

Zeitreihen

Statistik II

Wiederholung

Literatur

Zeitreihen

Zeitreihen-Daten

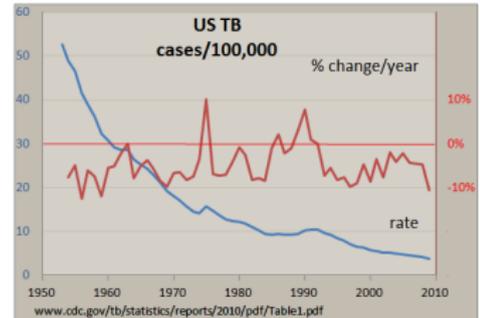
Modelle

Probleme

Trends und Saisonalität

Fehlerstruktur

Zusammenfassung



Wiederholung

Literatur

Zeitreihen

Zeitreihen-Daten

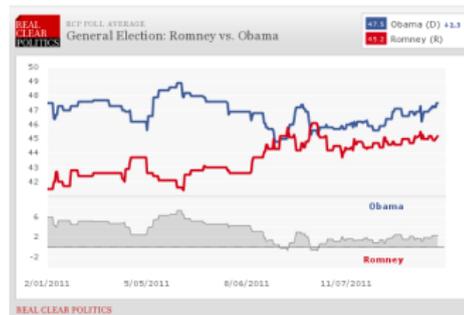
Modelle

Probleme

Trends und Saisonalität

Fehlerstruktur

Zusammenfassung



Zum Nachlesen

- ▶ Wooldridge ch 10.1 & 10.2

Für nächste Woche

- ▶ *Einfache* Modelle für Paneldaten
- ▶ Wooldridge ch. 13.1-13.4 (im Reader)

Was sind Zeitreihen?

- ▶ Bisher: „Fälle“
- ▶ Länder, Parteien, Städte, Personen . . .
- ▶ Unabhängig voneinander erhoben, in der Regel durch Zufallsverfahren aus Population (Grundgesamtheit) ausgewählt
- ▶ Jeder Fall hat Ordnungsnummer (Index) n : $y_1, y_5, y_{27}, y_n \dots$
- ▶ *Reihenfolge im Datensatz beliebig*

Was sind Zeitreihen?

- ▶ Bisher: „Fälle“
- ▶ Länder, Parteien, Städte, Personen . . .
- ▶ Unabhängig voneinander erhoben, in der Regel durch Zufallsverfahren aus Population (Grundgesamtheit) ausgewählt
- ▶ Jeder Fall hat Ordnungsnummer (Index) n : $y_1, y_5, y_{27}, y_n \dots$
- ▶ *Reihenfolge im Datensatz beliebig*
- ▶ Datenmatrix kann umsortiert werden (Spalten und Zeilen)

Inwiefern sind Zeitreihen anders?

- ▶ Zeitreihen beziehen sich auf **ein** Objekt (z. B. ein politisches System)
- ▶ Beobachtungen sind **nicht** voneinander unabhängig

Inwiefern sind Zeitreihen anders?

- ▶ Zeitreihen beziehen sich auf **ein** Objekt (z. B. ein politisches System)
- ▶ Beobachtungen sind **nicht** voneinander unabhängig
- ▶ Reihenfolge der Beobachtungen im Datensatz ist nicht beliebig, sondern durch Kalenderzeit vorgegeben
- ▶ Spalten der Datenmatrix können umsortiert werden, Zeilen nicht

Inwiefern sind Zeitreihen anders?

- ▶ Zeitreihen beziehen sich auf **ein** Objekt (z. B. ein politisches System)
- ▶ Beobachtungen sind **nicht** voneinander unabhängig
- ▶ Reihenfolge der Beobachtungen im Datensatz ist nicht beliebig, sondern durch Kalenderzeit vorgegeben
- ▶ Spalten der Datenmatrix können umsortiert werden, Zeilen nicht
- ▶ Beobachtungen haben Ordnungsnummer (Index) t , beginnend mit $t = 1$ (erste Beobachtung)
- ▶ Abstände zwischen Beobachtungen sind (normalerweise) gleich groß

Abstände

- ▶ Typischerweise an Kalenderzeit orientiert
- ▶ In der Politikwissenschaft gängige Abstände:
 - ▶ Tage
 - ▶ Wochen
 - ▶ Monate
 - ▶ Quartale

- ▶ Jahre
- ▶ (Legislaturperioden)

Abstände

- ▶ Typischerweise an Kalenderzeit orientiert
- ▶ In der Politikwissenschaft gängige Abstände:
 - ▶ Tage (tracking polls im Wahlkampf)
 - ▶ Wochen
 - ▶ Monate
 - ▶ Quartale

- ▶ Jahre
- ▶ (Legislaturperioden)

Abstände

- ▶ Typischerweise an Kalenderzeit orientiert
- ▶ In der Politikwissenschaft gängige Abstände:
 - ▶ Tage (tracking polls im Wahlkampf)
 - ▶ Wochen (Anzahl terroristischer Anschläge im Irak)
 - ▶ Monate
 - ▶ Quartale

- ▶ Jahre
- ▶ (Legislaturperioden)

Abstände

- ▶ Typischerweise an Kalenderzeit orientiert
- ▶ In der Politikwissenschaft gängige Abstände:
 - ▶ Tage (tracking polls im Wahlkampf)
 - ▶ Wochen (Anzahl terroristischer Anschläge im Irak)
 - ▶ Monate (Anteil der Parteiidentifizierer in Deutschland)
 - ▶ Quartale

- ▶ Jahre
- ▶ (Legislaturperioden)

Abstände

- ▶ Typischerweise an Kalenderzeit orientiert
- ▶ In der Politikwissenschaft gängige Abstände:
 - ▶ Tage (tracking polls im Wahlkampf)
 - ▶ Wochen (Anzahl terroristischer Anschläge im Irak)
 - ▶ Monate (Anteil der Parteiidentifizierer in Deutschland)
 - ▶ Quartale (Wirtschaftsleistung und Zufriedenheit mit US-Präsident)
 - ▶ Jahre
 - ▶ (Legislaturperioden)

