

Vorlesung 7b

Korrelationskoeffizient und Regressionsgerade

Teil 2

Der Korrelationskoeffizient

(Buch S. 62)

Definition.

Für zwei Zufallsvariable X, Y
mit positiven, endlichen Varianzen ist

$$\kappa_{XY} := \frac{\text{Cov}[X, Y]}{\sqrt{\text{Var}X} \sqrt{\text{Var}Y}}$$

$$\frac{\text{Cov}[X, Y]}{\sigma_X \sigma_Y}$$

der **Korrelationskoeffizient** von X und Y
(kurz auch: *die Korrelation* von X und Y).

Definition.

Für zwei Zufallsvariable X, Y
mit positiven, endlichen Varianzen ist

$$\kappa_{XY} := \frac{\text{Cov}[X, Y]}{\sqrt{\text{Var}X} \sqrt{\text{Var}Y}}$$


der **Korrelationskoeffizient** von X und Y
(kurz auch: *die Korrelation* von X und Y).

Aus der Kovarianz-Varianz-Ungleichung folgt sofort:

$$-1 \leq \kappa_{XY} \leq 1.$$


Fünf prominente Zahlen

zur (teilweisen) Beschreibung der Verteilung
eines zufälligen Paares (X, Y) in $\mathbb{R} \times \mathbb{R}$:



Fünf prominente Zahlen
zur (teilweisen) Beschreibung der Verteilung
eines zufälligen Paares (X, Y) in $\mathbb{R} \times \mathbb{R}$:

μ_X und μ_Y : die Erwartungswerte von X und Y

Fünf prominente Zahlen
zur (teilweisen) Beschreibung der Verteilung
eines zufälligen Paares (X, Y) in $\mathbb{R} \times \mathbb{R}$:

μ_X und μ_Y : die Erwartungswerte von X und Y

σ_X und σ_Y : die Standardabweichungen von X und Y

Fünf prominente Zahlen
zur (teilweisen) Beschreibung der Verteilung
eines zufälligen Paares (X, Y) in $\mathbb{R} \times \mathbb{R}$:


μ_X und μ_Y : die Erwartungswerte von X und Y

σ_X und σ_Y : die Standardabweichungen von X und Y


κ_{XY} : der Korrelationskoeffizient von X und Y

Die folgenden 11 Bilder zeigen jeweils die Realisierungen von 1000 unabhängige Kopien (X_i, Y_i) eines zufälligen Paares (X, Y) , mit X $N(0, 1)$ -verteilt, Y $N(0, 1)$ -verteilt, und $\kappa_{XY} = -0.9, -0.7, \dots, -0.1, 0, 0.1, \dots, 0.7, 0.9$, zusammen mit der Geraden durch den Ursprung mit Anstieg κ_{XY} .


Korrelation = - 0.9




Korrelation = - 0.7




Korrelation = - 0.5




Korrelation = - 0.3




Korrelation = - 0.1




Korrelation = 0




Korrelation = 0.1




Korrelation = 0.3




Korrelation = 0.5



Korrelation = 0.7



Korrelation = 0.9



$$k^2 + \rho = 1$$
$$k^2 + (1 - k^2) = 1$$

Hier kommt das Rezept,
wie in den 9 vorangegangenen Bildern
jeweils die 1000 Punkte (X_i, Y_i) erzeugt wurden:

Z_1, Z_2 unabh. nd $N(0,1)$ -verteilt

$$K=1$$
$$X, Y$$

$$X = Y =: Z_1$$

$$\text{cov}[Z_1, Z_1] = \text{var}[Z_1] = 1$$

Allgemein: K sei gegeben

$$X =: Z_1$$

$$Y =: k Z_1 + \sqrt{1 - k^2} Z_2$$

Beispiel:

Gemeinsam normalverteilte Zufallsvariable X und Y

mit $\sigma_X^2 = \sigma_Y^2 = 1$ und Korrelationskoeffizient κ :

Z_1, Z_2 seien unabhängig und standard-normalverteilt.

Beispiel:

Gemeinsam normalverteilte Zufallsvariable X und Y

mit $\sigma_X^2 = \sigma_Y^2 = 1$ und Korrelationskoeffizient κ :

Z_1, Z_2 seien unabhängig und standard-normalverteilt.

$$X := Z_1, \quad Y := \kappa Z_1 + \sqrt{1 - \kappa^2} Z_2.$$

Aus der Bilinearität der Kovarianz folgt:

$$\text{Cov}[X, Y] = \text{Cov}[Z_1, \kappa Z_1] + 0 = \kappa.$$

$$\sigma_X^2 = 1, \quad \sigma_Y^2 = \kappa^2 + (1 - \kappa^2) = 1.$$

$$\text{Also: } \kappa_{XY} = \kappa.$$

Auch Y ist (standard-) normalverteilt (siehe V7a1 Folie 12).

Eine Interpretation von κ^2 :

Wir werden sehen:

Für jedes zufällige Paar (X, Y) reellwertiger Zufallsvariabler mit endlichen Varianzen gilt:

κ^2 ist ein Maß dafür, um wieviel besser man Y durch eine affin lineare Funktion von X vorhersagen kann:

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


Eine Interpretation von κ^2 :

Wir werden sehen:

Für jedes zufällige Paar (X, Y) reellwertiger Zufallsvariabler mit endlichen Varianzen gilt:

κ^2 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:

$$Y = c + \text{“Fehler”}.$$

(Die “Güte der Vorhersage” bezieht sich auf die Kleinheit des **erwarteten quadrierten “Fehlers”** (mean square error).)

