

# Vorlesung 7b

## Korrelationskoeffizient und Regressionsgerade

### Teil 3

Beste affin lineare Vorhersage:  
die Regressionsgerade

(Buch S. 62-64)

Wie am Ende von Teil 2 angekündigt, wollen wir einsehen:

Das Quadrat des Korrelationskoeffizienten ist ein Maß dafür,  
um wieviel besser man  $Y$   
durch eine affin lineare Funktion von  $X$  vorhersagen kann:

$$Y = \beta_1 X + \beta_0 + \text{“Fehler”},$$

als durch eine Konstante:

$$Y = c + \text{“Fehler”}.$$

Dazu 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:

$$\mathbf{E}[(Y - c)^2] =$$

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

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

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

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

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

Wir begründen jetzt die Behauptung über  $\beta_0$  und  $\beta_1$ :

Wir begründen jetzt die Behauptung über  $\beta_0$  und  $\beta_1$ :

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

Wir begründen jetzt die Behauptung über  $\beta_0$  und  $\beta_1$ :

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

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  $\beta_1$  wird **der erste Summand** minimal?

Im Rest des Abschnittes schreiben wir um der besseren Lesbarkeit willen  $\kappa$  statt  $\kappa_{XY}$ .

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

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

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

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

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

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

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  $\sigma_Y^2$ .

Die **Verbesserung der Approximation** (“Vorhersage”) von  $Y$  im quadratischen Mittel, wenn man zu den Vielfachen von  $\mathbf{1}$  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  $\sigma_Y^2$ ,

der von den Vielfachen von  $X$  zusätzlich zu den Vielfachen von  $\mathbf{1}$  “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  $\beta_0, \beta_1$  wird  $\sum_{i=1}^n (y_i - \beta_1 x_i - \beta_0)^2$  minimal?

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  $\beta_0, \beta_1$  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

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

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  $\beta_0$  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*.