LINIOWE

## Przypadek ogólny:

$$y = f(x, a_1, a_2, \dots, a_n)$$

zmienne:  $x, y$  ; parametry:  $a_1, a_2, \dots, a_n$

## linearyzacja:


$$y \approx f(x, a_1^o, a_2^o, \dots, a_n^o) + \left(\frac{\partial f}{\partial a_1}\right)_o * \Delta a_1 + \left(\frac{\partial f}{\partial a_2}\right)_o * \Delta a_2 + \dots + \left(\frac{\partial f}{\partial a_n}\right)_o * \Delta a_n$$

Gdzie:  $a_i^o$  przybliżona wartość parametru  $a_i$

„Dokładna” wartość  $a_i = a_i^o + \Delta a_i$


# WYZNACZANIE A i B

- **EXCEL | statystyczne | NACHYLENIE** ,
- *znane\_y (wstawić wartości  $y_i$ )*
- *znane\_x (wstawić wartości  $x_i$ )*



**EXCEL | statystyczne | ODCIĘTA** ,

- *znane\_y (wstawić wartości  $y_i$ )*  
*znane\_x (wstawić wartości  $x_i$ )*



# ESTYMACJA LINIOWEJ FUNKCJI REGRESJI

$$y=A+Bx$$

Parametry A i B wyznacza się z próby, czyli są one **estymatorami** następujących parametrów zależności:

$$y=\alpha+\beta x$$

w populacji generalnej. Stwierdzono, że są one estymatorami nieobciążonymi i zgodnymi. Obszar ufności dla prostej regresji  $y=\alpha+\beta x$ , ograniczony tzw. *krzywymi ufności*, wyznacza się ze wzoru:

$$P\{\check{y}_i - t_\gamma s_{\check{y}_i} < \tilde{y}_i < \check{y}_i + t_\gamma s_{\check{y}_i}\} = 1 - \gamma \quad (21)$$

Gdzie  $\check{y}_i$  oznacza wartość funkcji  $\check{y} = A + Bx$ , wyznaczonej ze wzorów (10), (11)  $\tilde{y}_i$  oznacza wartość szacowanej funkcji regresji  $y = \alpha + \beta x$ ,  $t_\gamma$  jest wartością zmiennej o rozkładzie t-Studenta, wyznaczonej dla określonego  $1-\gamma$  poziomu ufności dla  $k=N-2$  stopni swobody oraz:

$$s_{\check{y}_i} = s_r \sqrt{\frac{1}{N} + \frac{(x_i - \bar{x})^2}{\sum_{i=1}^N (x_i - \bar{x})^2}} \quad (22)$$

Gdzie  $s_r$  jest odchyleniem przeciętnym do prostej regresji, obliczanym ze wzoru:

$$s_r = \sqrt{\frac{1}{N-2} \sum_{i=1}^N (y_i - \check{y}_i)^2} \quad (23)$$

# ESTYMACJA LINIOWEJ FUNKCJI REGRESJI

$$y=A+Bx$$

Obszar ufności dla prostej regresji  $y=\alpha+\beta x$ , ograniczony tzw. krzywymi ufności wyznacza się ze wzoru:

(21)

$$p\{\check{y}_i - t_\gamma s_{\check{y}_i} < \tilde{y}_i < \check{y}_i + t_\gamma s_{\check{y}_i}\} = 1 - \gamma$$

$$s_{\check{y}_i} = s_r \sqrt{\frac{1}{N} + \frac{(x_i - \bar{x})^2}{\sum_{i=1}^N (x_i - \bar{x})^2}} \quad s_r = \sqrt{\frac{1}{N-2} \sum_{i=1}^N (y_i - \check{y}_i)^2}$$