Abstände

- ▶ Typischerweise an Kalenderzeit orientiert
- ▶ In der Politikwissenschaft gängige Abstände:
 - ▶ Tage (tracking polls im Wahlkampf)
 - ▶ Wochen (Anzahl terroristischer Anschläge im Irak)
 - ▶ Monate (Anteil der Parteiidentifizierer in Deutschland)
 - ▶ Quartale (Wirtschaftsleistung und Zufriedenheit mit US-Präsident)
 - ▶ Jahre (Zustimmung zur EU und politische Variablen)
 - ▶ (Legislaturperioden)

Abstände

- ▶ Typischerweise an Kalenderzeit orientiert
- ▶ In der Politikwissenschaft gängige Abstände:
 - ▶ Tage (tracking polls im Wahlkampf)
 - ▶ Wochen (Anzahl terroristischer Anschläge im Irak)
 - ▶ Monate (Anteil der Parteiidentifizierer in Deutschland)
 - ▶ Quartale (Wirtschaftsleistung und Zufriedenheit mit US-Präsident)
 - ▶ Jahre (Zustimmung zur EU und politische Variablen)
 - ▶ (Legislaturperioden) (Entwicklung von Parteiprogrammen über die Zeit)

Abstände

- ▶ Typischerweise an Kalenderzeit orientiert
- ▶ In der Politikwissenschaft gängige Abstände:
 - ▶ Tage (tracking polls im Wahlkampf)
 - ▶ Wochen (Anzahl terroristischer Anschläge im Irak)
 - ▶ Monate (Anteil der Parteiidentifizierer in Deutschland)
 - ▶ Quartale (Wirtschaftsleistung und Zufriedenheit mit US-Präsident)
 - ▶ Jahre (Zustimmung zur EU und politische Variablen)
 - ▶ (Legislaturperioden) (Entwicklung von Parteiprogrammen über die Zeit)
- ▶ Beispiel: US-Präsident 1949-85

Presidential Approval & Unemployment

Presidential Approval

„Do you approve or disapprove of the way is handling his job as President?“

Presidential Approval & Unemployment

Presidential Approval

„Do you approve or disapprove of the way is handling his job as President?“

→ Wieviel Prozent Zustimmung zur Amtsführung?

Presidential Approval & Unemployment

Presidential Approval

„Do you approve or disapprove of the way is handling his job as President?“

→ Wieviel Prozent Zustimmung zur Amtsführung?

% Approval	% Unemployed	Kalenderzeit	<i>t</i>
⋮	⋮	⋮	⋮
69.7	2.8	1953q1	17
73.0	2.7	1953q2	18
74.0	2.6	1953q3	19
⋮	⋮	⋮	⋮

Lags und Leads

- ▶ Lag: Wert aus Vergangenheit (früherer Zeitpunkt)
- ▶ (Lead: Wert aus Zukunft)

Lags und Leads

- ▶ Lag: Wert aus Vergangenheit (früherer Zeitpunkt)
- ▶ (Lead: Wert aus Zukunft)
- ▶ Bsp.: Zum Zeitpunkt $t = 19$
 - ▶ Ist das erste Lag der Arbeitslosenquote (Vorquartal, $t - 1$) = 2.7
 - ▶ Das zweite Lag der Arbeitslosenquote ($t - 2$) = 2.8

% Unemployed	Kalenderzeit	t
⋮	⋮	⋮
2.8	1953q1	17
2.7	1953q2	18
2.6	1953q3	19
⋮	⋮	⋮

Wie kommen Zeitreihen zustande?

- ▶ „Normale“ Regression (über Stichproben)
 1. Stichprobe wird zufällig aus Grundgesamtheit ausgewählt
 2. Eine Stichprobe, die auch anders aussehen könnte
 3. Mathematisches Modell der Stichprobenziehung → Inferenzstatistik
 4. Rückschluß auf wahre Parameter in Grundgesamtheit

Wie kommen Zeitreihen zustande?

- ▶ „Normale“ Regression (über Stichproben)
 1. Stichprobe wird zufällig aus Grundgesamtheit ausgewählt
 2. Eine Stichprobe, die auch anders aussehen könnte
 3. Mathematisches Modell der Stichprobenziehung → Inferenzstatistik
 4. Rückschluß auf wahre Parameter in Grundgesamtheit
- ▶ Zeitreihenanalyse
 1. „Datengenerierender Prozeß“ (DGP) erzeugt historischen Ablauf
 2. Eine Zeitreihe, die auch anders hätte aussehen können
 3. Mathematisches Modell des Prozesses (Inferenzstatistik)
 4. Rückschluß auf wahre Parameter des Prozesses

Wie kommen Zeitreihen zustande?

- ▶ „Normale“ Regression (über Stichproben)
 1. Stichprobe wird zufällig aus Grundgesamtheit ausgewählt
 2. Eine Stichprobe, die auch anders aussehen könnte
 3. Mathematisches Modell der Stichprobenziehung → Inferenzstatistik
 4. Rückschluß auf wahre Parameter in Grundgesamtheit
- ▶ Zeitreihenanalyse
 1. „Datengenerierender Prozeß“ (DGP) erzeugt historischen Ablauf
 2. Eine Zeitreihe, die auch anders hätte aussehen können
 3. Mathematisches Modell des Prozesses (Inferenzstatistik)
 4. Rückschluß auf wahre Parameter des Prozesses
- ▶ **Stärkere Annahmen, u. a. über Stabilität des DGP**

Statisches Modell

- ▶ Lineare Beziehung zwischen y und x
- ▶ Schätzung des Modells
 - ▶ Nicht auf Grundlage von unabhängigen Fällen
 - ▶ Sondern auf Grundlage von zeitlich gestaffelten Beobachtungen am selben Objekt (z. B. USA)
 - ▶ Veränderungen in x haben **unmittelbaren** Effekt auf y
 - ▶ Unemployment \rightarrow approval (economic voting)

