

## Aproksymacja linią prostą

Tablica z danymi do aproksymacji

dane :=

0	1.03
1	3.6
3	23.16
5	27.57
4	24.26
6	16.63
8	30.41
12	50.3
11	48.22
13	60.33
16	71.89
14	59.18
17	84.27
19	77.69

$$X := \text{dane}^{\langle 0 \rangle}$$

$$Y := \text{dane}^{\langle 1 \rangle}$$

Współczynniki prostej

$$a := \text{line}(X, Y)$$

Funkcja aproksymująca


$$y(x) := a_0 + a_1 \cdot x$$

Można też tak

$$\begin{pmatrix} p \\ q \end{pmatrix} := \text{line}(X, Y)$$

$$y1(x) := p + q \cdot x$$

$x := -1, -0.95 \dots 20$



## Aproksymacja linią prostą - 2

Tablica z danymi do aproksymacji

dane :=

0	1.03
1	3.6
3	23.16
5	27.57
4	24.26
6	16.63
8	30.41
12	50.3
11	48.22
13	60.33
16	71.89
14	59.18
17	84.27
19	77.69

$X := \text{dane}^{\langle 0 \rangle}$

$Y := \text{dane}^{\langle 1 \rangle}$


Współczynniki prostej

$b := \text{intercept}(X, Y)$

$m := \text{slope}(X, Y)$

Funkcja aproksymująca:

$y(x) := b + m \cdot x$



## Aproksymacja wielomianem stopnia n

Tablica z danymi do aproksymacji

dane :=

0	1.03
1	3.6
3	23.16
5	27.57
4	24.26
6	16.63
8	30.41
12	50.3
11	48.22
13	60.33
16	71.89
14	59.18
17	84.27
19	77.69

$X := \text{dane}^{\langle 0 \rangle}$

$Y := \text{dane}^{\langle 1 \rangle}$


Współczynniki wyznaczone przez funkcję **regress** dla funkcji **interp**

$S := \text{regress}(X, Y, 5)$

Funkcja aproksymująca

$\text{fit}(x) := \text{interp}(S, X, Y, x)$

$z := 0, 0.1 \dots 19$



**Aproksymacja wielomianami stopnia drugiego**

Tablica z danymi do aproksymacji

dane :=

5	22.86
10.6	42.86
3	23.16
5	27.57
4	24.26
6	19.63
8	30.41
12	50.3
11	48.22
13	60.33
16	71.89
14	59.18
17	84.27
17.5	77.69

$X := \text{dane}^{\langle 0 \rangle}$

$Y := \text{dane}^{\langle 1 \rangle}$

Współczynniki wyznaczone przez funkcję **loess** dla funkcji **interp**

$S1 := \text{loess}(X, Y, 1.5)$


$S2 := \text{loess}(X, Y, 0.5)$

Funkcje aproksymujące:

$\text{fit1}(x) := \text{interp}(S1, X, Y, x)$

$\text{fit2}(x) := \text{interp}(S2, X, Y, x)$

$z := 3, 3.25 \dots 17.5$



Zastosowanie funkcji **linfit** do wyznaczenia współczynników wielomianu aproksymacyjnego drugiego stopnia


$$vx := \begin{pmatrix} 0.9 \\ 1.6 \\ 2.3 \\ 3.15 \\ 4.2 \\ 5 \\ 5.8 \end{pmatrix} \quad vy := \begin{pmatrix} 3 \\ 4.8 \\ 5.2 \\ 6.7 \\ 6.15 \\ 3.2 \\ 1 \end{pmatrix} \quad F(x) := \begin{pmatrix} 1 \\ x \\ x^2 \end{pmatrix}$$

Składowe wektora  $F(x)$  mogą być dowolnymi funkcjami.

$$a := \text{linfit}(vx, vy, F) \quad a = \begin{pmatrix} -0.763 \\ 4.638 \\ -0.749 \end{pmatrix}$$

$$yp(x) := \sum_{i=0}^2 (a_i \cdot F(x)_i)$$

$$x := 0.9, 1 \dots 5.8$$





## Aproksymacja nieliniowa za pomocą funkcji genfit

Wektory danych do aproksymacji

$$v_x := \begin{pmatrix} .3 \\ .4 \\ 1 \\ 1.4 \\ 2 \\ 4 \end{pmatrix} \quad v_y := \begin{pmatrix} 9.4 \\ 11.2 \\ 5 \\ 3 \\ 6 \\ 0 \end{pmatrix}$$

