

Lecture 11: Lineare (Regressions-) Modelle

$$\hat{y}(x)$$

11.1 Flussdiagramm

11.2 Modellspezifikation

11.2.1 Funktionale Spezifikation


11.2.2 Statistische Spezifikation

11.2.3 Datenspezifikation


11.3 Ordinary Least Squares (OLS)
Schätzung

data


11.1 Flussdiagramm



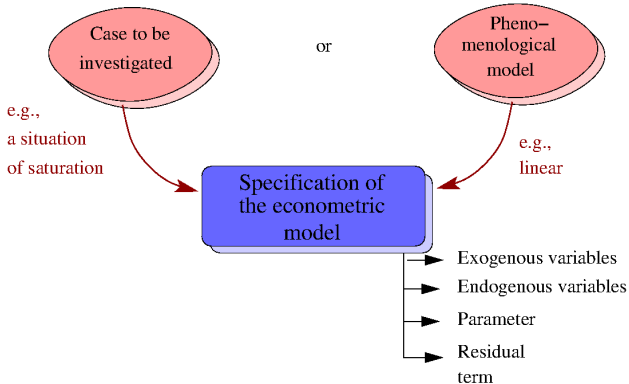
11.1 Flussdiagramm



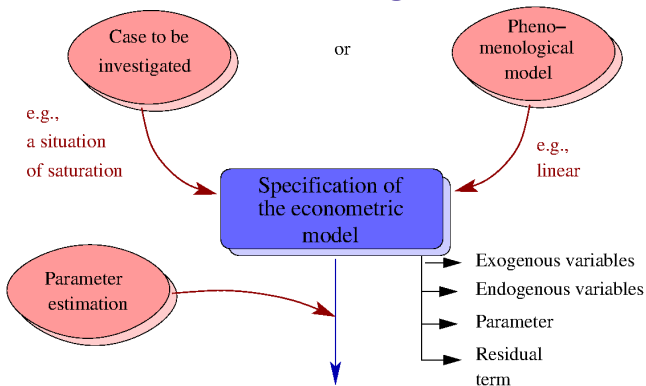
11.1 Flussdiagramm



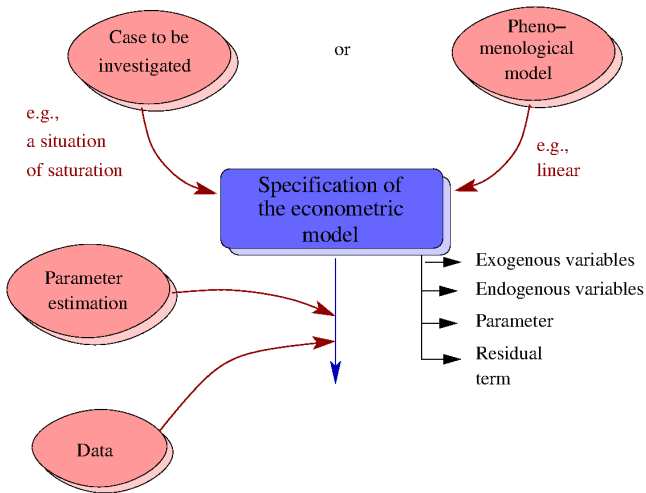
11.1 Flussdiagramm



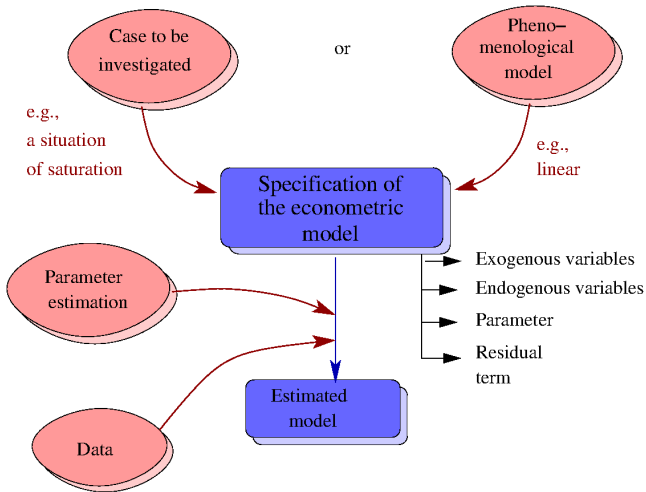
11.1 Flussdiagramm



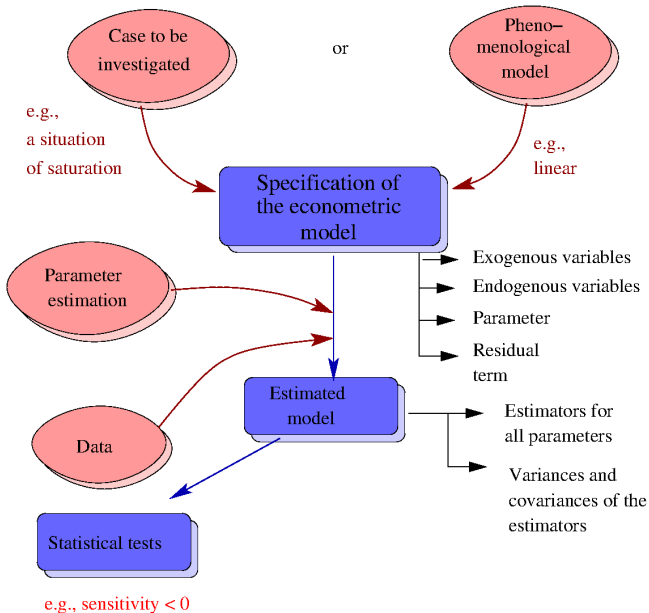
11.1 Flussdiagramm



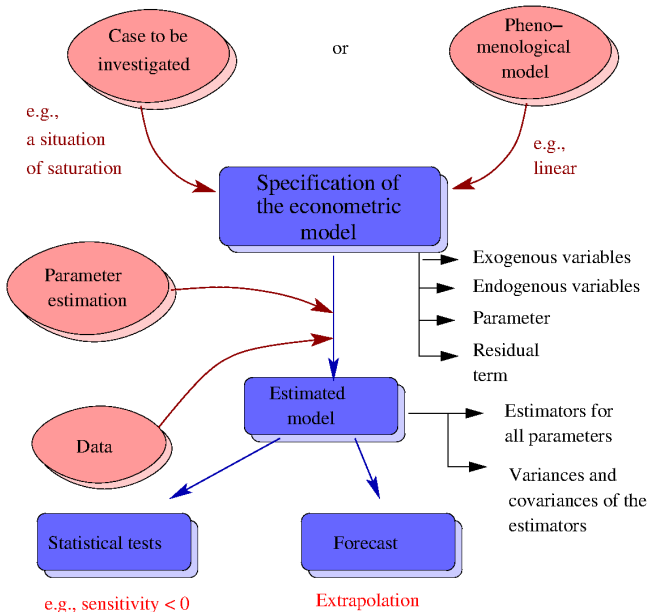
11.1 Flussdiagramm



11.1 Flussdiagramm



11.1 Flussdiagramm



11.2 Modellspezifikation

Modellspezifikation: *vollständige strukturelle Spezifikation* des Modells und seine Konsistenz mit den verfügbaren Daten. Es gibt drei Ebenen:

- ▶ **Funktionale Spezifikation:** Exogene und endogene Variable und die funktionale Form, wie sie im Modell auftauchen. Insbesondere die Transformation der exogenen Variablen \tilde{x} in lineare **Faktoren** $x_j = g_j(\tilde{x})$ durch feste, i.A. nichtlineare Funktionen $g_j(\cdot)$
- ▶ **Statistische Spezifikation:** Wie sind z.B. *Fehlerterme* verteilt und miteinander korreliert?
- ▶ **Datenspezifikation:** Passt das Modell zu den Daten? Gibt es eine ausreichende Zahl an Datensätzen? Sind alle exogenen *und* endogenen Variablen vorhanden?

11.2 Modellspezifikation

Modellspezifikation: *vollständige strukturelle Spezifikation* des Modells und seine Konsistenz mit den verfügbaren Daten. Es gibt drei Ebenen:

- ▶ **Funktionale Spezifikation:** Exogene und endogene Variable und die funktionale Form, wie sie im Modell auftauchen. Insbesondere die Transformation der exogenen Variablen \tilde{x} in lineare **Faktoren** $x_j = g_j(\tilde{x})$ durch feste, i.A. nichtlineare Funktionen $g_j(\cdot)$
- ▶ **Statistische Spezifikation:** Wie sind z.B. *Fehlerterme* verteilt und miteinander korreliert?
- ▶ **Datenspezifikation:** Passt das Modell zu den Daten? Gibt es eine ausreichende Zahl an Datensätzen? Sind alle exogenen *und* endogenen Variablen vorhanden?

11.2 Modellspezifikation

Modellspezifikation: *vollständige strukturelle Spezifikation* des Modells und seine Konsistenz mit den verfügbaren Daten. Es gibt drei Ebenen:

- ▶ **Funktionale Spezifikation:** Exogene und endogene Variable und die funktionale Form, wie sie im Modell auftauchen. Insbesondere die Transformation der exogenen Variablen \tilde{x} in lineare **Faktoren** $x_j = g_j(\tilde{x})$ durch feste, i.A. nichtlineare Funktionen $g_j(\cdot)$
- ▶ **Statistische Spezifikation:** Wie sind z.B. *Fehlerterme* verteilt und miteinander korreliert?
- ▶ **Datenspezifikation:** Passt das Modell zu den Daten? Gibt es eine ausreichende Zahl an Datensätzen? Sind alle exogenen *und* endogenen Variablen vorhanden?