Statisches Modell

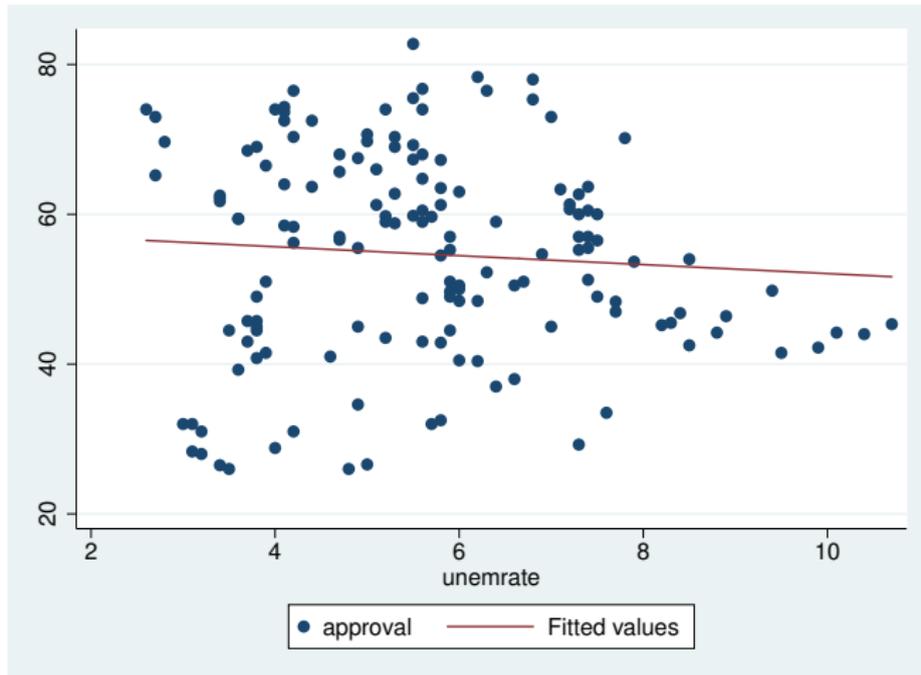
- ▶ Lineare Beziehung zwischen y und x
- ▶ Schätzung des Modells
 - ▶ Nicht auf Grundlage von unabhängigen Fällen
 - ▶ Sondern auf Grundlage von zeitlich gestaffelten Beobachtungen am selben Objekt (z. B. USA)
 - ▶ Veränderungen in x haben **unmittelbaren** Effekt auf y
 - ▶ Unemployment \rightarrow approval (economic voting)

Statisches Modell

$$\text{approval}_t = \beta_0 + \beta_1 \text{unemployment}_t + \epsilon_t$$

$$y_t = \beta_0 + \beta_1 x_{1,t} + \epsilon_t$$

Lineare Beziehung x und y



Implikation statisches Modell

```
. reg approval unemrate
```

Source	SS	df	MS			
Model	159.716707	1	159.716707		Number of obs =	148
Residual	27291.3802	146	186.927262		F(1, 146) =	0.85
					Prob > F =	0.3568
					R-squared =	0.0058
					Adj R-squared =	-0.0010
					Root MSE =	13.672
Total	27451.0969	147	186.742156			

approval	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
unemrate	-.5973806	.6462674	-0.92	0.357	-1.874628	.6798672
_cons	58.05901	3.814606	15.22	0.000	50.52003	65.59799

- ▶ Zu jedem Zeitpunkt $t \dots$
- ▶ Ist Zustimmung zur Amtsführung eine lineare Funktion der ALQ ($58 - 0.6 \times \text{unemrate}$)
- ▶ Z. B. Zunahme ALQ um zwei Prozentpunkte

Implikation statisches Modell

```
. reg approval unemrate
```

Source	SS	df	MS			
Model	159.716707	1	159.716707		Number of obs =	148
Residual	27291.3802	146	186.927262		F(1, 146) =	0.85
					Prob > F =	0.3568
					R-squared =	0.0058
					Adj R-squared =	-0.0010
					Root MSE =	13.672
Total	27451.0969	147	186.742156			

approval	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
unemrate	-.5973806	.6462674	-0.92	0.357	-1.874628	.6798672
_cons	58.05901	3.814606	15.22	0.000	50.52003	65.59799

- ▶ Zu jedem Zeitpunkt t ...
- ▶ Ist Zustimmung zur Amtsführung eine lineare Funktion der ALQ ($58 - 0.6 \times \text{unemrate}$)
- ▶ Z. B. Zunahme ALQ um zwei Prozentpunkte \rightarrow *sofortige* Abnahme Zustimmung um 1.2 Punkte
- ▶ Plausibel?

(Finite) Distributed Lag Model

- ▶ Veränderungen in x brauchen Zeit, um auf y zu wirken
- ▶ y eine Funktion von x heute plus vergangene 1, 2, ... Werte von x (Lags)
- ▶ Anzahl der vergangenen Zeitpunkte, die wir berücksichtigen können, endlich (finit)
- ▶ Im Text: andere Bezeichnung für Koeffizienten der Lags, um Sache klarer zu machen

(Finite) Distributed Lag Model

FDL mit zwei Lags

$$\begin{aligned}y_t &= \beta_0 + \delta_0 x_t + \delta_1 x_{t-1} + \delta_2 x_{t-2} + \epsilon_t \\ \text{approval}_t &= \beta_0 + \delta_0 \text{unemployment}_t \\ &\quad + \delta_1 \text{unemployment}_{t-1} \\ &\quad + \delta_2 \text{unemployment}_{t-2} \\ &\quad + \epsilon_t\end{aligned}$$

(Finite) Distributed Lag Model

- ▶ Temporäre Zunahme der Arbeitslosigkeit Zeitpunkt $t \rightarrow$ Effekt erst drei Quartale später ($t + 3$) abgeklungen
- ▶ δ_0 : impact propensity oder impact multiplier
- ▶ Permanente Zunahme der Arbeitslosigkeit: (Permanente) Veränderung von y braucht drei Quartale um sich aufzubauen
- ▶ Graphische Darstellung von $\delta_0, \delta_1, \delta_2$: Verteilung (distributed lag model)
- ▶ Gesamteffekt der Veränderung: Summe von $\delta_0, \delta_1, \delta_2$: long-run propensity oder long-run multiplier

(Finite) Distributed Lag Model

```
. tset date
      time variable: date, 1949q1 to 1985q4
      delta: 1 quarter

. reg approval unemrate L1.unemrate L2.unemrate
```

Source	SS	df	MS			
Model	230.998447	3	76.9994822	Number of obs =	146	
Residual	27008.0761	142	190.197719	F(3, 142) =	0.40	
				Prob > F =	0.7497	
				R-squared =	0.0085	
				Adj R-squared =	-0.0125	
Total	27239.0745	145	187.855687	Root MSE =	13.791	

approval	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
unemrate						
--	-2.674135	3.030339	-0.88	0.379	-8.664543	3.316273
L1.	3.164792	5.24657	0.60	0.547	-7.206685	13.53627
L2.	-1.029905	2.999669	-0.34	0.732	-6.959683	4.899873
_cons	57.63794	4.031501	14.30	0.000	49.66843	65.60746

- ▶ Langfristiger Gesamteffekt einer Zunahme der ALQ um einen Punkt?