# ESTYMACJA LINIOWEJ FUNKCJI REGRESJI

P.G.  $y = \alpha + \beta * x$  ; Próba (N-elementowa):  $y = A + B * x$

B- NACHYLENIE; A- ODCIĘTA

## 1. KRZYWE UFNOŚCI

$$p\{\check{y}_i - t_\gamma s_{\check{y}_i} < \hat{y}_i < \check{y}_i + t_\gamma s_{\check{y}_i}\} = 1 - \gamma$$

$$s_{\check{y}_i} = s_r \sqrt{\frac{1}{N} + \frac{(x_i - \bar{x})^2}{\sum_{i=1}^N (x_i - \bar{x})^2}} \quad s_r = \sqrt{\frac{1}{N-2} \sum_{i=1}^N (y_i - \check{y}_i)^2} \quad t_\gamma \text{ -ROZKŁAD.T.ODW; } k=n-2$$

$$\hat{y}_i = A + B * x_i$$

## 2. ESTYMACJI WSPÓŁCZYNNIKA (NACHYLENIA) REGRESJI LINIOWEJ

$$p\left\{B - t_\gamma \frac{s_r}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2}} < \beta < B + t_\gamma \frac{s_r}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2}}\right\} = 1 - \gamma$$

$t_\gamma$  - ROZKŁAD.T.ODW (prawdopodobieństwo=  $\gamma$  ; stopnie swobody:  $k=n-2$ )

# TESTY ISTOTNOŚCI DLA WSPÓŁCZYNNIKA REGRESJI LINIOWEJ

1.  $H_0 : B = \beta_0$

$$t = \frac{B - \beta_0}{s_r} \sqrt{\sum_{i=1}^N (x_i - \bar{x})^2}$$

$$s_r = \sqrt{\frac{1}{N-2} \sum_{i=1}^N (y_i - \hat{y}_i)^2}$$

$$\hat{y}_1 = A + B * x_i$$

k= N-2

2.  $H_0 : \beta_1 = \beta_2$  (test równoległości)

$$t = \frac{\beta_1 - \beta_2}{s_{\beta_1 - \beta_2}}$$

$$s_{\beta_1 - \beta_2} = \sqrt{\frac{\sum_{i=1}^{N1} (y_{i1} - \hat{y}_{i1})^2 + \sum_{i=1}^{N2} (y_{i2} - \hat{y}_{i2})^2}{N1 + N2 - 4} \left( \frac{1}{\sum_{i=1}^{N1} (x_{i1} - \bar{x}_1)^2} + \frac{1}{\sum_{i=1}^{N2} (x_{i2} - \bar{x}_2)^2} \right)}$$

k= N1+N2 -4

# ESTYMACJA LINIOWEJ FUNKCJI REGRESJI

**Przykład:** Celem uzyskania spieku materiału o kontrolowanej porowatości, do wyjściowego proszku przed spiekaniem dodawano grafitu. Po wypaleniu uzyskano następujące wyniki (wartości  $x_i$ ,  $y_i$  w Tabeli) :

Przyjmując poziom ufności  $1-\gamma=0,95$  oszacować metodą przedziałową zarówno całą funkcję regresji, jak i sam współczynnik regresji porowatości względem zawartości użytego grafitu.

$X_i$ [% wag. grafitu]	$Y_i$ [porowatość, %]	$\hat{y}_i$	$(x_i - \bar{x})^2$	$\sqrt{\frac{1}{N} + \frac{(x_i - \bar{x})^2}{\sum_{i=1}^N (x_i - \bar{x})^2}}$	$(y_i - \hat{y}_i)^2$				
1	8	9,5	9	0,681	2,25				
2	13	11,7	4	0,535	1,69				
3	14	13,8	1	0,423	0,04				
4	17	16,0	0	0,378	1,00				
5	18	18,1	1	0,423	0,01				
6	20	20,2	4	0,535	0,04				
7	22	22,4	9	0,681	0,16				
$\bar{x} = 4$			28		5,19				