11.2 Modellspezifikation

Modellspezifikation: *vollständige strukturelle Spezifikation* des Modells und seine Konsistenz mit den verfügbaren Daten. Es gibt drei Ebenen:

- ▶ **Funktionale Spezifikation:** Exogene und endogene Variable und die funktionale Form, wie sie im Modell auftauchen. Insbesondere die Transformation der exogenen Variablen \tilde{x} in lineare **Faktoren** $x_j = g_j(\tilde{x})$ durch feste, i.A. nichtlineare Funktionen $g_j(\cdot)$
- ▶ **Statistische Spezifikation:** Wie sind z.B. *Fehlerterme* verteilt und miteinander korreliert?
- ▶ **Datenspezifikation:** Passt das Modell zu den Daten? Gibt es eine ausreichende Zahl an Datensätzen? Sind alle exogenen *und* endogenen Variablen vorhanden?

WARNUNG

Fehlspezifizierte Modelle führen zu Fehlern aller Art, von unproblematisch bis desaströs

- ▶ **irrelevant:** Einige Fehlspezifikationen werden automatisch durch die Kalibrierungsprozedur "entdeckt", z.B. in dem sie "Null/Null" Fehler oder singuläre Matrizen produziert
- ▶ **mild:** keine automatische Detektierung durch die Kalibrierungsmethode, aber milde Folgen: Schätzer ist nach wie vor unverzerrt/effizient, aber die induktive Statistik führt zu unkorrekten Ergebnissen
- ▶ **mittel:** Immer noch unverzerrte Schätzer, aber dieser ist nicht mehr effizient und es gibt starke inferentielle Fehler, insbesondere wird eine zu hohe Signifikanz vorgegaukelt
- ▶ **desaströs:** ie Ergebnisse sind in einer unvorhersehbaren Weise verzerrt

Junk in, junk out!

Es gibt Lügen, verdammte
Lügen und Statistik!

WARNUNG

Fehlspezifizierte Modelle führen zu Fehlern aller Art, von unproblematisch bis desaströs

- ▶ **irrelevant:** Einige Fehlspezifikationen werden automatisch durch die Kalibrierungsprozedur “entdeckt”, z.B. in dem sie “Null/Null” Fehler oder singuläre Matrizen produziert
- ▶ **mild:** keine automatische Detektierung durch die Kalibrierungsmethode, aber milde Folgen: Schätzer ist nach wie vor unverzerrt/effizient, aber die induktive Statistik führt zu unkorrekten Ergebnissen
- ▶ **mittel:** Immer noch unverzerrte Schätzer, aber dieser ist nicht mehr effizient und es gibt starke inferentielle Fehler, insbesondere wird eine zu hohe Signifikanz vorgegaukelt
- ▶ **desaströs:** ie Ergebnisse sind in einer unvorhersehbaren Weise verzerrt

Junk in, junk out!

Es gibt Lügen, verdammte
Lügen und Statistik!

WARNUNG

Fehlspezifizierte Modelle führen zu Fehlern aller Art, von unproblematisch bis desaströs

- ▶ **irrelevant:** Einige Fehlspezifikationen werden automatisch durch die Kalibrierungsprozedur “entdeckt”, z.B. in dem sie “Null/Null” Fehler oder singuläre Matrizen produziert
- ▶ **mild:** keine automatische Detektierung durch die Kalibrierungsmethode, aber milde Folgen: Schätzer ist nach wie vor unverzerrt/effizient, aber die induktive Statistik führt zu unkorrekten Ergebnissen
- ▶ **mittel:** Immer noch unverzerrte Schätzer, aber dieser ist nicht mehr effizient und es gibt starke inferentielle Fehler, insbesondere wird eine zu hohe Signifikanz vorgegaukelt
- ▶ **desaströs:** ie Ergebnisse sind in einer unvorhersehbaren Weise verzerrt

Junk in, junk out!

Es gibt Lügen, verdammte
Lügen und Statistik!

WARNUNG

Fehlspezifizierte Modelle führen zu Fehlern aller Art, von unproblematisch bis desaströs

- ▶ **irrelevant:** Einige Fehlspezifikationen werden automatisch durch die Kalibrierungsprozedur “entdeckt”, z.B. in dem sie “Null/Null” Fehler oder singuläre Matrizen produziert
- ▶ **mild:** keine automatische Detektierung durch die Kalibrierungsmethode, aber milde Folgen: Schätzer ist nach wie vor unverzerrt/effizient, aber die induktive Statistik führt zu unkorrekten Ergebnissen
- ▶ **mittel:** Immer noch unverzerrte Schätzer, aber dieser ist nicht mehr effizient und es gibt starke inferentielle Fehler, insbesondere wird eine zu hohe Signifikanz vorgegaukelt
- ▶ **desaströs:** ie Ergebnisse sind in einer unvorhersehbaren Weise verzerrt

Junk in, junk out!

Es gibt Lügen, verdammte
Lügen und Statistik!

WARNUNG

Fehlspezifizierte Modelle führen zu Fehlern aller Art, von unproblematisch bis desaströs

- ▶ **irrelevant:** Einige Fehlspezifikationen werden automatisch durch die Kalibrierungsprozedur “entdeckt”, z.B. in dem sie “Null/Null” Fehler oder singuläre Matrizen produziert
- ▶ **mild:** keine automatische Detektierung durch die Kalibrierungsmethode, aber milde Folgen: Schätzer ist nach wie vor unverzerrt/effizient, aber die induktive Statistik führt zu unkorrekten Ergebnissen
- ▶ **mittel:** Immer noch unverzerrte Schätzer, aber dieser ist nicht mehr effizient und es gibt starke inferentielle Fehler, insbesondere wird eine zu hohe Signifikanz vorgegaukelt
- ▶ **desaströs:** ie Ergebnisse sind in einer unvorhersehbaren Weise verzerrt

Junk in, junk out!

Es gibt Lügen, verdammte
Lügen und Statistik!

WARNUNG

Fehlspezifizierte Modelle führen zu Fehlern aller Art, von unproblematisch bis desaströs

- ▶ **irrelevant:** Einige Fehlspezifikationen werden automatisch durch die Kalibrierungsprozedur “entdeckt”, z.B. in dem sie “Null/Null” Fehler oder singuläre Matrizen produziert
- ▶ **mild:** keine automatische Detektierung durch die Kalibrierungsmethode, aber milde Folgen: Schätzer ist nach wie vor unverzerrt/effizient, aber die induktive Statistik führt zu unkorrekten Ergebnissen
- ▶ **mittel:** Immer noch unverzerrte Schätzer, aber dieser ist nicht mehr effizient und es gibt starke inferentielle Fehler, insbesondere wird eine zu hohe Signifikanz vorgegaukelt
- ▶ **desaströs:** ie Ergebnisse sind in einer unvorhersehbaren Weise verzerrt

Junk in, junk out!

Es gibt Lügen, verdammte
Lügen und Statistik!

WARNUNG


Fehlspezifizierte Modelle führen zu Fehlern aller Art, von unproblematisch bis desaströs

- ▶ **irrelevant:** Einige Fehlspezifikationen werden automatisch durch die Kalibrierungsprozedur “entdeckt”, z.B. in dem sie “Null/Null” Fehler oder singuläre Matrizen produziert
- ▶ **mild:** keine automatische Detektierung durch die Kalibrierungsmethode, aber milde Folgen: Schätzer ist nach wie vor unverzerrt/effizient, aber die induktive Statistik führt zu unkorrekten Ergebnissen
- ▶ **mittel:** Immer noch unverzerrte Schätzer, aber dieser ist nicht mehr effizient und es gibt starke inferentielle Fehler, insbesondere wird eine zu hohe Signifikanz vorgegaukelt
- ▶ **desaströs:** ie Ergebnisse sind in einer unvorhersehbaren Weise verzerrt

Junk in, junk out!