(Finite) Distributed Lag Model

```
. tset date
      time variable: date, 1949q1 to 1985q4
      delta: 1 quarter

. reg approval unemrate L1.unemrate L2.unemrate
```

Source	SS	df	MS			
Model	230.998447	3	76.9994822	Number of obs =	146	
Residual	27008.0761	142	190.197719	F(3, 142) =	0.40	
Total	27239.0745	145	187.855687	Prob > F =	0.7497	
				R-squared =	0.0085	
				Adj R-squared =	-0.0125	
				Root MSE =	13.791	

approval	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
unemrate						
--.	-2.674135	3.030339	-0.88	0.379	-8.664543	3.316273
L1.	3.164792	5.24657	0.60	0.547	-7.206685	13.53627
L2.	-1.029905	2.999669	-0.34	0.732	-6.959683	4.899873
_cons	57.63794	4.031501	14.30	0.000	49.66843	65.60746

- ▶ Langfristiger Gesamteffekt einer Zunahme der ALQ um einen Punkt?
- ▶ $-2.67 + 3.16 - 1.03 = -0.54$

Approval & unemployment: lags

```
. list date approval unemrate L1.unemrate L2.unemrate in 1/8, clean
```

	date	approval	unemrate	L. unemrate	L2. unemrate
1.	1949q1	69	3.8	.	.
2.	1949q2	57	4.7	3.8	.
3.	1949q3	57	5.9	4.7	3.8
4.	1949q4	51	6.7	5.9	4.7
5.	1950q1	45	7	6.7	5.9
6.	1950q2	37	6.4	7	6.7
7.	1950q3	43	5.6	6.4	7
8.	1950q4	41	4.6	5.6	6.4

Verzögerter Effekt der Arbeitslosigkeit

- ▶ Annahme: Modell ist korrekt, d. h.

$$\text{approval}_t = 57.6 - 2.6 \times \text{alq}_t + 3.2 \times \text{alq}_{t-1} - 1 \times \text{alq}_{t-2}$$

- ▶ ALQ einmalig 4 Prozent, sonst 2

Verzögerter Effekt der Arbeitslosigkeit

- ▶ Annahme: Modell ist korrekt, d. h.

$$\text{approval}_t = 57.6 - 2.6 \times \text{alq}_t + 3.2 \times \text{alq}_{t-1} - 1 \times \text{alq}_{t-2}$$

- ▶ ALQ einmalig 4 Prozent, sonst 2

	date	approval	alq	L. alq	L2. alq
7.	7	56.8	2	2	2
8.	8	56.8	2	2	2
9.	9	56.8	2	2	2
10.	10	51.6	4	2	2
11.	11	63.2	2	4	2
12.	12	54.8	2	2	4
13.	13	56.8	2	2	2
14.	14	56.8	2	2	2

Verzögerter Effekt der Arbeitslosigkeit

- ▶ Annahme: Modell ist korrekt, d. h.

$$\text{approval}_t = 57.6 - 2.6 \times \text{alq}_t + 3.2 \times \text{alq}_{t-1} - 1 \times \text{alq}_{t-2}$$

- ▶ ALQ 2 Prozent, dann dauerhafter Anstieg auf 4 Prozent

Verzögerter Effekt der Arbeitslosigkeit

- ▶ Annahme: Modell ist korrekt, d. h.

$$\text{approval}_t = 57.6 - 2.6 \times \text{alq}_t + 3.2 \times \text{alq}_{t-1} - 1 \times \text{alq}_{t-2}$$

- ▶ ALQ 2 Prozent, dann dauerhafter Anstieg auf 4 Prozent

	date	approval	alq	L. alq	L2. alq
7.	7	56.8	2	2	2
8.	8	56.8	2	2	2
9.	9	56.8	2	2	2
10.	10	51.6	4	2	2
11.	11	58	4	4	2
12.	12	56	4	4	4
13.	13	56	4	4	4
14.	14	56	4	4	4

Trends

- ▶ Annahme: die beobachteten x und y Werte werden zufällig vom DGP hervorgebracht
- ▶ Deshalb können wir sie ähnlich wie Stichprobe behandeln
- ▶ Tatsächlich: Trends
- ▶ Beispiel
 - ▶ x und y nehmen beide über Zeit zu
 - ▶ Regression von y auf x zeigt positiven Effekt, selbst wenn Korrelation 0 oder schwach negativ
- ▶ Drittvariablenproblem → Drittvariablenkontrolle durch Einschluß Kalenderzeit
- ▶ Beispiel: Presidential Approval und Verbraucherpreise (CPI)

Presidential Approval und CPI

```
. reg approval cpi
```

Source	SS	df	MS
Model	1719.69082	1	1719.69082
Residual	25731.4061	146	176.242507
Total	27451.0969	147	186.742156

```
Number of obs = 148  
F( 1, 146) = 9.76  
Prob > F = 0.0022  
R-squared = 0.0626  
Adj R-squared = 0.0562  
Root MSE = 13.276
```

approval	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
cpi	-.1348399	.0431667	-3.12	0.002	-.2201522	-.0495277
_cons	60.95396	2.283144	26.70	0.000	56.44168	65.46624