Rozwiązanie:

$$\hat{y} = A + Bx$$

EXCEL | statystyczne | NACHYLENIE, EXCEL | statystyczne | ODCIĘTA,  
znane\_y (wstawić wartości  $y_i$ ), znane\_y (wstawić wartości  $y_i$ )  
znane\_x (wstawić wartości  $x$ ), znane\_x (wstawić wartości  $x$ )

$$\bar{x} = 4$$

•  $B=2,14$

•  $A=7,4$

$$\hat{y}_1 = A + Bx_1 = 7,4 + 2,14 * 1 = 9,5$$

# ESTYMACJA LINIOWEJ FUNKCJI REGRESJI

Przyjmując poziom ufności  $1-\gamma=0,95$  oszacować metodą przedziałową zarówno całą funkcję regresji, jak i sam współczynnik regresji porowatości względem zawartości użytego grafitu.

$X_i$ [% wag. grafitu]	$Y_i$ [porowatość, %]	$\hat{y}_i$	$(x_i - \bar{x})^2$	$\sqrt{\frac{1}{N} + \frac{(x_i - \bar{x})^2}{\sum_{i=1}^N (x_i - \bar{x})^2}}$	$(y_i - \hat{y}_i)^2$	$s_{\hat{y}_i}$	$t_\gamma s_{\hat{y}_i}$	$\hat{y}_i - t_\gamma s_{\hat{y}_i}$	$\hat{y}_i + t_\gamma s_{\hat{y}_i}$
1	8	9,5	9	0,681	2,25	0,695	1,8	7,7	11,3
2	13	11,7	4	0,535	1,69	0,546	1,4	10,3	13,1
3	14	13,8	1	0,423	0,04	0,431	1,1	12,7	14,9
4	17	16,0	0	0,378	1,00	0,386	1,0	15,0	17,0
5	18	18,1	1	0,423	0,01	0,431	1,1	17,0	19,2
6	20	20,2	4	0,535	0,04	0,546	1,4	18,8	21,6
7	22	22,4	9	0,681	0,16	0,695	1,8	20,6	24,2
$\bar{x} = 4$			28		5,19				

$$s_r = \sqrt{\frac{1}{N-2} \sum_{i=1}^N (y_i - \check{y}_i)^2} \quad s_r = \sqrt{\frac{5,19}{5}} = 1,02 \quad s_{\check{y}_i} = s_r \sqrt{\frac{1}{N} + \frac{(x_i - \bar{x})^2}{\sum_{i=1}^N (x_i - \bar{x})^2}}$$

**EXCEL | statystyczne | ROZKŁAD.T.ODW**

$1-\gamma=0,95 \Rightarrow \gamma=0,05$ ,  $k=N-2=5$ ,

- $t_\gamma = 2,571$**



# ESTYMACJA LINIOWEJ FUNKCJI REGRESJI

$$y=A+Bx$$

Obszar ufności dla prostej regresji  $y=\alpha+\beta x$ , ograniczony tzw. krzywymi ufności wyznacza się ze wzoru:

(21)

$$p\{\check{y}_i - t_\gamma s_{\check{y}_i} < \tilde{y}_i < \check{y}_i + t_\gamma s_{\check{y}_i}\} = 1 - \gamma$$


$$s_{\check{y}_i} = s_r \sqrt{\frac{1}{N} + \frac{(x_i - \bar{x})^2}{\sum_{i=1}^N (x_i - \bar{x})^2}} \quad s_r = \sqrt{\frac{1}{N-2} \sum_{i=1}^N (y_i - \check{y}_i)^2}$$

$$p\left\{B - t_\gamma \frac{s_r}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2}} < \beta < B + t_\gamma \frac{s_r}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2}}\right\} = 1 - \gamma$$

$t_\gamma$  - ROZKŁAD.T.ODW

(prawdopodobieństwo=  $\gamma$  ; stopnie swobody:  $k=n-2$ )