Es gibt Lügen, verdammte
Lügen und **Statistik!**

11.2.1 Funktionale Spezifikation 1: relevante Faktoren




- ▶ Berücksichtige alle relevanten Faktoren (oben), lasse keinen aus! (unten)
- ▶ Folgen fehlender Faktoren: i.A. Verzerrung: **“junk in, junk out”**
- ▶ Folgen überflüssiger Faktoren: **keine Verzerrung, aber unnötig hohe Schätzfehler**
- ▶ Lösung: Tests, z.B. *F-test: ökonometrische Expertise nötig!*

11.2.1 Funktionale Spezifikation 1: relevante Faktoren




- ▶ Berücksichtige alle relevanten Faktoren (oben), lasse keinen aus! (unten)
- ▶ **Folgen fehlender Faktoren:** i.A. Verzerrung: **“junk in, junk out”**
- ▶ Folgen überflüssiger Faktoren: **keine Verzerrung, aber unnötig hohe Schätzfehler**
- ▶ **Lösung:** Tests, z.B. **F-test:** *ökonometrische Expertise nötig!*

11.2.1 Funktionale Spezifikation 1: relevante Faktoren




- ▶ Berücksichtige alle relevanten Faktoren (oben), lasse keinen aus! (unten)
- ▶ Folgen fehlender Faktoren: i.A. Verzerrung: **“junk in, junk out”**
- ▶ Folgen überflüssiger Faktoren: **keine Verzerrung, aber unnötig hohe Schätzfehler**
- ▶ Lösung: Tests, z.B. **F-test**: *ökonometrische Expertise nötig!*

11.2.1 Funktionale Spezifikation 1: relevante Faktoren

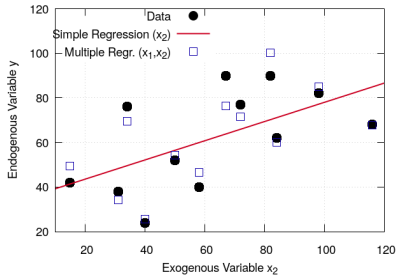
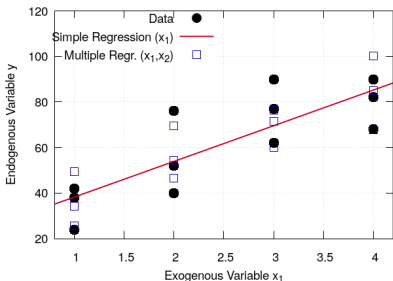


- ▶ Berücksichtige alle relevanten Faktoren (oben), lasse keinen aus! (unten)
- ▶ Folgen fehlender Faktoren: i.A. Verzerrung: **“junk in, junk out”**
- ▶ Folgen überflüssiger Faktoren: **keine Verzerrung, aber unnötig hohe Schätzfehler**
- ▶ Lösung: Tests, z.B. **F-test**: *ökonometrische Expertise nötig!*


Beispiel: Auslastung von Hotels




- ▶ $y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \epsilon$ mit den Faktoren $x_0 = 1$, x_1 : Proxy für Qualität [# stars]; x_2 : Preis [€/Nacht].
- ▶ Die exogenen Faktoren sind (nicht vollständig) korreliert: ✓
- ▶ Endogene Variable: Auslastung [%]
- ▶ Nachfrage ist positiv mit Qualität und Preis (!) korreliert



Effekt der Korrelationen zwischen den exogenen Variablen




Funktionale Spezifikation 2: Linearität




- ▶ Das Modell sollte linear sein (hier nicht erfüllt)
- ▶ Konsequenz: **“junk in, junk out”**
- ▶ Lösung: Nichtlineare Transformation der exogenen Variablen in **Faktoren**, bezüglich derer das Modell linear ist, hier z.B. $x'_0 = 1, x'_1 = 1/x, x'_2 = x^2$ or $x'_0 = 1, x'_1 = x, x'_2 = x^2$.

Funktionale Spezifikation 2: Linearität



- ▶ Das Modell sollte linear sein (hier nicht erfüllt)
- ▶ **Konsequenz: “junk in, junk out”**
- ▶ **Lösung:** Nichtlineare Transformation der exogenen Variablen in **Faktoren**, bezüglich derer das Modell linear ist, hier z.B. $x'_0 = 1, x'_1 = 1/x, x'_2 = x^2$ or $x'_0 = 1, x'_1 = x, x'_2 = x^2$.

Funktionale Spezifikation 2: Linearität



- ▶ Das Modell sollte linear sein (hier nicht erfüllt)
- ▶ **Konsequenz: “junk in, junk out”**
- ▶ **Lösung:** Nichtlineare Transformation der exogenen Variablen in **Faktoren**, bezüglich derer das Modell linear ist, hier z.B. $x'_0 = 1, x'_1 = 1/x, x'_2 = x^2$ or $x'_0 = 1, x'_1 = x, x'_2 = x^2$.

Beispiel: Kraftstoffverbrauch

Für einen konstanten Wirkungsgrad chemische \rightarrow mechanische Energie ist der für die Fortbewegung benötigte Verbrauch y (pro 100 km) proportional zum *Fahrwiderstand* mit den additiven Anteilen

- ▶ Rollreibung: Unabhängig von der Geschwindigkeit \tilde{x}_1 , proportional zur Masse \tilde{x}_2 .
- ▶ Luftwiderstand: proportional zur quadrierten Geschwindigkeit \tilde{x}_1^2 , unabhängig von der Masse
- ▶ Steigung: proportional zum Produkt aus Masse und Steigung \tilde{x}_3

Zusätzlich gibt es eine Basisverbrauchsrate (≈ 0.5 Liter/h) für Leerlauf, Heizung, Lüftung, Licht etc \Rightarrow Anteil proportional zu $1/\text{Geschwindigkeit} \Rightarrow$ Modell

$$y(x) = \sum_{j=1}^4 \beta_j x_j + \epsilon, \quad x_1 = \tilde{x}_2, \quad x_2 = \tilde{x}_1^2, \quad x_3 = \tilde{x}_2 \tilde{x}_3, \quad x_4 = \frac{1}{\tilde{x}_1}$$

Beispiel: Kraftstoffverbrauch

Für einen konstanten Wirkungsgrad chemische \rightarrow mechanische Energie ist der für die Fortbewegung benötigte Verbrauch y (pro 100 km) proportional zum *Fahrwiderstand* mit den additiven Anteilen

- ▶ Rollreibung: Unabhängig von der Geschwindigkeit \tilde{x}_1 , proportional zur Masse \tilde{x}_2 .
- ▶ Luftwiderstand: proportional zur quadrierten Geschwindigkeit \tilde{x}_1^2 , unabhängig von der Masse
- ▶ Steigung: proportional zum Produkt aus Masse und Steigung \tilde{x}_3

Zusätzlich gibt es eine Basisverbrauchsrate (≈ 0.5 Liter/h) für Leerlauf, Heizung, Lüftung, Licht etc \Rightarrow Anteil proportional zu $1/\text{Geschwindigkeit} \Rightarrow$ Modell

$$y(x) = \sum_{j=1}^4 \beta_j x_j + \epsilon, \quad x_1 = \tilde{x}_2, \quad x_2 = \tilde{x}_1^2, \quad x_3 = \tilde{x}_2 \tilde{x}_3, \quad x_4 = \frac{1}{\tilde{x}_1}$$

Beispiel: Kraftstoffverbrauch

Für einen konstanten Wirkungsgrad chemische \rightarrow mechanische Energie ist der für die Fortbewegung benötigte Verbrauch y (pro 100 km) proportional zum *Fahrwiderstand* mit den additiven Anteilen

- ▶ Rollreibung: Unabhängig von der Geschwindigkeit \tilde{x}_1 , proportional zur Masse \tilde{x}_2 .
- ▶ Luftwiderstand: proportional zur quadrierten Geschwindigkeit \tilde{x}_1^2 , unabhängig von der Masse
- ▶ Steigung: proportional zum Produkt aus Masse und Steigung \tilde{x}_3

Zusätzlich gibt es eine Basisverbrauchsrate (≈ 0.5 Liter/h) für Leerlauf, Heizung, Lüftung, Licht etc \Rightarrow Anteil proportional zu $1/\text{Geschwindigkeit} \Rightarrow$ Modell

$$y(x) = \sum_{j=1}^4 \beta_j x_j + \epsilon, \quad x_1 = \tilde{x}_2, \quad x_2 = \tilde{x}_1^2, \quad x_3 = \tilde{x}_2 \tilde{x}_3, \quad x_4 = \frac{1}{\tilde{x}_1}$$

Beispiel: Kraftstoffverbrauch

Für einen konstanten Wirkungsgrad chemische \rightarrow mechanische Energie ist der für die Fortbewegung benötigte Verbrauch y (pro 100 km) proportional zum *Fahrwiderstand* mit den additiven Anteilen

- ▶ Rollreibung: Unabhängig von der Geschwindigkeit \tilde{x}_1 , proportional zur Masse \tilde{x}_2 .
- ▶ Luftwiderstand: proportional zur quadrierten Geschwindigkeit \tilde{x}_1^2 , unabhängig von der Masse
- ▶ Steigung: proportional zum Produkt aus Masse und Steigung \tilde{x}_3

Zusätzlich gibt es eine Basisverbrauchsrate (≈ 0.5 Liter/h) für Leerlauf, Heizung, Lüftung, Licht etc \Rightarrow Anteil proportional zu $1/\text{Geschwindigkeit} \Rightarrow$ Model

$$y(x) = \sum_{j=1}^4 \beta_j x_j + \epsilon, \quad x_1 = \tilde{x}_2, \quad x_2 = \tilde{x}_1^2, \quad x_3 = \tilde{x}_2 \tilde{x}_3, \quad x_4 = \frac{1}{\tilde{x}_1}$$

Beispiel: Kraftstoffverbrauch


Für einen konstanten Wirkungsgrad chemische \rightarrow mechanische Energie ist der für die Fortbewegung benötigte Verbrauch y (pro 100 km) proportional zum *Fahrwiderstand* mit den additiven Anteilen

- ▶ Rollreibung: Unabhängig von der Geschwindigkeit \tilde{x}_1 , proportional zur Masse \tilde{x}_2 .
- ▶ Luftwiderstand: proportional zur quadrierten Geschwindigkeit \tilde{x}_1^2 , unabhängig von der Masse
- ▶ Steigung: proportional zum Produkt aus Masse und Steigung \tilde{x}_3