Presidential Approval und CPI

```
. reg approval date
```

Source	SS	df	MS
Model	1632.71801	1	1632.71801
Residual	25818.3789	146	176.838212
Total	27451.0969	147	186.742156

```
Number of obs = 148  
F( 1, 146) = 9.23  
Prob > F = 0.0028  
R-squared = 0.0595  
Adj R-squared = 0.0530  
Root MSE = 13.298
```

approval	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
date	-.0777434	.0255856	-3.04	0.003	-.1283094	-.0271774
_cons	56.98289	1.32836	42.90	0.000	54.35759	59.60819

```
. reg cpi date
```

Source	SS	df	MS
Model	73781.978	1	73781.978
Residual	20801.062	146	142.473028
Total	94583.0401	147	643.422041

```
Number of obs = 148  
F( 1, 146) = 517.87  
Prob > F = 0.0000  
R-squared = 0.7801  
Adj R-squared = 0.7786  
Root MSE = 11.936
```

cpi	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
date	.5226165	.0229654	22.76	0.000	.4772289	.5680041
_cons	31.0416	1.192323	26.03	0.000	28.68515	33.39804

Presidential Approval und CPI

```
. reg approval cpi date
```

Source	SS	df	MS
Model	1784.67952	2	892.339761
Residual	25666.4174	145	177.009775
Total	27451.0969	147	186.742156

```
Number of obs = 148  
F( 2, 145) = 5.04  
Prob > F = 0.0076  
R-squared = 0.0650  
Adj R-squared = 0.0521  
Root MSE = 13.305
```

approval	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
cpi	-.085472	.0922478	-0.93	0.356	-.267796	.0968519
date	-.0330743	.0545846	-0.61	0.546	-.1409586	.07481
_cons	59.63608	3.156895	18.89	0.000	53.3966	65.87555

Presidential Approval und CPI

```
. reg approval cpi
```

Source	SS	df	MS
Model	1719.69082	1	1719.69082
Residual	25731.4061	146	176.242507
Total	27451.0969	147	186.742156

```
Number of obs = 148  
F( 1, 146) = 9.76  
Prob > F = 0.0022  
R-squared = 0.0626  
Adj R-squared = 0.0562  
Root MSE = 13.276
```

approval	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
cpi	-.1348399	.0431667	-3.12	0.002	-.2201522	-.0495277
_cons	60.95396	2.283144	26.70	0.000	56.44168	65.46624

Presidential Approval und CPI

```
. reg approval cpi date
```

Source	SS	df	MS			
Model	1784.67952	2	892.339761	Number of obs =	148	
Residual	25666.4174	145	177.009775	F(2, 145) =	5.04	
Total	27451.0969	147	186.742156	Prob > F =	0.0076	

	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
approval						
cpi	-.085472	.0922478	-0.93	0.356	-.267796	.0968519
date	-.0330743	.0545846	-0.61	0.546	-.1409586	.07481
_cons	59.63608	3.156895	18.89	0.000	53.3966	65.87555

- ▶ Effekt des CPI nur halb so stark und nicht mehr signifikant, wenn für gemeinsamen Trend kontrolliert wird
- ▶ Kontrolle für Trends
 - ▶ Entweder separate Regressionen von x und y auf Zeit, dann Regression mit Residuen rechnen
 - ▶ Oder einfach multivariate Regression
 - ▶ Äquivalent

Saisonalität

- ▶ In vielen ökonomischen Zeitreihen Saisonalität (Zyklen)
 - ▶ Arbeitslosigkeit im Winter höher
 - ▶ Mehr Autos, Fahrräder etc. verkauft im Sommer
 - ▶ Anstieg Ölpreis im Herbst
- ▶ Saisonalität in politikwissenschaftlichen Zeitreihen weniger klar, aber
 - ▶ Midterm-Effekt in amerikanischen Wahlen
 - ▶ Beliebtheit der Regierungsparteien in Deutschland über BTW-Wahlzyklus
 - ▶ Häufung von Terrorakten zu Jahrestagen/Festen
- ▶ Ggf. z. B. durch Dummies modellieren, um Verzerrungen zu vermeiden

Saisonalität: CPI und Approval

```
. reg cpi _I* date
```

Source	SS	df	MS			
Model	73783.4552	4	18445.8638	Number of obs =	148	
Residual	20799.5849	143	145.451643	F(4, 143) =	126.82	
Total	94583.0401	147	643.422041	Prob > F =	0.0000	
				R-squared =	0.7801	
				Adj R-squared =	0.7739	
				Root MSE =	12.06	

cpi	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
_Iquarter_2	.1125771	2.804067	0.04	0.968	-5.4302	5.655354
_Iquarter_3	.2359647	2.804355	0.08	0.933	-5.307382	5.779311
_Iquarter_4	.2431365	2.804835	0.09	0.931	-5.301159	5.787432
date	.5225581	.0232122	22.51	0.000	.4766747	.5684414
_cons	30.8954	2.086516	14.81	0.000	26.771	35.0198

Saisonalität: CPI und Approval

```
. reg cpi _I* date
```

Source	SS	df	MS			
Model	73783.4552	4	18445.8638	Number of obs = 148		
Residual	20799.5849	143	145.451643	F(4, 143) = 126.82		
Total	94583.0401	147	643.422041	Prob > F = 0.0000		
				R-squared = 0.7801		
				Adj R-squared = 0.7739		
				Root MSE = 12.06		

cpi	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
_Iquarter_2	.1125771	2.804067	0.04	0.968	-5.4302	5.655354
_Iquarter_3	.2359647	2.804355	0.08	0.933	-5.307382	5.779311
_Iquarter_4	.2431365	2.804835	0.09	0.931	-5.301159	5.787432
date	.5225581	.0232122	22.51	0.000	.4766747	.5684414
_cons	30.8954	2.086516	14.81	0.000	26.771	35.0198

```
. reg approval honeymoon date
```

Source	SS	df	MS			
Model	2688.40949	2	1344.20475	Number of obs = 148		
Residual	24762.6874	145	170.777155	F(2, 145) = 7.87		
Total	27451.0969	147	186.742156	Prob > F = 0.0006		
				R-squared = 0.0979		
				Adj R-squared = 0.0855		
				Root MSE = 13.068		

approval	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
honeymoon	12.58499	5.061734	2.49	0.014	2.580679	22.5893
date	-.0791643	.0251498	-3.15	0.002	-.1288719	-.0294567
_cons	56.42957	1.324231	42.61	0.000	53.81228	59.04686

Recap: Schätzverfahren

Welche Eigenschaften sollen Schätzverfahren haben?