# ESTYMACJA LINIOWEJ FUNKCJI REGRESJI



# ESTYMACJA LINIOWEJ FUNKCJI REGRESJI PRZEDZIAŁ UFNOŚCI DLA WSPÓŁCZYNNIKA $\beta$ (NACHYLENIA)

$$y = \alpha + \beta x$$

Dwuwymiarowy rozkład cech X i Y w populacji jest normalny, lub zbliżony do normalnego. Z populacji tej wylosowano n-elementową próbę, która dała wyniki  $(x_i, y_i)$   $i=1, 2, \dots, N$ . Przedział ufności dla współczynnika regresji  $\beta$  funkcji regresji  $y = \alpha + \beta x$  w populacji wynosi:

$$p \left\{ B - t_\gamma \frac{s_r}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2}} < \beta < B + t_\gamma \frac{s_r}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2}} \right\} = 1 - \gamma \quad (24)$$

Gdzie B jest współ. regresji, otrzymanym metodą najmniejszych kwadratów ( równ. 11 lub 11'),  $s_r$  dane jest równ. (23), a  $t_\gamma$  jest wartością zmiennej o rozkładzie t-Studenta, wyznaczonej dla określonego  $1-\gamma$  poziomu ufności dla  $k=N-2$  stopni swobody.

# ESTYMACJA LINIOWEJ FUNKCJI REGRESJI PRZEDZIAŁ UFNOŚCI DLA WSPÓŁCZYNNIKA $\beta$ (NACHYLENIA)

$$p \left\{ B - t_\gamma \frac{s_r}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2}} < \beta < B + t_\gamma \frac{s_r}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2}} \right\} = 1 - \gamma$$

$$t_\gamma = 2,571 \quad B=2,14 \quad s_r = \sqrt{\frac{5,19}{5}} = 1,02 \quad \sqrt{\sum_{i=1}^N (x_i - \bar{x})^2} = \sqrt{28} = 5,29$$

$$2,14 - 2,571 \cdot 1,02 / 5,29 < \beta < 2,14 + 2,571 \cdot 1,02 / 5,29$$

$$1,64 < \beta < 2,64$$

# TESTY ISTOTNOŚCI DLA WSPÓŁCZYNNIKA B (NACHYLENIA) REGRESJI LINIOWEJ

1.  $H_0 : B = \beta_0$

$$t = \frac{B - \beta_0}{s_r} \sqrt{\sum_{i=1}^N (x_i - \bar{x})^2}$$

$$s_r = \sqrt{\frac{1}{N-2} \sum_{i=1}^N (y_i - \hat{y}_i)^2}$$

$$\hat{y}_i = A + B * x_i$$

$$k = N-2$$

2.  $H_0 : \beta_1 = \beta_2$  (test równoległości)

$$t = \frac{\beta_1 - \beta_2}{s_{\beta_1 - \beta_2}}$$

$$s_{\beta_1 - \beta_2} = \sqrt{\frac{\sum_{i=1}^{N1} (y_{i1} - \hat{y}_{i1})^2 + \sum_{i=1}^{N2} (y_{i2} - \hat{y}_{i2})^2}{N1 + N2 - 4} \left( \frac{1}{\sum_{i=1}^{N1} (x_{i1} - \bar{x}_1)^2} + \frac{1}{\sum_{i=1}^{N2} (x_{i2} - \bar{x}_2)^2} \right)}$$

$$k = N1 + N2 - 4$$

# TEST ISTOTNOŚCI DLA WSPÓŁCZYNNIKA REGRESJI LINIOWEJ

**PROBLEM:** Dwuwymiarowy rozkład cech X i Y w populacji jest normalny, lub zbliżony do normalnego. Z populacji tej wylosowano n-elementową próbę, która dała wyniki  $(x_i, y_i)$   $i=1, 2, \dots, N$ . Na podstawie wyników próby sprawdzić hipotezę, że współczynnik  $\beta$  liniowej funkcji regresji:  $y=\alpha+\beta x$  w populacji ma określoną wartość, tj:  $H_0: \beta = \beta_0$  wobec  $H_1: \beta \neq \beta_0$  (w szczególności gdy  $\beta_0 = 0$ , hipoteza głosi, że brak jest zależności między badanymi cechami X i Y).


