

## 0.1 Prosta regresji.

Założmy, że w wyniku pomiarów wielkości  $y(x)$  zależnej od argumentu  $x$  w punktach

$$x_0, x_1, x_2, \dots, x_m$$

otrzymaliśmy wartości

$$y_0, y_1, y_2, \dots, y_m,$$

które zanotowaliśmy w postaci tabeli

Tabela danych punktów  $(x, y)$

$x$	$x_0$	$x_1$	$x_2$	.....	$x_m$
$y$	$y_0$	$y_1$	$y_2$	.....	$y_m$

Na przykład zmierzaliśmy temperaturę w każdą poniedziałek września, 2018 i zanotowaliśmy wyniki pomiaru w tabeli

Tabela 1

dzień	1	8	15	22	29
temperatura	15	17	20	14	10

W tym doświadczeniu  $m = 4$

(1)

## 0.2 Prosta regresji

Prosta regresji o równaniu

$$y(x) = a_1x + a_0$$

jest najlepiej dopasowaną prostą do danych punktów  $(x_i, y_i)$ ,  $i = 0, 1, 2, \dots, m$  w sensie *najmniejszych kwadratów*.

Prosta jest najlepiej dopasowaną do danych punktów w tabeli w *sensie najmniejszych kwadratów*, jeżeli suma kwadratów odległości wszystkich punktów od prostej położonej na płaszczyźnie kartezjańskiej jest najmniejsza.

Współczynniki  $a_0$ ,  $a_1$  obliczymy rozwiązując następujący układ dwóch równań

$$s_0a_0 + s_1a_1 = v_0$$

$$s_1a_0 + s_2a_1 = v_1$$

gdzie

$$s_0 = m + 1,$$

$$s_1 = x_0 + x_1 + x_2 + \cdots + x_m = \sum_{i=0}^m x_i,$$

$$s_2 = x_0^2 + x_1^2 + x_2^2 + \cdots + x_m^2 = \sum_{i=0}^m x_i^2,$$

$$v_0 = y_0 + y_1 + y_2 + \cdots + y_m = \sum_{i=0}^m y_i,$$

$$v_1 = x_0 * y_0 + x_1 * y_1 + x_2 * y_2 + \cdots + x_m * y_m = \sum_{i=0}^m x_i * y_i$$

Układ dwóch równań o współczynnikach  $s_0, s_1, s_2$  i prawych stronach  $v_0, v_1$  wynika z warunku na minimum funkcji

$$\begin{aligned} \phi(a_0, a_1) &= (a_0 + a_1 * x_0 - y_0)^2 + (a_0 + a_1 * x_1 - y_1)^2 + \cdots + (a_0 + a_1 * x_m)^2 \\ &= \sum_{i=0}^m (a_0 + a_1 x_i - y_i)^2, \end{aligned}$$

dwóch zmiennych  $a_0, a_1$ .

Warunek na minimum funkcji dwóch zmiennych jest sformułowany w pojęciach pochodnych cząstkowych funkcji wielu zmiennych i wykracza poza zakres programu szkół średnich. Sam układ dwóch równań jest prosty i łatwo rozwiązywany metodą eliminacji niewiadomych  $a_0, a_1$ .

**Przykład 0.1** *Znajdź równanie prostej*

$$y(x) = a_1 * x + a_0$$

*najlepiej dopasowane do danych w tabeli (1) i podaj jej wykres we współrzędnych kartezjańskich  $x, y$ .*

*Oblicz temperaturę 20-go września, 2018 roku  $y(20)$  z równania prostej regresji.*

**Rozwiązanie.**

Obliczamy współczynniki  $s_0, s_1, s_2$  i prawe strony  $v_0, v_1$  dla  $m = 4$  i danych w tabeli (1)

$$s_0 = m + 1 = 4 + 1 = 5,$$

$$s_1 = x_0 + x_1 + x_2 + \cdots + x_m = 1 + 8 + 15 + 22 + 29 = 75,$$

$$s_2 = x_0^2 + x_1^2 + x_2^2 + \cdots + x_m^2 = 1 * 15 + 8 * 17 + 15 * 20 + 22 * 14 + 29 * 10 = 1615,$$

$$v_0 = y_0 + y_1 + y_2 + \cdots + y_m = 15 + 17 + 20 + 14 + 10 = 76,$$

$$v_1 = x_0 * y_0 + \cdots + x_m * y_m = 1 * 15 + 8 * 17 + 15 * 20 + 22 * 14 + 29 * 10 = 1049$$

Dla danych w tabeli (1) otrzymamy następujący układ dwóch równań

$$5a_0 + 75a_1 = 76$$

$$75a_0 + 1615a_1 = 1049$$

*Rozwiązanie układu metodą eliminacji Gaussa.*

Pomnóżmy obie strony pierwszego równania przez 15 i odejmijmy stronami równanie drugie od równania pierwszego, jak niżej

$$5a_0 + 75a_1 = 76 \quad | * 15, \quad 75a_0 + 1125a_1 = 1140,$$

$$75a_0 + 1615a_1 = 1049, \quad 75a_0 + 1615a_1 = 1049,$$

-----

$$1125a_1 - 1615a_1 = 1140 - 1049, \quad -490a_1 = 91$$

Z równania  $-490a_1 = 91$  obliczamy

$$a_1 = \frac{91}{-490} = -\frac{13}{70} = -0.185714$$

z równania  $5a_0 + 75a_1 = 76$  obliczamy


$$a_0 = \frac{76 + 75 * \frac{13}{70}}{5} = \frac{1259}{70} = 17.9857$$

Równanie prostej regresji najlepiej dopasowanej do danych w tabeli (1) w sensie metody najmniejszych kwadratów

$$y = \frac{1259}{70} - \frac{13}{70}x, \quad \text{lub} \quad y = 17.9857 - 0.185714x$$

Temperatura 20-go września  $y(20) = 17.9857 - 0.185714 * 20 = 14.18856$ .

Wykres prostej regresji



Zauważmy, że żaden z danych punktów w tabeli (1) nie leży na prostej regresji. Pomimo tego prosta jest najlepiej dopasowana do tych danych w sensie metody najmniejszych kwadratów.

### 0.3 Zadania

**Zadanie 0.1** *Wzrost chłopca zanotowano w tabeli*

*Tabela 2*

<i>rok</i>	<i>1 rok</i>	<i>5 lat</i>	<i>10 lat</i>	<i>15 lat</i>	<i>20 lat</i>
<i>wzrost</i>	<i>80cm</i>	<i>100cm</i>	<i>140cm</i>	<i>160cm</i>	<i>180cm</i>

*W tym doświadczeniu  $m = 4$*

- *Znajdź równanie*

$$y(x) = a_1x + a_0$$

*prostej regresji dla danych w powyższej tabeli 2.*

- *Na płaszczyźnie katezjańskiej we współrzędnych  $x, y$  zaznacz punkty*

$$(x_0, y_0) = (1, 80), \quad (x_1, y_1) = (5, 100),$$

$$(x_2, y_2) = (10, 140), \quad (x_3, y_3) = (15, 160),$$

$$(x_4, y_4) = (20, 180)$$

*i podaj wykres prostej regresji.*

- *Oblicz wzrost chłopca  $y(18)$  w wieku 18 lat z prostej regresji.*