

Vorlesung 7b

Korrelationskoeffizient und Regressionsgerade

Teil 3

Beste affin lineare Vorhersage:
die Regressionsgerade

(Buch S. 62-64)

Um die am Ende von Teil 2 behauptete
Eigenschaft von κ_{XY}^2 einzusehen,
fragen wir erst einmal:

Durch welche **Konstante** wird die Zufallsvariable Y
(im Sinn des erwarteten quadratischen Fehlers)
am besten vorhergesagt?

Die Antwort ist:

Durch ihren **Erwartungswert $E[Y]$** !

Denn:

$$\begin{aligned}\mathbf{E}[(Y - c)^2] &= \mathbf{E}[(Y - \mu_Y + \mu_Y - c)^2] \\ &= \mathbf{E}[(Y - \mu_Y)^2] + 2\mathbf{E}[(Y - \mu_Y)(\mu_Y - c)] + (\mu_Y - c)^2 \\ &= \sigma_Y^2 + 0 + (\mu_Y - c)^2.\end{aligned}$$

Das wird minimiert von

$$c = \mu_Y$$

und hat den Minimalwert

$$\sigma_Y^2.$$

Jetzt fragen wir:

Durch welche **affin lineare Funktion von X** ,

$$\beta_1 X + \beta_0,$$

wird die Zufallsvariable Y

(wieder im Sinn des erwarteten quadratischen Fehlers)

am besten vorhergesagt?

Genauer:

Für welche Zahlen β_1, β_0 wird
 $\mathbf{E}[(Y - \beta_1 X - \beta_0)^2]$ minimal?

Wie wir gleich sehen werden, ist die Lösung:

$$\beta_1 := \frac{\sigma_Y}{\sigma_X} \kappa_{XY}$$

und β_0 so, dass $\mu_Y = \beta_1 \mu_X + \beta_0$.

M. a. W.: β_0 so, dass der Punkt (μ_X, μ_Y)
auf der Geraden $y = \beta_1 x + \beta_0$ liegt.

Wir nennen diese Gerade
die **Regressionsgerade** für Y auf der Basis von X .

Wir begründen jetzt die Behauptung über β_0 und β_1 :

$$\begin{aligned} & \mathbf{E}[(Y - \beta_1 X - \beta_0)^2] \\ &= \mathbf{Var}[Y - \beta_1 X - \beta_0] + (\mathbf{E}[Y - \beta_1 X - \beta_0])^2 \\ &= \mathbf{Var}[Y - \beta_1 X] + (\mu_Y - \beta_1 \mu_X - \beta_0)^2 \end{aligned}$$

Der **zweite Summand** ist Null für $\beta_0 = \mu_Y - \beta_1 \mu_X$.

Damit haben wir schon mal **die eine Bedingung** gefunden.

Für welches β_1 wird **der erste Summand** minimal?

Im Rest des Abschnittes schreiben wir um der besseren Lesbarkeit willen κ statt κ_{XY} .

$$\mathbf{Var}[Y - \beta_1 X] = \mathbf{Var}[Y] - 2\beta_1 \mathbf{Cov}[X, Y] + \beta_1^2 \mathbf{Var}[X]$$

$$= \sigma_Y^2 - 2\beta_1 \kappa \sigma_X \sigma_Y + \beta_1^2 \sigma_X^2$$

$$= \sigma_Y^2 - \sigma_Y^2 \kappa^2 + (\sigma_Y^2 \kappa^2 - 2\beta_1 \kappa \sigma_X \sigma_Y + \beta_1^2 \sigma_X^2)$$

$$\mathbf{Var}[Y - \beta_1 X] = \mathbf{Var}[Y] - 2\beta_1 \mathbf{Cov}[X, Y] + \beta_1^2 \mathbf{Var}[X]$$

$$= \sigma_Y^2 - 2\beta_1 \kappa \sigma_X \sigma_Y + \beta_1^2 \sigma_X^2$$

$$= \sigma_Y^2 - \sigma_Y^2 \kappa^2 + (\sigma_Y \kappa - \beta_1 \sigma_X)^2$$

Der rechte Summand wird Null für

$$\beta_1 = \frac{\sigma_Y}{\sigma_X} \kappa.$$

Und der Minimalwert von $\mathbf{Var}[Y - \beta_1 X]$ ist $\sigma_Y^2(1 - \kappa^2)$.