1. Möglichst unverzerrt (wenig bias)
2. Möglichst wenig Varianz der Schätzungen (relative Effizienz)
3. Konsistenz (durch größere Fallzahlen beliebig kleine Abweichungen von wahren Werten)

Recap: Schätzverfahren

Welche Eigenschaften sollen Schätzverfahren haben?

1. Möglichst unverzerrt (wenig bias)
2. Möglichst wenig Varianz der Schätzungen (relative Effizienz)
3. Konsistenz (durch größere Fallzahlen beliebig kleine Abweichungen von wahren Werten)

Recap: Schätzverfahren

Welche Eigenschaften sollen Schätzverfahren haben?

1. **Möglichst unverzerrt (wenig bias)**
2. Möglichst wenig Varianz der Schätzungen (relative Effizienz)
3. Konsistenz (durch größere Fallzahlen beliebig kleine Abweichungen von wahren Werten)
 - ▶ Wiederholte Stichprobenziehung (Umfang n) \rightarrow zufällige Verteilung von Schätzungen
 - ▶ Mittelwert der Schätzungen stimmt mit wahren Parameter in Grundgesamtheit überein
 - ▶ Systematische Abweichung: bias (Mittelwert \neq wahrer Parameter)

Recap: Schätzverfahren

Welche Eigenschaften sollen Schätzverfahren haben?

1. Möglichst unverzerrt (wenig bias)
 2. Möglichst wenig Varianz der Schätzungen (relative Effizienz)
 3. Konsistenz (durch größere Fallzahlen beliebig kleine Abweichungen von wahren Werten)
- ▶ Wiederholte Stichprobenziehung (Umfang n) \rightarrow zufällige Verteilung von Schätzungen
 - ▶ Unter verschiedenen Schätzverfahren das mit der geringsten Streuung der Schätzungen auswählen
 - ▶ (Relativ) effizientes Verfahren

Recap: Schätzverfahren

Welche Eigenschaften sollen Schätzverfahren haben?

1. **Möglichst unverzerrt (wenig bias)**
2. **Möglichst wenig Varianz der Schätzungen (relative Effizienz)**
3. Konsistenz (durch größere Fallzahlen beliebig kleine Abweichungen von wahren Werten)
 - ▶ Trade-off zwischen Effizienz und möglichst wenig bias
 - ▶ Gemeinsame Größe Mean Squared Error (MSE)
 - ▶ $(\text{MSE}) = (\text{bias}(\hat{\beta}))^2 + \text{Varianz}(\hat{\beta})$

Recap: Schätzverfahren

Welche Eigenschaften sollen Schätzverfahren haben?

1. Möglichst unverzerrt (wenig bias)
 2. Möglichst wenig Varianz der Schätzungen (relative Effizienz)
 3. **Konsistenz (durch größere Fallzahlen beliebig kleine Abweichungen von wahren Werten)**
- ▶ Was passiert bei steigendem Stichprobenumfang?
 - ▶ Hinreichende Bedingung für Konsistenz
 - ▶ Wenn Stichprobenumfang gegen ∞ geht
 - ▶ Gehen bias und Varianz der Schätzungen gegen null
 - ▶ D. h. die Wahrscheinlichkeit einer relevanten Abweichung zwischen Schätzung und wahren Wert geht gegen null

Recap: Voraussetzungen für OLS

- ▶ Wann ist OLS unverzerrt, effizient und konsistent?
- ▶ (Gauß-Markov-Bedingungen):
 1. y intervallskaliert und unbeschränkt, Varianz aller x , keine perfekte Multikollinearität
 2. Keine Autokorrelation der zufälligen Einflüsse ϵ , d. h. für zwei Beobachtungen i und h sind ϵ_i und ϵ_h bei wiederholter Stichprobenziehung unkorreliert
 3. Kein Zusammenhang zwischen ϵ und x -Variablen, d. h.
 - 3.1 Konditionaler Mittelwert von $\epsilon = 0$ für alle Werte von x
 - 3.2 Konstante konditionale Varianz von ϵ (Homoskedastizität) für alle Werte von x
 4. (Normalverteilung von ϵ – wird nur für Berechnung Standardfehler gebraucht, kein Problem bei großen Stichproben)
- ▶ OLS = BLUE: Best Linear Unbiased Estimator

Probleme mit Zeitreihendaten

- ▶ Grundproblem: Fälle sind nicht zufällig ausgewählt, sondern zeitlich strukturiert
- ▶ Fiktives Beispiel: nationale Bildungsausgaben (x) und nationaler Schulleistungstests (y), jährliche Messung
- ▶ Typische Probleme:
 1. (Zusammenhang zwischen Variablen bzw. Verteilung einer Variablen ändert sich über die Zeit ((Non-)Stationarität))
 2. (Extreme Autokorrelation einer x -Variablen)
 3. Heteroskedastizität (Varianz von ϵ nicht konstant)
 4. Abhängigkeit zwischen x und ϵ
 5. Autokorrelation von ϵ

Probleme mit Zeitreihendaten

- ▶ Grundproblem: Fälle sind nicht zufällig ausgewählt, sondern zeitlich strukturiert
- ▶ Fiktives Beispiel: nationale Bildungsausgaben (x) und nationaler Schulleistungstests (y), jährliche Messung
- ▶ Typische Probleme:
 1. (Zusammenhang zwischen Variablen bzw. Verteilung einer Variablen ändert sich über die Zeit ((Non-)Stationarität))
 2. (Extreme Autokorrelation einer x -Variablen)
 3. Heteroskedastizität (Varianz von ϵ nicht konstant)
 4. Abhängigkeit zwischen x und ϵ
 5. Autokorrelation von ϵ