**Rozwiązanie:** Metodą najmn. kwadratów szacujemy parametry próby (A i B), obliczamy wg (23)  $s_r$  oraz statystykę:

$$t = \frac{B - \beta_0}{s_r} \sqrt{\sum_{i=1}^N (x_i - \bar{x})^2} \quad s_r = \sqrt{\frac{1}{N-2} \sum_{i=1}^N (y_i - \check{y}_i)^2}$$

Statystyka ta ma rozkład t-Studenta z  $k=n-2$  stopniami swobody, odczytujemy dla danego  $\gamma$ ,  $t_\gamma$ , gdy  $|t| \geq t_\gamma$  to  $H_0$  odrzucić

# ĆWICZENIE

$x_i$	$y_i$
[kg]	[J]
1	3.5
2	8.4
3	8.5
4	12.4
5	11.5
6	16.5
7	15.7
8	19.0
9	18.8
10	25.2
$x_{sr}=5.5$	$y_{sr}=13.95$




EXCEL => A (ODCIĘTA) i B (NACHYLENIE) dla  $x_i$ ,  $y_i$  A=2.77 ; B= 2.03

# ĆWICZENIE (2)

$x_i$ [kg]	$y_i$ [J]
1	3.5
2	8.4
3	8.5
4	12.4
5	11.5
6	16.5
7	15.7
8	19.0
9	18.8
10	25.2
$x_{sr}=5.5$	$y_{sr}=13.95$