Damit ist auch der Minimalwert von $\text{Var}[Y - \beta_1 X - \beta_0 \mathbf{1}]$
gleich $\sigma_Y^2(1 - \kappa^2)$.

Der Minimalwert von $\text{Var}[Y - c \mathbf{1}]$ war σ_Y^2 .

Die Verbesserung der Approximation (“Vorhersage”) von Y
im quadratischen Mittel, wenn man zu den Vielfachen von 1

die Vielfachen von X dazunimmt, beträgt

$$\sigma_Y^2 - \sigma_Y^2(1 - \kappa^2) = \kappa^2 \sigma_Y^2.$$

Also ist der Anteil von σ_Y^2 ,

der von den Vielfachen von X zusätzlich zu
den Vielfachen von 1 “erklärt” wird, gleich $\kappa^2 \sigma_Y^2$.

Wir halten fest: Die Minimierungsaufgabe

$$\mathbf{E}[(Y - \beta_1 X - \beta_0)^2] \stackrel{!}{=} \min$$

für die *beste affin lineare Vorhersage von Y*

auf der Basis von X

(im Sinn des quadratischen Mittels)

hat die Lösung

$$\beta_1 = \frac{\sigma_Y}{\sigma_X} \kappa, \quad \mu_Y = \beta_1 \mu_X + \beta_0$$

und den Minimalwert $(1 - \kappa^2) \sigma_Y^2$.

Beispiel: “Welche Gerade passt am besten?”

Die Methode der kleinsten Quadrate.

$(x_1, y_1), \dots, (x_n, y_n)$ seien n verschiedene Punkte im \mathbb{R}^2 .

Für welche β_0, β_1 wird $\sum_{i=1}^n (y_i - \beta_1 x_i - \beta_0)^2$ minimal?

Diese Aufgabe interpretieren wir stochastisch. Sei J uniform

verteilt auf $\{1, \dots, n\}$ und $(X, Y) := ((x_J, y_J)$, also

$$\mathbf{P}((X, Y) = (x_i, y_i)) = \frac{1}{n}, \quad i = 1, \dots, n.$$

Dann ist

$$\mathbf{E}[X] = \frac{1}{n} \sum x_i =: \bar{x}, \quad \mathbf{E}[Y] = \frac{1}{n} \sum y_i =: \bar{y},$$

$$\sigma_X^2 = \frac{1}{n} \sum (x_i - \bar{x})^2, \quad \sigma_Y^2 = \frac{1}{n} \sum (y_i - \bar{y})^2,$$

$$\mathbf{Cov}[X, Y] = \frac{1}{n} \sum (x_i - \bar{x})(y_i - \bar{y}),$$

$$\kappa := \kappa_{XY} = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2} \sqrt{\sum (y_i - \bar{y})^2}}.$$

$$\mathbf{E}[(Y - \beta_1 X - \beta_0)^2] = \frac{1}{n} \sum_{i=1}^n (y_i - \beta_1 x_i - \beta_0)^2$$

wird, wie wir gezeigt haben, minimiert durch

$$\beta_1 := \frac{\sigma_Y}{\sigma_X} \kappa = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sum (x_i - \bar{x})^2}$$

und β_0 so, dass $\bar{y} = \beta_1 \bar{x} + \beta_0$.

Diese Gerade $y = \beta_1 x + \beta_0$ heißt die **Regressionsgerade** zu den Punkten (x_i, y_i) , $i = 1, \dots, n$.
(oder auch die mit der Methode der kleinsten Quadrate gefundene Ausgleichsgerade).