Pierwszy element po prawej stronie funkcji  $F(z,u)$  jest funkcją, która będzie aproksymować dane. Następne elementy to pochodne cząstkowe  $F$  względem poszukiwanych współczynników  $u_i$ .

$$F(z,u) := \begin{pmatrix} e^{u_0+u_1 \cdot z+u_2 \cdot z^2} \\ e^{u_0+u_1 \cdot z+u_2 \cdot z^2} \\ z \cdot e^{u_0+u_1 \cdot z+u_2 \cdot z^2} \\ z^2 \cdot e^{u_0+u_1 \cdot z+u_2 \cdot z^2} \end{pmatrix}$$

Poniższy wektor zawiera założone początkowe wartości poszukiwanych współczynników  $u_0$ ,  $u_1$ , and  $u_2$ .

$$v_g := \begin{pmatrix} 1 \\ 0 \\ -1 \end{pmatrix}$$

$$P := \text{genfit}(v_x, v_y, v_g, F)$$

Wektor P zawiera optymalne wartości współczynników  $u_0$ ,  $u_1$ , and  $u_2$ , obliczone przez **genfit**.

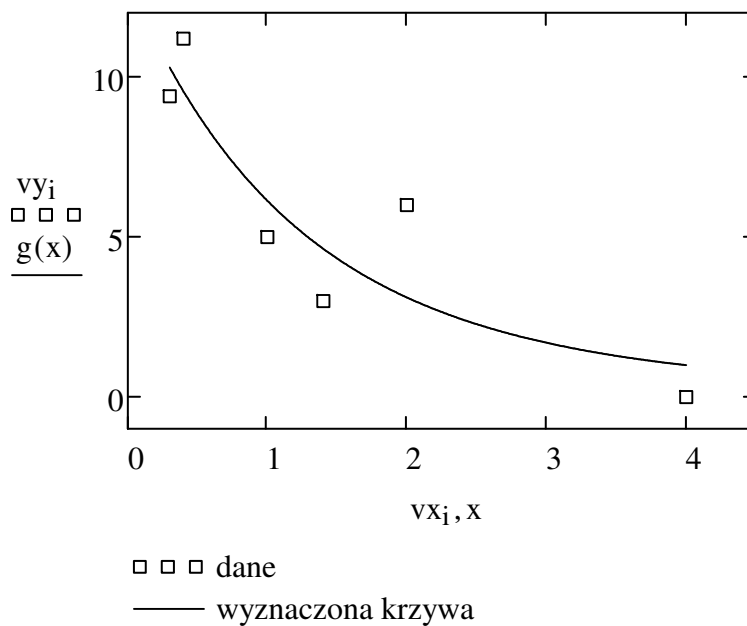
$$P = \begin{pmatrix} 2.5654 \\ -0.7881 \\ 0.0364 \end{pmatrix}$$

Krzywa najlepiej dopasowana do danych

$$g(x) := F(x, P)_0$$

$$i := 0..5$$

$$x := .3, .31 .. 4$$



Zastosowanie funkcji genfit z numerycznym wyznaczaniem pochodnych

$$F(z, u) := e^{u_0 + u_1 \cdot z + u_2 \cdot z^2}$$

$\underline{P} := \text{genfit}(vx, vy, vg, F)$

Prawym klawiszem myszy kliknąć w nazwę funkcji "genfit" i wybrać metodę:  
Optimized Levenberg Marquardt

$$P = \begin{pmatrix} 2.5654 \\ -0.7881 \\ 0.0364 \end{pmatrix}$$

## Regresja nieliniowa

$$vx := \begin{bmatrix} vx_0 \\ vx_1 \\ vx_2 \\ \vdots \\ vx_n \end{bmatrix} \quad (1a)$$

$$vy := \begin{bmatrix} vy_0 \\ vy_1 \\ vy_2 \\ \vdots \\ vy_n \end{bmatrix} \quad (1b)$$

$$vg := \begin{bmatrix} a_z \\ b_z \\ c_z \end{bmatrix} \quad (1c)$$

## Funkcja wykładnicza

$$wsp := \text{expfit}(vx, vy, vg) \quad (2a) \quad y = a \cdot e^{b \cdot x} + c \quad (2b)$$

$$wsp = \begin{bmatrix} wsp_0 \\ wsp_1 \\ wsp_2 \end{bmatrix} \quad (3a) \quad \begin{aligned} a &= wsp_0 \\ b &= wsp_1 \\ c &= wsp_2 \end{aligned} \quad (3b)$$