Zusätzlich gibt es eine Basisverbrauchsrate (≈ 0.5 Liter/h) für Leerlauf, Heizung, Lüftung, Licht etc \Rightarrow Anteil proportional zu $1/\text{Geschwindigkeit} \Rightarrow$ Model

$$y(\mathbf{x}) = \sum_{j=1}^4 \beta_j x_j + \epsilon, \quad x_1 = \tilde{x}_2, \quad x_2 = \tilde{x}_1^2, \quad x_3 = \tilde{x}_2 \tilde{x}_3, \quad x_4 = \frac{1}{\tilde{x}_1}$$

Transformation der endogenen Variable I




Eine Zeittransformation $\tilde{x} \rightarrow x = \exp(\tilde{x})$ würde zwar linearisieren, aber die Fluktuationen (Residualterme) sind nicht mehr i.i.d (\Rightarrow statistische Spezifikation)

Transformation der endogenen Variable II



Transformation der *endogenen* Variable $y \rightarrow u = \ln(y)$, $x = \tilde{x}$
gibt hingegen ein korrekt spezifiziertes Modell $u(x) = \beta_0 + \beta_1 x + \epsilon$, $\epsilon \sim \text{i.i.d.}$

Funktionale Spezifikation 3: Homogenität der Grundgesamtheit




- ▶ **Folgen einer Verletzung:** ein nichtberücksichtigter **Strukturbruch** im Raum der exogenen Variablen führt zu einer **Verzerrung: junk in, junk out**
- ▶ **Lösung:** *Dummyvariable* mit Werten 0 und 1 vor/nach dem Strukturbruch

? Möglicher Strukturbruch in obigem Plot?

!

1. neue Datenbasis (DDR+Westdeutschland → Deutschland); 2. Umdefinitionen, z.B. "ernsthaft verletzt" bedeutete vor dem Strukturbruch stationärer, danach ambulanter+stationärer Krankenhausaufenthalt

Funktionale Spezifikation 3: Homogenität der Grundgesamtheit




- ▶ **Folgen einer Verletzung:** ein nichtberücksichtigter **Strukturbruch** im Raum der exogenen Variablen führt zu einer **Verzerrung: junk in, junk out**
- ▶ **Lösung:** *Dummyvariable* mit Werten 0 und 1 vor/nach dem Strukturbruch

? Möglicher Strukturbruch in obigem Plot?

!

1. neue Datenbasis (DDR+Westdeutschland → Deutschland); 2. Umdefinitionen, z.B. "ernsthaft verletzt" bedeutete vor dem Strukturbruch stationärer, danach ambulanter+stationärer Krankenhausaufenthalt

Funktionale Spezifikation 3: Homogenität der Grundgesamtheit




- ▶ **Folgen einer Verletzung:** ein nichtberücksichtigter **Strukturbruch** im Raum der exogenen Variablen führt zu einer **Verzerrung: junk in, junk out**
 - ▶ **Lösung:** *Dummyvariable* mit Werten 0 und 1 vor/nach dem Strukturbruch
- ? Möglicher Strukturbruch in obigem Plot?

!

1. neue Datenbasis (DDR+Westdeutschland → Deutschland); 2. Umdefinitionen, z.B. "ernsthaft verletzt" bedeutete vor dem Strukturbruch stationärer, danach ambulanter+stationärer Krankenhausaufenthalt

Funktionale Spezifikation 3: Homogenität der Grundgesamtheit





- ▶ **Folgen einer Verletzung:** ein nichtberücksichtigter **Strukturbruch** im Raum der exogenen Variablen führt zu einer **Verzerrung: junk in, junk out**
 - ▶ **Lösung:** *Dummyvariable* mit Werten 0 und 1 vor/nach dem Strukturbruch
- ? Möglicher Strukturbruch in obigem Plot?

!

1. neue Datenbasis (DDR+Westdeutschland → Deutschland); 2. Umdefinitionen, z.B. "ernsthaft verletzt" bedeutete vor dem Strukturbruch stationärer, danach ambulanter+stationärer Krankenhausaufenthalt

11.2.2 Statistical Spezifikation



1. Residuum ϵ hat Erwartungswert null



- ▶ **Bedingung:** $E(\epsilon) = 0$.
- ▶ **Konsequenz:** keine: Die OLS- (KQ-) Kalibrierung/Schätzmethode berücksichtigt dies automatisch. Bei der diskreten Wahltheorie ist es sogar überhaupt nicht relevant (**Warum?**)



11.2.2 Statistical Spezifikation

1. Residuum ϵ hat Erwartungswert null





- ▶ **Bedingung:** $E(\epsilon) = 0$.
- ▶ **Konsequenz:** **keine:** Die OLS- (KQ-) Kalibrierung/Schätzmethode berücksichtigt dies automatisch. Bei der diskreten Wahltheorie ist es sogar überhaupt nicht relevant (**Warum?**)

Statistische Spezifikation 2: Homoskedastizität





- ▶ **Bedingung:** ϵ soll konstante Varianz haben (Homoskedastizität, rechts), keine variable (Heteroskedastizität, links)
- ▶ **Konsequenz:** bei Verletzung bleibt der KQ-Schätzer **unverzerrt, ist aber nicht mehr effizient** (ein relativ "milder" Fehler).
- ▶ **Lösung:** Fortgeschrittene Methoden wie gewichteter KQ-Schätzer. Ggf Transformation der abhängigen Variable (→ Dow-Jones-Beispiel)

Statistische Spezifikation 2: Homoskedastizität





- ▶ **Bedingung:** ϵ soll konstante Varianz haben (Homoskedastizität, rechts), keine variable (Heteroskedastizität, links)
- ▶ **Konsequenz:** bei Verletzung bleibt der KQ-Schätzer **unverzerrt, ist aber nicht mehr effizient** (ein relativ "milder" Fehler).
- ▶ **Lösung:** Fortgeschrittene Methoden wie gewichteter KQ-Schätzer. Ggf Transformation der abhängigen Variable (→ Dow-Jones-Beispiel)

Statistische Spezifikation 2: Homoskedastizität





- ▶ **Bedingung:** ϵ soll konstante Varianz haben (Homoskedastizität, rechts), keine variable (Heteroskedastizität, links)
- ▶ **Konsequenz:** bei Verletzung bleibt der KQ-Schätzer **unverzerrt, ist aber nicht mehr effizient** (ein relativ "milder" Fehler).
- ▶ **Lösung:** Fortgeschrittene Methoden wie gewichteter KQ-Schätzer. Ggf Transformation der abhängigen Variable (→ Dow-Jones-Beispiel)

Statistische Spezifikation 3: Korrelationsfreiheit der Residuen





- ▶ **Bedingung:** ϵ ist nicht bezüglich der x_i und/oder y korreliert (rechts). Die linke Modell-Daten-Kombination ist fehlspezifiziert
- ▶ **Konsequenz:** relativ **mild:** (KQ-Schätzer nicht efficient; Unterschätzung der Schätzfehler, evtl unbedeutende Verzerrung).
- ▶ **Lösung:** Identifiziere aus dem Sachverhalt einen nichtberücksichtigten systematischen Einfluss, z.B. Periodizität

Statistische Spezifikation 3: Korrelationsfreiheit der Residuen





- ▶ **Bedingung:** ϵ ist nicht bezüglich der x_i und/oder y korreliert (rechts). Die linke Modell-Daten-Kombination ist fehlspezifiziert
- ▶ **Konsequenz:** relativ **mild:** (KQ-Schätzer nicht efficient; Unterschätzung der Schätzfehler, evtl unbedeutende Verzerrung).
- ▶ **Lösung:** Identifiziere aus dem Sachverhalt einen nichtberücksichtigten systematischen Einfluss, z.B. Periodizität

Statistische Spezifikation 3: Korrelationsfreiheit der Residuen



- ▶ **Bedingung:** ϵ ist nicht bezüglich der x_i und/oder y korreliert (rechts). Die linke Modell-Daten-Kombination ist fehlspezifiziert
- ▶ **Konsequenz:** relativ **mild:** (KQ-Schätzer nicht effizient; Unterschätzung der Schätzfehler, evtl unbedeutende Verzerrung).
- ▶ **Lösung:** Identifiziere aus dem Sachverhalt einen nichtberücksichtigten systematischen Einfluss, z.B. Periodizität



Statistische Spezifikation 4: Gaußverteilte Residuen



- ▶ **Bedingung:** $\epsilon \sim N(0, \sigma^2)$ (rechts), nicht anders verteilt (links).
- ▶ **Konsequenz:** eine Verletzung hat **sehr milde** Konsequenzen. Der KQ-Schätzer bleibt unverzerrt *und* effizient, nur die üblichen Fehlerabschätzungen und Tests sind falsch, vor allem bei kleinen Fehlerwahrscheinlichkeiten α
- ▶ Alle vier statistischen Spezifikationen zusammen:

$\epsilon \sim \text{i.i.d.} N(0, \sigma^2)$ i.i.d.: identical independent distributions