Heteroskedastizität

- ▶ Höhere Bildungsausgaben
 - ▶ Bessere Testergebnisse
 - ▶ Tests werden sorgfältiger durchgeführt → weniger zufällige Varianz
- ▶ Abhängigkeit der *Varianz* von ϵ vom Niveau von x
- ▶ Standardfehler zu optimistisch
- ▶ Mögliche Lösungen
 - ▶ Qualität der Testdurchführung direkt messen (möglicherweise aber hoch mit x korreliert)
 - ▶ „Robuste“ Standardfehler berechnen lassen

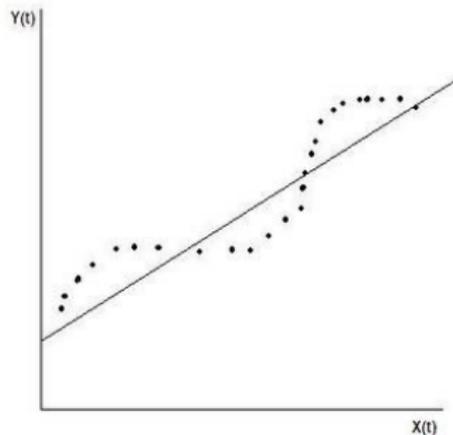
Endogenität

- ▶ Idealerweise: Alle Werte von x komplett von aktuellen, vergangenen, zukünftigen Werten von ϵ unabhängig (strikt exogen)
- ▶ D. h. Gedankenexperiment:
 - ▶ DGP würde sehr häufig wiederholt
 - ▶ Werte für z. B. x_t und ϵ_{t-1} würden notiert
 - ▶ Korrelation zwischen beiden?
- ▶ Endogenität im Beispiel leicht möglich
 - ▶ Zufälliger negativer ϵ_{t-1} (z. B. Fußball-WM 2014) beeinflusst Leistungen im Test 2014 (y_{t-1})
 - ▶ Panische Erhöhung der Bildungsausgaben in 2015 (x_t)
 - ▶ Zusammenhang zwischen x und ϵ ; x ist nicht exogen
- ▶ Bias, aber möglicherweise noch konsistent → besondere Modelle

Autokorrelation von ϵ

- ▶ In Zeitreihen sind die Werte von ϵ häufig (positiv) mit sich selbst korreliert
 - ▶ Neue Show mit G. Jauch führt zu besonderen Anstrengungen zum Zeitpunkt $t \rightarrow \epsilon_t > 0, y_t$ ungewöhnlich hoch
 - ▶ Ein Jahr später: positiver Effekt der Show abgeschwächt, aber noch vorhanden $\rightarrow \epsilon_t > \epsilon_{t+1} > 0$
 - ▶ Allgemein: $\epsilon_t = \rho\epsilon_{t-1} + u_t$ mit $|\rho| < 1$

Autokorrelation von ϵ



Positive Autokorrelation der zufälligen Einflüsse („Fehler“, ϵ)

Autokorrelation von ϵ

- ▶ In Zeitreihen sind die Werte von ϵ häufig (positiv) mit sich selbst korreliert
 - ▶ Neue Show mit G. Jauch führt zu besonderen Anstrengungen zum Zeitpunkt $t \rightarrow \epsilon_t > 0, y_t$ ungewöhnlich hoch
 - ▶ Ein Jahr später: positiver Effekt der Show abgeschwächt, aber noch vorhanden $\rightarrow \epsilon_t > \epsilon_{t+1} > 0$
 - ▶ Allgemein: $\epsilon_t = \rho\epsilon_{t-1} + u_t$ mit $|\rho| < 1$
- ▶ OLS immer noch konsistent und unverzerrt, aber nicht mehr effizient
- ▶ R^2 zu hoch, Signifikanztests nicht mehr gültig
- ▶ Statistischer Test (Durbin-Watson-Test und Alternativen)
- ▶ Ggf. besonderes Modell schätzen

Presidential Approval

```
. reg approval honeymoon date
```

Source	SS	df	MS			
Model	2688.40949	2	1344.20475	Number of obs =	148	
Residual	24762.6874	145	170.777155	F(2, 145) =	7.87	
Total	27451.0969	147	186.742156	Prob > F =	0.0006	
				R-squared =	0.0979	
				Adj R-squared =	0.0855	
				Root MSE =	13.068	

approval	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
honeymoon	12.58499	5.061734	2.49	0.014	2.580679	22.5893
date	-.0791643	.0251498	-3.15	0.002	-.1288719	-.0294567
_cons	56.42957	1.324231	42.61	0.000	53.81228	59.04686

```
. estat durбина
```

Durbin's alternative test for autocorrelation

lags(p)	chi2	df	Prob > chi2
1	639.669	1	0.0000

H0: no serial correlation

Presidential Approval

```
. prais approval honeymoon date,robust
```

```
Iteration 0: rho = 0.0000
```

```
Iteration 1: rho = 0.8928
```

```
Iteration 2: rho = 0.8933
```

```
Iteration 3: rho = 0.8933
```

```
Iteration 4: rho = 0.8933
```

```
Prais-Winsten AR(1) regression -- iterated estimates
```

```
Linear regression
```

```
Number of obs =    148  
F( 3, 145) =    61.56  
Prob > F      =    0.0000  
R-squared     =    0.3154  
Root MSE     =    5.9474
```

approval	Coef.	Semirobust Std. Err.	t	P> t	[95% Conf. Interval]	
honeymoon	11.79881	3.382	3.49	0.001	5.114425	18.4832
date	-.0679737	.091423	-0.74	0.458	-.2486677	.1127202
_cons	57.35978	4.873512	11.77	0.000	47.72748	66.99208
rho	.8933075					

```
Durbin-Watson statistic (original) 0.218290
```

```
Durbin-Watson statistic (transformed) 1.511600
```