**A= 2.77**

**B= 2.03**





# ĆWICZENIE (3)

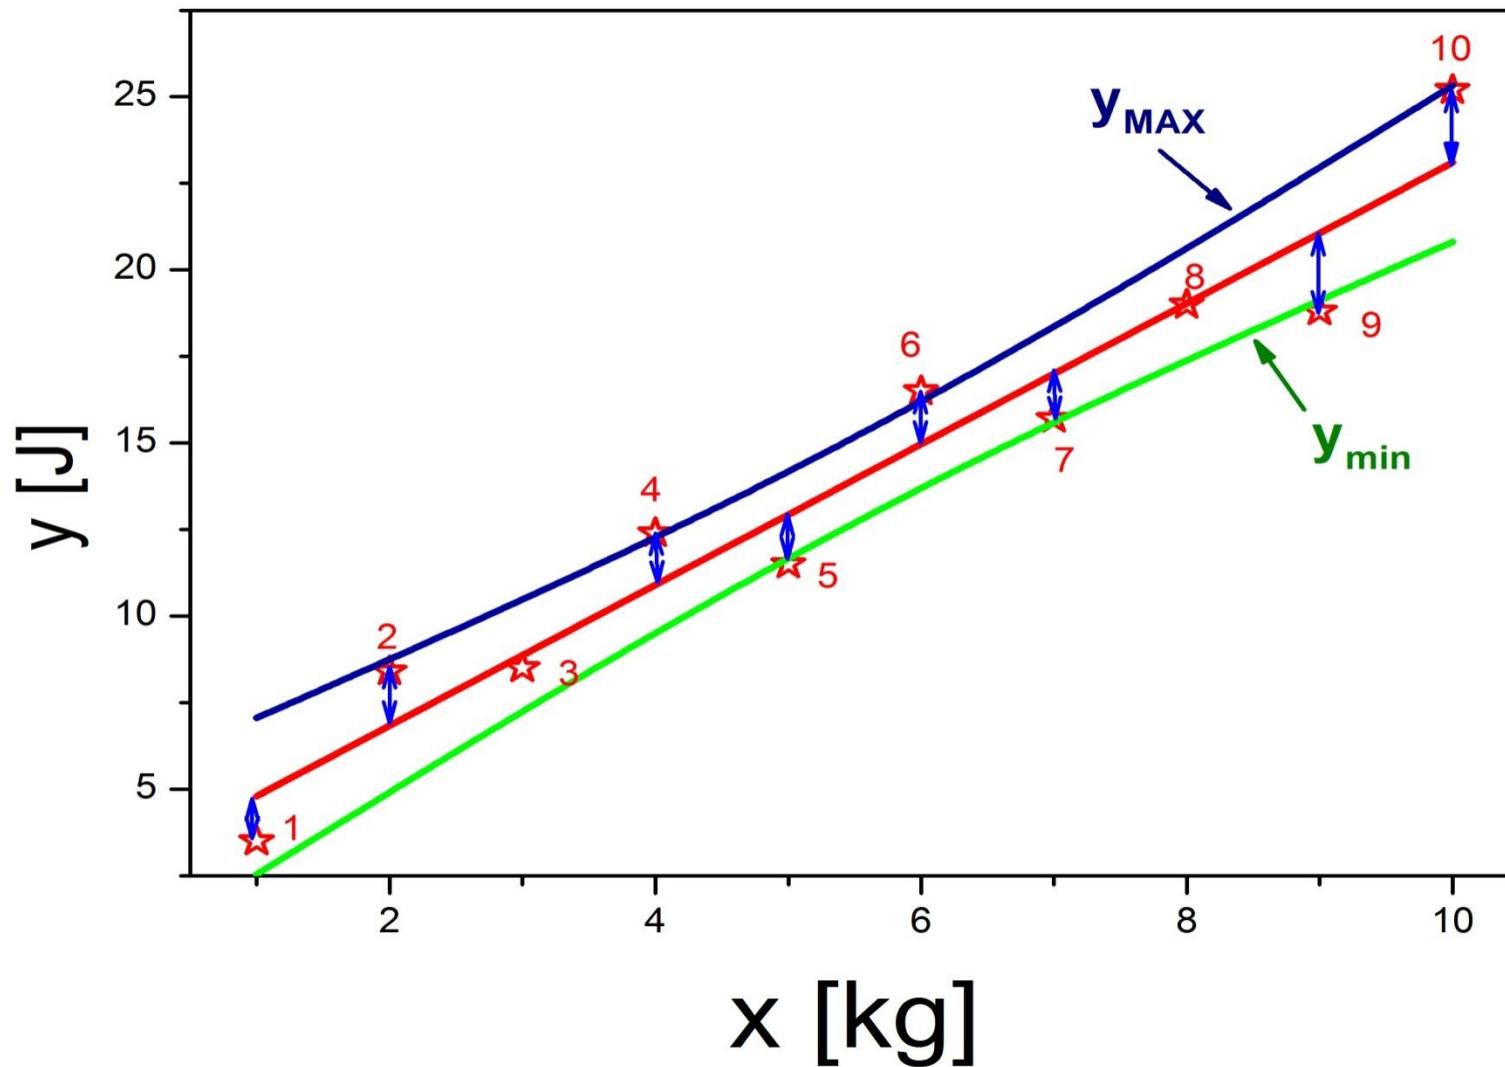
$X_i$ [kg]	$Y_i$ [J]	$\hat{y}_i$	$(x_i - x_{sr})^2$	$(y_i - \hat{y}_i)^2$	$\frac{(x_i - x_{sr})^2}{\sum_{i=1}^n (x_i - x_{sr})^2}$ = $S_i$	$\sqrt{\frac{1}{n} + S_i}$	$s_{\hat{y}_i}$	$s_{\hat{y}_i} * t_\gamma$	$Y_{min}$	$Y_{MAX}$
1	3.5	4.8	20.25	1.690	0.2455	0.588	0.979	2.257	2.543	7.057
2	8.4	6.83	12.25	2.465	0.1485	0.498	0.830	1.914	4.916	8.744
3	8.5	8.86	6.25	0.130	0.0758	0.419	0.698	1.610	7.250	10.470
4	12.4	10.89	2.25	2.280	0.0273	0.357	0.594	1.370	9.520	12.260
5	11.5	12.92	0.25	2.016	0.0030	0.321	0.534	1.232	11.688	14.152
6	16.5	14.95	0.25	2.403	0.0030	0.321	0.534	1.232	13.718	16.182
7	15.7	16.98	2.25	1.638	0.0273	0.357	0.594	1.370	15.610	18.350
8	19.0	19.01	6.25	0.000	0.0758	0.419	0.698	1.610	17.400	20.620
9	18.8	21.04	12.25	5.018	0.1485	0.498	0.830	1.914	19.126	22.954
10	25.2	23.07	20.25	4.537	0.2455	0.588	0.979	2.257	20.813	25.327
$x_{sr} =$ 5.5	$y_{sr} =$ 13.95		SUMA= 82.5	SUMA= 22.177						