Statistische Spezifikation 4: Gaußverteilte Residuen



- ▶ **Bedingung:** $\epsilon \sim N(0, \sigma^2)$ (rechts), nicht anders verteilt (links).
- ▶ **Konsequenz:** eine Verletzung hat **sehr milde** Konsequenzen. Der KQ-Schätzer bleibt unverzerrt *und* effizient, nur die üblichen Fehlerabschätzungen und Tests sind falsch, vor allem bei kleinen Fehlerwahrscheinlichkeiten α
- ▶ Alle vier statistischen Spezifikationen zusammen:

$\epsilon \sim \text{i.i.d. } N(0, \sigma^2)$ i.i.d.: identical independent distributions

Statistische Spezifikation 4: Gaußverteilte Residuen



- ▶ **Bedingung:** $\epsilon \sim N(0, \sigma^2)$ (rechts), nicht anders verteilt (links).
- ▶ **Konsequenz:** eine Verletzung hat **sehr milde** Konsequenzen. Der KQ-Schätzer bleibt unverzerrt *und* effizient, nur die üblichen Fehlerabschätzungen und Tests sind falsch, vor allem bei kleinen Fehlerwahrscheinlichkeiten α
- ▶ Alle vier statistischen Spezifikationen zusammen:

$\epsilon \sim \text{i.i.d.} N(0, \sigma^2)$ i.i.d.: **identical independent distributions**

Datenspezifikation 1: genug Daten

- ▶ Jeder Datensatz muss *alle* endogenen und exogenen Variablen enthalten und es muss mehr Datensätze als Parameter geben: $n > J + 1$. Die Daten müssen das Modell also *überbestimmen*
- ▶ **Konsequenz einer Verletzung:** Falls $n = J + 1$, kann das Modell *exakt* ohne Fehler an die Daten angepasst werden: $\epsilon_i = 0$ bzw. *overfitting*. Dennoch **harmlos**, da der KQ-Schätzer und andere Tests einen "0/0-Fehler" auswerfen. Bei $n < J + 1$ wird darüberhinaus eine Inversion einer singulären Matrix versucht
- ▶ **Konsequenz einer Erfüllung "gerade so":** Falls es nur wenig mehr Datensätze als Parameter gibt, also wenig **Freiheitsgrade** verbleiben, ist der Schätzer unverzerrt und effizient, aber hat **großen Schätzfehler**
- ▶ **Lösung:** Mehr Daten ...

Datenspezifikation 1: genug Daten

- ▶ Jeder Datensatz muss *alle* endogenen und exogenen Variablen enthalten und es muss mehr Datensätze als Parameter geben: $n > J + 1$. Die Daten müssen das Modell also *überbestimmen*
- ▶ **Konsequenz einer Verletzung:** Falls $n = J + 1$, kann das Modell *exakt* ohne Fehler an die Daten angepasst werden: $\epsilon_i = 0$ bzw. *overfitting*. Dennoch **harmlos**, da der KQ-Schätzer und andere Tests einen “0/0-Fehler” auswerfen. Bei $n < J + 1$ wird darüberhinaus eine Inversion einer singulären Matrix versucht
- ▶ **Konsequenz einer Erfüllung “gerade so”:** Falls es nur wenig mehr Datensätze als Parameter gibt, also wenig **Freiheitsgrade** verbleiben, ist der Schätzer unverzerrt und effizient, aber hat **großen Schätzfehler**
- ▶ **Lösung:** Mehr Daten ...



Datenspezifikation 1: genug Daten

- ▶ Jeder Datensatz muss *alle* endogenen und exogenen Variablen enthalten und es muss mehr Datensätze als Parameter geben: $n > J + 1$. Die Daten müssen das Modell also *überbestimmen*
- ▶ **Konsequenz einer Verletzung:** Falls $n = J + 1$, kann das Modell *exakt* ohne Fehler an die Daten angepasst werden: $\epsilon_i = 0$ bzw. *overfitting*. Dennoch **harmlos**, da der KQ-Schätzer und andere Tests einen “0/0-Fehler” auswerfen. Bei $n < J + 1$ wird darüberhinaus eine Inversion einer singulären Matrix versucht
- ▶ **Konsequenz einer Erfüllung “gerade so”:** Falls es nur wenig mehr Datensätze als Parameter gibt, also wenig **Freiheitsgrade** verbleiben, ist der Schätzer unverzerrt und effizient, aber hat **großen Schätzfehler**
- ▶ **Lösung:** Mehr Daten ...

Datenspezifikation 1: genug Daten

- ▶ Jeder Datensatz muss *alle* endogenen und exogenen Variablen enthalten und es muss mehr Datensätze als Parameter geben: $n > J + 1$. Die Daten müssen das Modell also *überbestimmen*
- ▶ **Konsequenz einer Verletzung:** Falls $n = J + 1$, kann das Modell *exakt* ohne Fehler an die Daten angepasst werden: $\epsilon_i = 0$ bzw. *overfitting*. Dennoch **harmlos**, da der KQ-Schätzer und andere Tests einen “0/0-Fehler” auswerfen. Bei $n < J + 1$ wird darüberhinaus eine Inversion einer singulären Matrix versucht
- ▶ **Konsequenz einer Erfüllung “gerade so”:** Falls es nur wenig mehr Datensätze als Parameter gibt, also wenig **Freiheitsgrade** verbleiben, ist der Schätzer unverzerrt und effizient, aber hat **großen Schätzfehler**
- ▶ **Lösung:** Mehr Daten ...



Datenspezifikation 2: Keine Multi-Kollinearität



- ▶ Multikollinearität → Mindestens eine exogene Variable kann *in allen Datensätzen* als Linearkombination anderer Variablen angegeben werden. Die Datenmatrix ist damit *singulär*.
- ▶ Nichtperfekte Korrelationen hingegen sind ausdrücklich erlaubt
- ▶ Nichtperfekte Korrelationen sind häufig, z.B. Preis vs. Qualität (**Vorzeichen?**)
- ▶ Konsequenz einer Verletzung: der KQ-Schätzer "entdeckt" für Sie eine Verletzung automatisch: "0/0"-Fehler. Nahezu perfekte Kollinearität ⇒ **große Schätzfehler**

Sind alle Kriterien aus allen drei Spezifikationen erfüllt, sagt man, dass das ökonometrische Problem die Gauß-Markov Annahmen erfüllt


Datenspezifikation 2: Keine Multi-Kolarität



- ▶ Multikolarität → Mindestens eine exogene Variable kann *in allen Datensätzen* als Linearkombination anderer Variablen angegeben werden. Die Datenmatrix ist damit *singulär*.
- ▶ Nichtperfekte Korrelationen hingegen sind ausdrücklich erlaubt
- ▶ Nichtperfekte Korrelationen sind häufig, z.B. Preis vs. Qualität (**Vorzeichen?**)
- ▶ Konsequenz einer verletzung: der KQ-Schätzer **"entdeckt"** für Sie **eine Verletzung automatisch**: "0/0"-Fehler. Nahezu perfekte Kolarität ⇒ **große Schätzfehler**

Sind alle Kriterien aus allen drei Spezifikationen erfüllt, sagt man, dass das ökonometrische Problem die **Gauß-Markov Annahmen** erfüllt


Datenspezifikation 2: Keine Multi-Kolarität



- ▶ Multikolarität \rightarrow Mindestens eine exogene Variable kann *in allen Datensätzen* als Linearkombination anderer Variablen angegeben werden. Die Datenmatrix ist damit *singulär*.
- ▶ Nichtperfekte Korrelationen hingegen sind ausdrücklich erlaubt
- ▶ Nichtperfekte Korrelationen sind häufig, z.B. Preis vs. Qualität (**Vorzeichen?**)
- ▶ Konsequenz einer Verletzung: der KQ-Schätzer **“entdeckt”** für Sie **eine Verletzung automatisch**: “0/0”-Fehler. Nahezu perfekte Kolarität \Rightarrow **große Schätzfehler**

Sind alle Kriterien aus allen drei Spezifikationen erfüllt, sagt man, dass das ökonometrische Problem die **Gauß-Markov Annahmen** erfüllt


Datenspezifikation 2: Keine Multi-Kolarität



- ▶ Multikolarität → Mindestens eine exogene Variable kann *in allen Datensätzen* als Linearkombination anderer Variablen angegeben werden. Die Datenmatrix ist damit *singulär*.
- ▶ Nichtperfekte Korrelationen hingegen sind ausdrücklich erlaubt
- ▶ Nichtperfekte Korrelationen sind häufig, z.B. Preis vs. Qualität (**Vorzeichen?**)
- ▶ **Konsequenz einer verletzung:** der KQ-Schätzer **“entdeckt” für Sie eine Verletzung automatisch:** “0/0”-Fehler. Nahezu perfekte Kolarität ⇒ **große Schätzfehler**

Sind alle Kriterien aus allen drei Spezifikationen erfüllt, sagt man, dass das ökonometrische Problem die **Gauß-Markov Annahmen** erfüllt

Datenspezifikation 2: Keine Multi-Kolarität



- ▶ Multikolarität → Mindestens eine exogene Variable kann *in allen Datensätzen* als Linearkombination anderer Variablen angegeben werden. Die Datenmatrix ist damit *singulär*.
- ▶ Nichtperfekte Korrelationen hingegen sind ausdrücklich erlaubt
- ▶ Nichtperfekte Korrelationen sind häufig, z.B. Preis vs. Qualität (**Vorzeichen?**)
- ▶ **Konsequenz einer verletzung:** der KQ-Schätzer **“entdeckt” für Sie eine Verletzung automatisch:** “0/0”-Fehler. Nahezu perfekte Kolarität ⇒ **große Schätzfehler**

Sind alle Kriterien aus allen drei Spezifikationen erfüllt, sagt man, dass das ökonometrische Problem die **Gauß-Markov Annahmen** erfüllt

Wie entdeckt man Multi-Kolinearität?