(1.) Differenzen

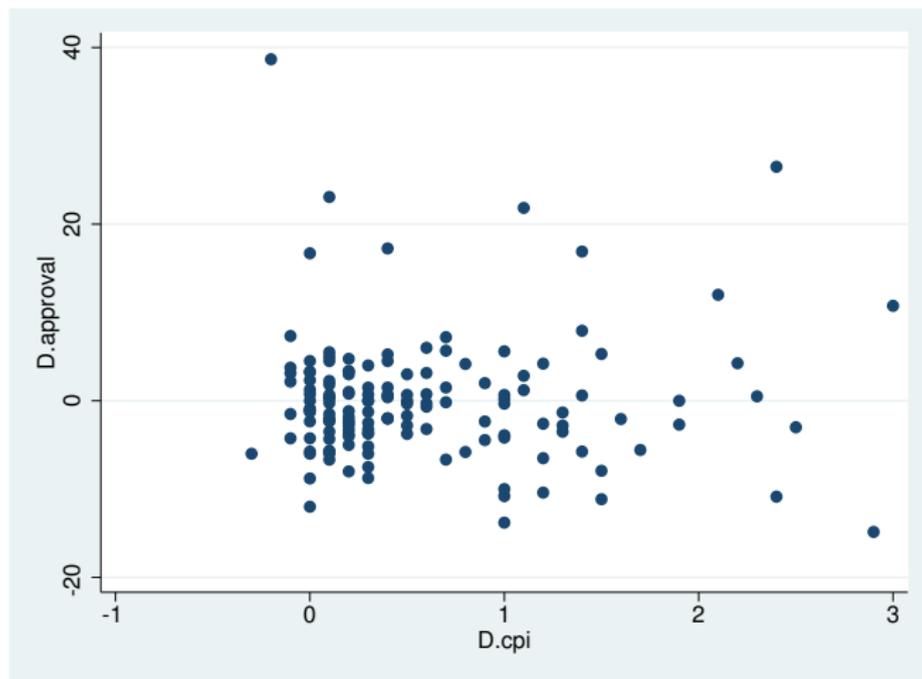
- ▶ Zeitreihen mit starken Trends machen Probleme bei Schätzung
- ▶ Oft ist nicht Niveau, sondern Veränderung interessant
- ▶ Differenzen (gegenüber Vorperiode) für abhängige und/oder unabhängige Variablen
- ▶ In Stata: D.-Operator

(1.) Differenzen

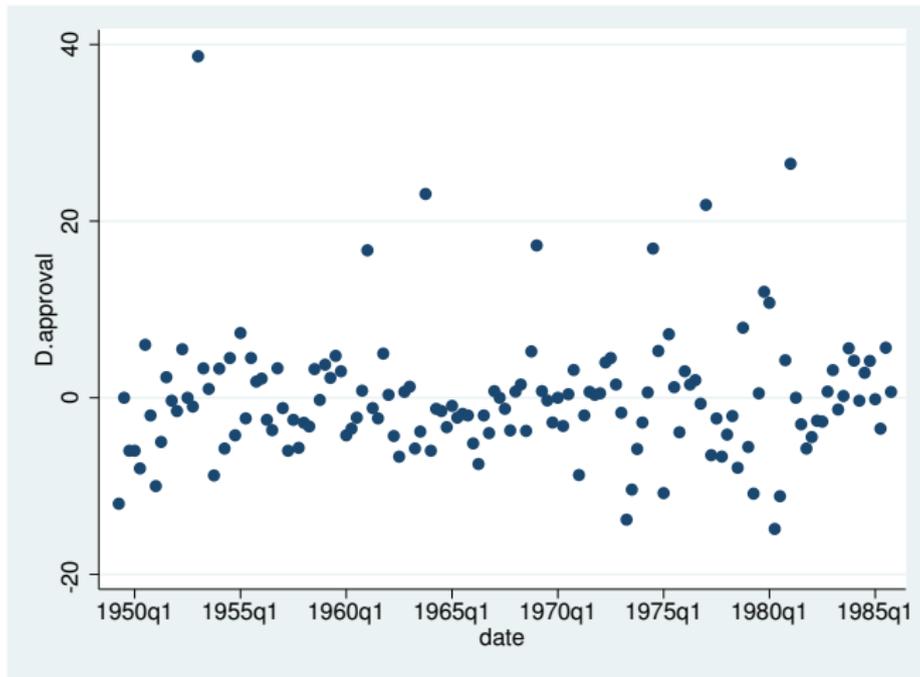
```
. list date approval D.approval cpi D.cpi in 1/6,clean
```

	date	approval	D. approval	cpi	D. cpi
1.	1949q1	69	.	23.8	.
2.	1949q2	57	-12	23.8	0
3.	1949q3	57	0	23.8	0
4.	1949q4	51	-6	23.8	0
5.	1950q1	45	-6	23.5	-.2999992
6.	1950q2	37	-8	23.7	.2000008

Veränderung approval / Veränderung CPI



Veränderung approval / Zeit



Finales (?) Modell

```
. prais D.approval honeymoon D.cpi date
```

```
Iteration 0: rho = 0.0000  
Iteration 1: rho = 0.0628  
Iteration 2: rho = 0.0641  
Iteration 3: rho = 0.0642  
Iteration 4: rho = 0.0642
```

```
Prais-Winsten AR(1) regression -- iterated estimates
```

Source	SS	df	MS	Number of obs =	147
Model	3936.77694	3	1312.25898	F(3, 143) =	55.48
Residual	3382.07009	143	23.6508398	Prob > F =	0.0000
				R-squared =	0.5379
				Adj R-squared =	0.5282
				Root MSE =	4.8632
Total	7318.84703	146	50.1290893		

D.approval	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
honeymoon	24.13866	1.876509	12.86	0.000	20.42938 27.84794
cpi					
D1.	-1.264644	.8988159	-1.41	0.162	-3.041326 .5120389
date	.0182705	.0142053	1.29	0.200	-.0098091 .04635
_cons	-1.00744	.5734237	-1.76	0.081	-2.140922 .1260424
rho	.0641721				

```
Durbin-Watson statistic (original) 1.843234  
Durbin-Watson statistic (transformed) 1.963893
```

Zusammenfassung

- ▶ Zeitreihen sind anders:
 - ▶ Kein Stichprobenziehung
 - ▶ Nur ein Objekt wird beobachtet
 - ▶ Viele Informationen über dieses Objekt
- ▶ Zeitreihen sind schwach
 - ▶ Beobachtungen sind voneinander abhängig
 - ▶ Effektive Fallzahl kleiner als n
- ▶ Gleichzeitig informativer als Querschnittsdaten: Dynamik
- ▶ *Sehr* sorgfältige Analyse notwendig