## Funkcja logistyczna

$$wsp := \text{lgsfit}(vx, vy, vg) \quad (4a) \quad y = \frac{a}{1 + b \cdot e^{-cx}} \quad (4b)$$

## Funkcja logarytmiczna

$$wsp := \text{logfit}(vx, vy, vg) \quad (5a) \quad y = a \cdot \ln(x + b) + c \quad (5b)$$

## Funkcja potęgowa

$$wsp := \text{pwrfit}(vx, vy, vg) \quad (6a) \quad y = a \cdot x^b + c \quad (6b)$$

## Funkcja sinusoidalna

$$wsp := \text{sinfite}(vx, vy, vg) \quad (7a) \quad y = a \cdot \sin(x + b) + c \quad (7b)$$

Zastosowanie funkcji **expfit** do wyznaczenia współczynników  $a_i$

funkcji aproksymującej postaci  $yp(x) := a_0 \cdot e^{a_1 \cdot x} + a_2$


$$vx := \begin{pmatrix} 0.1 \\ 0.9 \\ 1.2 \\ 2 \\ 2.8 \\ 3.4 \\ 4.55 \end{pmatrix} \quad vy := \begin{pmatrix} 5.2 \\ 8 \\ 11.2 \\ 16.5 \\ 25 \\ 33 \\ 48.1 \end{pmatrix} \quad \begin{array}{l} \text{Wartości początkowe} \\ a_{z_i} \\ \text{(założone)} \end{array}$$

$$az := \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix}$$

$$a := \text{expfit}(vx, vy, az) \quad a = \begin{pmatrix} 19.794 \\ 0.26 \\ -15.989 \end{pmatrix}$$

$$yp(x) := a_0 \cdot e^{a_1 \cdot x} + a_2$$

$$x := 0.1, 0.2 \dots 4.55$$



$n := 6$  (7 punktów o numerach od 0 do 6)

Suma kwadratów

$$S := \sum_{i=0}^n (vy_i - yp(vx_i))^2 \quad S = 3.894$$

Odchylenie średniokwadratowe

$$\Delta S := \sqrt{\frac{\sum_{i=0}^n (vy_i - yp(vx_i))^2}{n+1}} \quad \Delta S = 0.746$$

Można też tak

$$\begin{pmatrix} p \\ q \\ r \end{pmatrix} := \text{expfit}(vx, vy, az)$$

$$yp(x) := p \cdot e^{q \cdot x} + r$$

$$yp(1) = 9.673$$

Zastosowanie funkcji **minimize** do wyznaczenia współczynników funkcji aproksymującej dowolnej postaci

$$vx := \begin{pmatrix} 0.1 \\ 0.9 \\ 1.2 \\ 2 \\ 2.8 \\ 3.4 \\ 4.55 \end{pmatrix} \quad vy := \begin{pmatrix} 5.2 \\ 3.43 \\ 11.2 \\ 18.5 \\ 16 \\ 33 \\ 48.1 \end{pmatrix}$$

$$fit(a, x) := a_0 + a_1 \cdot x^2 + a_2 \cdot e^{a_3 \cdot x}$$

$$S(a) := \sum_{i=0}^{\text{last}(vx)} (vy_i - fit(a, vx_i))^2$$


$$a_0 := 0 \quad a_1 := 0 \quad a_2 := 0 \quad a_3 := 0$$

$$a := \text{Minimize}(S, a)$$

$$a = \begin{pmatrix} 2.468 \\ 1.706 \\ 2.567 \\ 0.317 \end{pmatrix}$$

$$yp(x) := fit(a, x)$$

$x := 0.1, 0.2 \dots 4.55$



$n := 6$  (7 punktów o numerach od 0 do 6)

Suma kwadratów

$$S := \sum_{i=0}^n (vy_i - yp(vx_i))^2 \quad S = 88.082$$

Odchylenie średniokwadratowe

$$\Delta S := \sqrt{\frac{\sum_{i=0}^n (vy_i - yp(vx_i))^2}{n+1}} \quad \Delta S = 3.547$$