- ▶ Gegeben: n Datensätze $\{x_{i0}, \dots, x_{ij}, \dots, x_{iJ}\}$, $i = 1, \dots, n$ (die Datensätze enthalten auch y_i , aber das ist hier nicht relevant)
- ▶ x_{ij} ist der j^{th} Faktor im Datensatz i
- ▶ Multikollinearität ist gegeben, wenn man einen Faktor x_k als Linearkombination aus allen anderen Faktoren *für alle Datensätze* ausdrücken kann:

$$x_{ik} = \sum_{j \neq k} c_j x_{ij} \quad \forall i = 1, \dots, n, \quad \text{konstante Koeffizienten } c_j$$

- ▶ Bei zwei Variablen ist dies leicht: $x_2 = c_0 x_1$ bzw Korrelationskoeffizient ist $=1$ oder $=-1$. Bei mehreren Variablen gilt das nicht.
- ▶ Lösung: Check, ob die **deskriptive Varianz-Kovarianz-Matrix**

$$S_{jk} = \frac{1}{n} \sum_{i=1}^n (x_{ij} - \bar{x}_j)(x_{ik} - \bar{x}_k)$$

den vollen Rang $J + 1$ hat bzw. $\det \mathbf{S} \neq 0$

- ▶ Für $n < J + 1$ ist das trivialerweise nicht erfüllt

Wie entdeckt man Multi-Kollinearität?

- ▶ Gegeben: n Datensätze $\{x_{i0}, \dots, x_{ij}, \dots, x_{iJ}\}$, $i = 1, \dots, n$ (die Datensätze enthalten auch y_i , aber das ist hier nicht relevant)
- ▶ x_{ij} ist der j^{th} Faktor im Datensatz i
- ▶ Multikollinearität ist gegeben, wenn man einen Faktor x_k als Linearkombination aus allen anderen Faktoren *für alle Datensätze* ausdrücken kann:

$$x_{ik} = \sum_{j \neq k} c_j x_{ij} \quad \forall i = 1, \dots, n, \quad \text{konstante Koeffizienten } c_j$$

- ▶ Bei zwei Variablen ist dies leicht: $x_2 = c_0 x_1$ bzw Korrelationskoeffizient ist $=1$ oder $=-1$. Bei mehreren Variablen gilt das nicht.
- ▶ Lösung: Check, ob die **deskriptive Varianz-Kovarianz-Matrix**

$$S_{jk} = \frac{1}{n} \sum_{i=1}^n (x_{ij} - \bar{x}_j)(x_{ik} - \bar{x}_k)$$

den vollen Rang $J + 1$ hat bzw. $\det \mathbf{S} \neq 0$

- ▶ Für $n < J + 1$ ist das trivialerweise nicht erfüllt

Wie entdeckt man Multi-Kolinearität?

- ▶ Gegeben: n Datensätze $\{x_{i0}, \dots, x_{ij}, \dots, x_{iJ}\}$, $i = 1, \dots, n$ (die Datensätze enthalten auch y_i , aber das ist hier nicht relevant)
- ▶ x_{ij} ist der j^{th} Faktor im Datensatz i
- ▶ Multikollinearität ist gegeben, wenn man einen Faktor x_k als Linearkombination aus allen anderen Faktoren *für alle Datensätze* ausdrücken kann:

$$x_{ik} = \sum_{j \neq k} c_j x_{ij} \quad \forall i = 1, \dots, n, \quad \text{konstante Koeffizienten } c_j$$

- ▶ Bei zwei Variablen ist dies leicht: $x_2 = c_0 x_1$ bzw Korrelationskoeffizient ist $=1$ oder $= -1$. Bei mehreren Variablen gilt das nicht.
- ▶ Lösung: Check, ob die **deskriptive Varianz-Kovarianz-Matrix**

$$S_{jk} = \frac{1}{n} \sum_{i=1}^n (x_{ij} - \bar{x}_j)(x_{ik} - \bar{x}_k)$$

den vollen Rang $J + 1$ hat bzw. $\det \mathbf{S} \neq 0$

- ▶ Für $n < J + 1$ ist das trivialerweise nicht erfüllt

Wie entdeckt man Multi-Kollinearität?

- ▶ Gegeben: n Datensätze $\{x_{i0}, \dots, x_{ij}, \dots, x_{iJ}\}$, $i = 1, \dots, n$ (die Datensätze enthalten auch y_i , aber das ist hier nicht relevant)
- ▶ x_{ij} ist der j^{th} Faktor im Datensatz i
- ▶ Multikollinearität ist gegeben, wenn man einen Faktor x_k als Linearkombination aus allen anderen Faktoren *für alle Datensätze* ausdrücken kann:

$$x_{ik} = \sum_{j \neq k} c_j x_{ij} \quad \forall i = 1, \dots, n, \quad \text{konstante Koeffizienten } c_j$$

- ▶ Bei zwei Variablen ist dies leicht: $x_2 = c_0 x_1$ bzw Korrelationskoeffizient ist $=1$ oder $=-1$. Bei mehreren Variablen gilt das nicht.
- ▶ Lösung: Check, ob die **deskriptive Varianz-Kovarianz-Matrix**

$$S_{jk} = \frac{1}{n} \sum_{i=1}^n (x_{ij} - \bar{x}_j)(x_{ik} - \bar{x}_k)$$

den vollen Rang $J + 1$ hat bzw. $\det \mathbf{S} \neq 0$

- ▶ Für $n < J + 1$ ist das trivialerweise nicht erfüllt

Wie entdeckt man Multi-Kolinearität?

- ▶ Gegeben: n Datensätze $\{x_{i0}, \dots, x_{ij}, \dots, x_{iJ}\}$, $i = 1, \dots, n$ (die Datensätze enthalten auch y_i , aber das ist hier nicht relevant)
- ▶ x_{ij} ist der j^{th} Faktor im Datensatz i
- ▶ Multikollinearität ist gegeben, wenn man einen Faktor x_k als Linearkombination aus allen anderen Faktoren *für alle Datensätze* ausdrücken kann:

$$x_{ik} = \sum_{j \neq k} c_j x_{ij} \quad \forall i = 1, \dots, n, \quad \text{konstante Koeffizienten } c_j$$


- ▶ Bei zwei Variablen ist dies leicht: $x_2 = c_0 x_1$ bzw Korrelationskoeffizient ist $=1$ oder $= -1$. Bei mehreren Variablen gilt das nicht.
- ▶ Lösung: Check, ob die **deskriptive Varianz-Kovarianz-Matrix**

$$S_{jk} = \frac{1}{n} \sum_{i=1}^n (x_{ij} - \bar{x}_j)(x_{ik} - \bar{x}_k)$$

den vollen Rang $J + 1$ hat bzw. $\det \mathbf{S} \neq 0$


- ▶ Für $n < J + 1$ ist das trivialerweise nicht erfüllt

Datenspezifikation 2: Beispiel




- ▶ Die Nachfrage y_i für den ÖPNV in den Städten i hängt vom Preis x_{i1} und der Qualität x_{i2} (Proxy: Haustür-zu-Haustür-Geschwindigkeit) ab.
- ▶ Parameter: Achsabschnitt (*intercept*) β_0 , Preissensitivität β_1 , Qualitätsbewusstsein β_2
- ▶ Preis und Qualität sind (*wie bei fast allen Produkten und Dienstleistungen*) korreliert, aber unvollständig: OK

Datenspezifikation 2: Beispiel



- ▶ Die Nachfrage y_i für den ÖPNV in den Städten i hängt vom Preis x_{i1} und der Qualität x_{i2} (Proxy: Haustür-zu-Haustür-Geschwindigkeit) ab.
- ▶ Parameter: Achsabschnitt (*intercept*) β_0 , Preissensitivität β_1 , Qualitätsbewusstsein β_2
- ▶ Preis und Qualität sind (*wie bei fast allen Produkten und Dienstleistungen*) korreliert, aber unvollständig: OK

Datenspezifikation 2: Beispiel



- ▶ Die Nachfrage y_i für den ÖPNV in den Städten i hängt vom Preis x_{i1} und der Qualität x_{i2} (Proxy: Haustür-zu-Haustür-Geschwindigkeit) ab.
- ▶ Parameter: Achsabschnitt (*intercept*) β_0 , Preissensitivität β_1 , Qualitätsbewusstsein β_2
- ▶ Preis und Qualität sind (*wie bei fast allen Produkten und Dienstleistungen*) korreliert, aber unvollständig: OK

11.3 Kleinste-Fehlerquadrate (KQ) Schätzung

- ▶ Gegeben: lineares Modell der Form

$$y(\mathbf{x}) = \beta' \mathbf{x} + \epsilon = \hat{y}(\mathbf{x}) + \epsilon, \quad \epsilon \sim i.i.d.$$

welches *alle Gauß-Markow-Annahmen mit Ausnahme der gaußverteilten Residualterme* erfüllt