$$\hat{y}_i = A + B * x_i \quad s_r = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n-2}}$$

$$\hat{y}_i = 2.77 + 2.03 * x_i \quad s_r = \sqrt{\frac{22.177}{8}} = 1.665$$

$$s_{\hat{y}_i} = s_r \sqrt{\frac{1}{n} + s_i} \quad Y_{min} = \hat{y}_i - s_{\hat{y}_i} * t_\gamma \quad Y_{MAX} = \hat{y}_i + s_{\hat{y}_i} * t_\gamma$$

# ĆWICZENIE (4)



# ZMIANA NIEKTÓRYCH PRZYPADKÓW NIELINIOWYCH FUNKCJI REGRESJI NA LINIOWE (układy prostujące)

a) Adsorpcja promieniowania:  $I = I_o e^{-\mu x}$

zmienne  $I, x$  ; parametry  $I_o, \mu$   
Układ prostujący:  $Y = \log I = f(X)$ :

$$Y = \log I = \log I_o - \mu \log e * x = A - B * X$$

b) Przewodnictwo elektryczne półprzewodników

$$\sigma = \sigma_o * \exp\left[-\frac{E_{act}}{RT}\right]$$

zmienne:  $\sigma, T$  ; parametry:  $\sigma_o, E_{act}$ ; stałe:  $R$   
Układ prostujący:  $Y = \log \sigma = f(T^{-1}) = f(X)$ :

$$Y = \log \sigma = \log \sigma_o - \frac{E_{act} \log e}{R} * T^{-1} = A - B * X$$

c) Przewodnictwo elektryczne elektrolitów

$$\sigma = \frac{\sigma_o}{T} * \exp\left[-\frac{E_{act}}{RT}\right]$$

zmienne:  $\sigma, T$  ; parametry:  $\sigma_o, E_{act}$ ; stałe:  $R$   
Układ prostujący:  $Y = \log(\sigma T) = f(T^{-1}) = f(X)$ :

$$Y = \log(\sigma T) = \log \sigma_o - \frac{E_{act} \log e}{R} * T^{-1} = A - B * X$$

# ZMIANA NIEKTÓRYCH PRZYPADKÓW NIELINIOWYCH FUNKCJI REGRESJI NA LINIOWE (układy prostujące)

## d) Izoterma BET

$$V = \frac{v_m c p}{(p_o - p) \left[ 1 + \frac{p}{p_o} (c - 1) \right]}$$

zmienne:  $V, p$  ; parametry:  $p_o, c, v_m$   
Układ prostujący:

$$Y = \frac{p}{(p_o - p)V} = f\left(\frac{p}{p_o}\right) = f(X)$$

$$Y = \frac{p}{(p_o - p)V} = \frac{1}{c v_m} + \frac{c - 1}{c v_m} * \left(\frac{p}{p_o}\right) = A + B * X$$

$$A + B = \frac{1}{v_m}$$