- ▶ Gegeben sind ebenfalls n vollständige Datensätze aller exogenen Faktoren und der endogenen Variablen, welche die Datenspezifikation erfüllen:

$$\{\mathbf{p}_i = (x_{i0}, \dots, x_{iJ}, y_i)'\}, \quad i = 1, \dots, n\}$$

- ▶ Gesucht ist ein Parameterschätzer $\hat{\beta}$, welcher die Fehlerquadratsumme zwischen den deterministischen Modellvoraussagen $\mathbf{x}_i' \beta$ und der beobachteten endogenen Variable y_i bezüglich der Parameter minimiert:

$$\hat{\beta} = \arg \min_{\beta} S(\beta)$$

wobei

$$S(\beta) = \epsilon' \epsilon = (\mathbf{y} - \mathbf{X} \beta)' (\mathbf{y} - \mathbf{X} \beta).$$

11.3 Kleinste-Fehlerquadrate (KQ) Schätzung

- ▶ Gegeben: lineares Modell der Form

$$y(\mathbf{x}) = \boldsymbol{\beta}'\mathbf{x} + \epsilon = \hat{y}(\mathbf{x}) + \epsilon, \quad \epsilon \sim i.i.d.$$

welches *alle Gauß-Markow-Annahmen mit Ausnahme der gaußverteilten Residualterme* erfüllt

- ▶ Gegeben sind ebenfalls n vollständige Datensätze aller exogenen Faktoren und der endogenen Variablen, welche die Datenspezifikation erfüllen:

$$\{\mathbf{p}_i = (x_{i0}, \dots, x_{iJ}, y_i)'\}, \quad i = 1, \dots, n\}$$

- ▶ Gesucht ist ein Parameterschätzer $\hat{\boldsymbol{\beta}}$, welcher die Fehlerquadratsumme zwischen den deterministischen Modellvoraussagen $\mathbf{x}'_i\boldsymbol{\beta}$ und der beobachteten endogenen Variable y_i bezüglich der Parameter minimiert:

$$\hat{\boldsymbol{\beta}} = \arg \min_{\boldsymbol{\beta}} S(\boldsymbol{\beta})$$

wobei

$$S(\boldsymbol{\beta}) = \boldsymbol{\epsilon}'\boldsymbol{\epsilon} = (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})'(\mathbf{y} - \mathbf{X}\boldsymbol{\beta}).$$

11.3 Kleinste-Fehlerquadrate (KQ) Schätzung

- ▶ Gegeben: lineares Modell der Form

$$y(\mathbf{x}) = \boldsymbol{\beta}'\mathbf{x} + \epsilon = \hat{y}(\mathbf{x}) + \epsilon, \quad \epsilon \sim i.i.d.$$

welches *alle Gauß-Markow-Annahmen mit Ausnahme der gaußverteilten Residualterme* erfüllt

- ▶ Gegeben sind ebenfalls n vollständige Datensätze aller exogenen Faktoren und der endogenen Variablen, welche die Datenspezifikation erfüllen:

$$\{\mathbf{p}_i = (x_{i0}, \dots, x_{iJ}, y_i)'\}, \quad i = 1, \dots, n\}$$

- ▶ Gesucht ist ein Parameterschätzer $\hat{\boldsymbol{\beta}}$, welcher die Fehlerquadratsumme zwischen den deterministischen Modellvoraussagen $\mathbf{x}'_i\boldsymbol{\beta}$ und der beobachteten endogenen Variable y_i bezüglich der Parameter minimiert:

$$\hat{\boldsymbol{\beta}} = \arg \min_{\boldsymbol{\beta}} S(\boldsymbol{\beta})$$

wobei

$$S(\boldsymbol{\beta}) = \boldsymbol{\epsilon}'\boldsymbol{\epsilon} = (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})'(\mathbf{y} - \mathbf{X}\boldsymbol{\beta}).$$

11.3 Kleinste-Fehlerquadrate (KQ) Schätzung

- ▶ Gegeben: lineares Modell der Form

$$y(\mathbf{x}) = \boldsymbol{\beta}'\mathbf{x} + \epsilon = \hat{y}(\mathbf{x}) + \epsilon, \quad \epsilon \sim i.i.d.$$

welches *alle Gauß-Markow-Annahmen mit Ausnahme der gaußverteilten Residualterme* erfüllt

- ▶ Gegeben sind ebenfalls n vollständige Datensätze aller exogenen Faktoren und der endogenen Variablen, welche die Datenspezifikation erfüllen:

$$\{\mathbf{p}_i = (x_{i0}, \dots, x_{iJ}, y_i)'\}, \quad i = 1, \dots, n\}$$

- ▶ Gesucht ist ein Parameterschätzer $\hat{\boldsymbol{\beta}}$, welcher die Fehlerquadratsumme zwischen den deterministischen Modellvoraussagen $\mathbf{x}'_i\boldsymbol{\beta}$ und der beobachteten endogenen Variable y_i bezüglich der Parameter minimiert:

$$\hat{\boldsymbol{\beta}} = \arg \min_{\boldsymbol{\beta}} S(\boldsymbol{\beta})$$

wobei

$$S(\boldsymbol{\beta}) = \boldsymbol{\epsilon}'\boldsymbol{\epsilon} = (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})'(\mathbf{y} - \mathbf{X}\boldsymbol{\beta}).$$

Bestimmung des KQ-Schätzers

$$S = (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})'(\mathbf{y} - \mathbf{X}\boldsymbol{\beta})$$

Bestimmung des KQ-Schätzers

$$\begin{aligned} S &= (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})' (\mathbf{y} - \mathbf{X}\boldsymbol{\beta}) \\ \text{[Distributivität } \rightarrow] &= \mathbf{y}'\mathbf{y} - (\mathbf{X}\boldsymbol{\beta})'\mathbf{y} - \mathbf{y}'\mathbf{X}\boldsymbol{\beta} + (\mathbf{X}\boldsymbol{\beta})'\mathbf{X}\boldsymbol{\beta} \end{aligned}$$

Bestimmung des KQ-Schätzers

$$S = (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})' (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})$$

$$\text{[Distributivität } \rightarrow] = \mathbf{y}'\mathbf{y} - (\mathbf{X}\boldsymbol{\beta})'\mathbf{y} - \mathbf{y}'\mathbf{X}\boldsymbol{\beta} + (\mathbf{X}\boldsymbol{\beta})'\mathbf{X}\boldsymbol{\beta}$$

$$\text{[Transpositionsregeln } \rightarrow] = \mathbf{y}'\mathbf{y} - \boldsymbol{\beta}'\mathbf{X}'\mathbf{y} - \mathbf{y}'\mathbf{X}\boldsymbol{\beta} + \boldsymbol{\beta}'\mathbf{X}'\mathbf{X}\boldsymbol{\beta}$$

Bestimmung des KQ-Schätzers

$$\begin{aligned} S &= (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})' (\mathbf{y} - \mathbf{X}\boldsymbol{\beta}) \\ \text{[Distributivität } \rightarrow] &= \mathbf{y}'\mathbf{y} - (\mathbf{X}\boldsymbol{\beta})'\mathbf{y} - \mathbf{y}'\mathbf{X}\boldsymbol{\beta} + (\mathbf{X}\boldsymbol{\beta})'\mathbf{X}\boldsymbol{\beta} \\ \text{[Transpositionsregeln } \rightarrow] &= \mathbf{y}'\mathbf{y} - \boldsymbol{\beta}'\mathbf{X}'\mathbf{y} - \mathbf{y}'\mathbf{X}\boldsymbol{\beta} + \boldsymbol{\beta}'\mathbf{X}'\mathbf{X}\boldsymbol{\beta} \\ \text{[Transpositionsregeln } \rightarrow] &= \mathbf{y}'\mathbf{y} - 2\boldsymbol{\beta}'(\mathbf{X}'\mathbf{y}) + \boldsymbol{\beta}'(\mathbf{X}'\mathbf{X})\boldsymbol{\beta} \end{aligned}$$

Bestimmung des KQ-Schätzers

$$\begin{aligned} S &= (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})' (\mathbf{y} - \mathbf{X}\boldsymbol{\beta}) \\ \text{[Distributivität } \rightarrow] &= \mathbf{y}'\mathbf{y} - (\mathbf{X}\boldsymbol{\beta})'\mathbf{y} - \mathbf{y}'\mathbf{X}\boldsymbol{\beta} + (\mathbf{X}\boldsymbol{\beta})'\mathbf{X}\boldsymbol{\beta} \\ \text{[Transpositionsregeln } \rightarrow] &= \mathbf{y}'\mathbf{y} - \boldsymbol{\beta}'\mathbf{X}'\mathbf{y} - \mathbf{y}'\mathbf{X}\boldsymbol{\beta} + \boldsymbol{\beta}'\mathbf{X}'\mathbf{X}\boldsymbol{\beta} \\ \text{[Transpositionsregeln } \rightarrow] &= \mathbf{y}'\mathbf{y} - 2\boldsymbol{\beta}'(\mathbf{X}'\mathbf{y}) + \boldsymbol{\beta}'(\mathbf{X}'\mathbf{X})\boldsymbol{\beta} \end{aligned}$$

Ableiten nach $\boldsymbol{\beta}$ und Nullsetzen mit den Regeln $\frac{\partial}{\partial \boldsymbol{\beta}}(\boldsymbol{\beta}'\mathbf{a}) = \mathbf{a}$ und $\frac{\partial}{\partial \boldsymbol{\beta}}(\boldsymbol{\beta}'\mathbf{A}\boldsymbol{\beta}) = (\mathbf{A} + \mathbf{A}')\boldsymbol{\beta}$, wobei $\mathbf{A} = \mathbf{X}'\mathbf{X}$:

Bestimmung des KQ-Schätzers

$$\begin{aligned}
 S &= (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})' (\mathbf{y} - \mathbf{X}\boldsymbol{\beta}) \\
 \text{[Distributivität } \rightarrow] &= \mathbf{y}'\mathbf{y} - (\mathbf{X}\boldsymbol{\beta})'\mathbf{y} - \mathbf{y}'\mathbf{X}\boldsymbol{\beta} + (\mathbf{X}\boldsymbol{\beta})'\mathbf{X}\boldsymbol{\beta} \\
 \text{[Transpositionsregeln } \rightarrow] &= \mathbf{y}'\mathbf{y} - \boldsymbol{\beta}'\mathbf{X}'\mathbf{y} - \mathbf{y}'\mathbf{X}\boldsymbol{\beta} + \boldsymbol{\beta}'\mathbf{X}'\mathbf{X}\boldsymbol{\beta} \\
 \text{[Transpositionsregeln } \rightarrow] &= \mathbf{y}'\mathbf{y} - 2\boldsymbol{\beta}'(\mathbf{X}'\mathbf{y}) + \boldsymbol{\beta}'(\mathbf{X}'\mathbf{X})\boldsymbol{\beta}
 \end{aligned}$$

Ableiten nach $\boldsymbol{\beta}$ und Nullsetzen mit den Regeln $\frac{\partial}{\partial \boldsymbol{\beta}}(\boldsymbol{\beta}'\mathbf{a}) = \mathbf{a}$ und $\frac{\partial}{\partial \boldsymbol{\beta}}(\boldsymbol{\beta}'\mathbf{A}\boldsymbol{\beta}) = (\mathbf{A} + \mathbf{A}')\boldsymbol{\beta}$, wobei $\mathbf{A} = \mathbf{X}'\mathbf{X}$:

$$\frac{\partial S(\boldsymbol{\beta})}{\partial \boldsymbol{\beta}} = 0 - 2\mathbf{X}'\mathbf{y} + 2\mathbf{X}'\mathbf{X}\boldsymbol{\beta} \stackrel{!}{=} 0$$

Bestimmung des KQ-Schätzers

$$\begin{aligned} S &= (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})' (\mathbf{y} - \mathbf{X}\boldsymbol{\beta}) \\ \text{[Distributivität } \rightarrow] &= \mathbf{y}'\mathbf{y} - (\mathbf{X}\boldsymbol{\beta})'\mathbf{y} - \mathbf{y}'\mathbf{X}\boldsymbol{\beta} + (\mathbf{X}\boldsymbol{\beta})'\mathbf{X}\boldsymbol{\beta} \\ \text{[Transpositionsregeln } \rightarrow] &= \mathbf{y}'\mathbf{y} - \boldsymbol{\beta}'\mathbf{X}'\mathbf{y} - \mathbf{y}'\mathbf{X}\boldsymbol{\beta} + \boldsymbol{\beta}'\mathbf{X}'\mathbf{X}\boldsymbol{\beta} \\ \text{[Transpositionsregeln } \rightarrow] &= \mathbf{y}'\mathbf{y} - 2\boldsymbol{\beta}'(\mathbf{X}'\mathbf{y}) + \boldsymbol{\beta}'(\mathbf{X}'\mathbf{X})\boldsymbol{\beta} \end{aligned}$$

Ableiten nach $\boldsymbol{\beta}$ und Nullsetzen mit den Regeln $\frac{\partial}{\partial \boldsymbol{\beta}}(\boldsymbol{\beta}'\mathbf{a}) = \mathbf{a}$ und $\frac{\partial}{\partial \boldsymbol{\beta}}(\boldsymbol{\beta}'\mathbf{A}\boldsymbol{\beta}) = (\mathbf{A} + \mathbf{A}')\boldsymbol{\beta}$, wobei $\mathbf{A} = \mathbf{X}'\mathbf{X}$:

$$\frac{\partial S(\boldsymbol{\beta})}{\partial \boldsymbol{\beta}} = 0 - 2\mathbf{X}'\mathbf{y} + 2\mathbf{X}'\mathbf{X}\boldsymbol{\beta} \stackrel{!}{=} 0$$

$$\mathbf{X}'\mathbf{X}\boldsymbol{\beta} = \mathbf{X}'\mathbf{y}$$

Bestimmung des KQ-Schätzers

$$\begin{aligned} S &= (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})' (\mathbf{y} - \mathbf{X}\boldsymbol{\beta}) \\ \text{[Distributivität } \rightarrow] &= \mathbf{y}'\mathbf{y} - (\mathbf{X}\boldsymbol{\beta})'\mathbf{y} - \mathbf{y}'\mathbf{X}\boldsymbol{\beta} + (\mathbf{X}\boldsymbol{\beta})'\mathbf{X}\boldsymbol{\beta} \\ \text{[Transpositionsregeln } \rightarrow] &= \mathbf{y}'\mathbf{y} - \boldsymbol{\beta}'\mathbf{X}'\mathbf{y} - \mathbf{y}'\mathbf{X}\boldsymbol{\beta} + \boldsymbol{\beta}'\mathbf{X}'\mathbf{X}\boldsymbol{\beta} \\ \text{[Transpositionsregeln } \rightarrow] &= \mathbf{y}'\mathbf{y} - 2\boldsymbol{\beta}'(\mathbf{X}'\mathbf{y}) + \boldsymbol{\beta}'(\mathbf{X}'\mathbf{X})\boldsymbol{\beta} \end{aligned}$$

Ableiten nach $\boldsymbol{\beta}$ und Nullsetzen mit den Regeln $\frac{\partial}{\partial \boldsymbol{\beta}}(\boldsymbol{\beta}'\mathbf{a}) = \mathbf{a}$ und $\frac{\partial}{\partial \boldsymbol{\beta}}(\boldsymbol{\beta}'\mathbf{A}\boldsymbol{\beta}) = (\mathbf{A} + \mathbf{A}')\boldsymbol{\beta}$, wobei $\mathbf{A} = \mathbf{X}'\mathbf{X}$:

$$\frac{\partial S(\boldsymbol{\beta})}{\partial \boldsymbol{\beta}} = 0 - 2\mathbf{X}'\mathbf{y} + 2\mathbf{X}'\mathbf{X}\boldsymbol{\beta} \stackrel{!}{=} 0$$

$$\mathbf{X}'\mathbf{X}\boldsymbol{\beta} = \mathbf{X}'\mathbf{y} \quad | \cdot (\mathbf{X}'\mathbf{X})^{-1}$$

Bestimmung des KQ-Schätzers

$$\begin{aligned} S &= (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})' (\mathbf{y} - \mathbf{X}\boldsymbol{\beta}) \\ \text{[Distributivität } \rightarrow] &= \mathbf{y}'\mathbf{y} - (\mathbf{X}\boldsymbol{\beta})'\mathbf{y} - \mathbf{y}'\mathbf{X}\boldsymbol{\beta} + (\mathbf{X}\boldsymbol{\beta})'\mathbf{X}\boldsymbol{\beta} \\ \text{[Transpositionsregeln } \rightarrow] &= \mathbf{y}'\mathbf{y} - \boldsymbol{\beta}'\mathbf{X}'\mathbf{y} - \mathbf{y}'\mathbf{X}\boldsymbol{\beta} + \boldsymbol{\beta}'\mathbf{X}'\mathbf{X}\boldsymbol{\beta} \\ \text{[Transpositionsregeln } \rightarrow] &= \mathbf{y}'\mathbf{y} - 2\boldsymbol{\beta}'(\mathbf{X}'\mathbf{y}) + \boldsymbol{\beta}'(\mathbf{X}'\mathbf{X})\boldsymbol{\beta} \end{aligned}$$

Ableiten nach $\boldsymbol{\beta}$ und Nullsetzen mit den Regeln $\frac{\partial}{\partial \boldsymbol{\beta}}(\boldsymbol{\beta}'\mathbf{a}) = \mathbf{a}$ und $\frac{\partial}{\partial \boldsymbol{\beta}}(\boldsymbol{\beta}'\mathbf{A}\boldsymbol{\beta}) = (\mathbf{A} + \mathbf{A}')\boldsymbol{\beta}$, wobei $\mathbf{A} = \mathbf{X}'\mathbf{X}$:

$$\frac{\partial S(\boldsymbol{\beta})}{\partial \boldsymbol{\beta}} = 0 - 2\mathbf{X}'\mathbf{y} + 2\mathbf{X}'\mathbf{X}\boldsymbol{\beta} \stackrel{!}{=} 0$$

$$\mathbf{X}'\mathbf{X}\boldsymbol{\beta} = \mathbf{X}'\mathbf{y} \quad | \cdot (\mathbf{X}'\mathbf{X})^{-1}$$

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y}$$