

Zusammenhangsmaße I

Statistik I

Sommersemester 2009

Wiederholung/Einführung Zusammenhangsmaße

Überblick

Nominale Daten: χ^2

Nominale Daten: PRE-Maß

Zusammenfassung

$$\chi^2 =?!?$$

Wiederholung/Einführung Zusammenhangsmaße

Überblick

Nominale Daten: χ^2

Nominale Daten: PRE-Maß

Zusammenfassung

Nächste Woche: Maße für ordinale,
nominal/intervallskalierte und
intervallskalierte Daten

$$\chi^2 =?!?$$

Zum Nachlesen

- ▶ Agresti/Finlay: Kapitel 8.1-8.4
- ▶ Gehring/Weins: Kapitel 7.1
- ▶ Schumann: Schumann Kapitel 7

Verteilungen

- ▶ Verteilungen von Variablen haben ...
- ▶ Eine Streuung um diese Mitte
- ▶ Sie sind symmetrisch oder schief
- ▶ Und haben eine mehr oder minder breiten Gipfel

Verteilungen

- ▶ Verteilungen von Variablen haben ...
- ▶ Eine Streuung um diese Mitte
- ▶ Sie sind symmetrisch oder schief
- ▶ Und haben eine mehr oder minder breiten Gipfel
- ▶ **Beschreibung der Eigenschaften durch Maßzahlen**

Univariate vs. bivariate Verteilungen

- ▶ Letzte Woche: *univariate* Verteilungen – eine einzige Variable

Univariate vs. bivariate Verteilungen

- ▶ Letzte Woche: *univariate* Verteilungen – eine einzige Variable
- ▶ Aber: LRS in drei Ländern: *konditionale* Verteilung – Zusammenhang?

Univariate vs. bivariate Verteilungen

- ▶ Letzte Woche: *univariate* Verteilungen – eine einzige Variable
- ▶ Aber: LRS in drei Ländern: *konditionale* Verteilung – Zusammenhang?
- ▶ *Gemeinsame* Verteilung von zwei Variablen: *bivariate* Verteilung – zeigt Zusammenhang (oder auch nicht)

Was ist ein Zusammenhang?

- ▶ Allgemein: gemeinsames „Muster“ in der Verteilung zweier Variablen (kausal?)
- ▶ Beispiele
 - ▶ Arbeiter wählen häufiger die SPD als andere Gruppen
 - ▶ Hochgebildete vertreten häufiger postmaterialistische Werte als Niedriggebildete
 - ▶ Männer haben ein höheres Durchschnittsgehalt als Frauen
 - ▶ Je älter ein Befragter ist, desto höher ist auch sein Wert auf einer Konservatismusskala

Warum sind Zusammenhänge interessant?

- ▶ Zusammenhänge erlauben Prognosen
- ▶ Zusammenhänge = empirische Entsprechung von Hypothesen

Welche Arten von Zusammenhängen gibt es?

- ▶ Unterschieds- vs. Zusammenhangshypothesen – strukturell identisch
- ▶ Durchschnittseinkommen von Männern/Frauen unterscheidet sich = Zusammenhang zwischen Geschlecht und Einkommen
- ▶ Gerichtete vs. ungerichtete Hypothesen → gerichtete vs. ungerichtete Zusammenhänge
 - ▶ Einkommen von Männern ist höher vs.
 - ▶ Einkommen unterscheidet sich
- ▶ Gerichtete Zusammenhänge
 - ▶ positiv: mehr von x , mehr von y ; weniger von x ... ?

Welche Arten von Zusammenhängen gibt es?

- ▶ Unterschieds- vs. Zusammenhangshypothesen – strukturell identisch
- ▶ Durchschnittseinkommen von Männern/Frauen unterscheidet sich = Zusammenhang zwischen Geschlecht und Einkommen
- ▶ Gerichtete vs. ungerichtete Hypothesen → gerichtete vs. ungerichtete Zusammenhänge
 - ▶ Einkommen von Männern ist höher vs.
 - ▶ Einkommen unterscheidet sich
- ▶ Gerichtete Zusammenhänge
 - ▶ positiv: mehr von x , mehr von y ; weniger von x ... ?
 - ▶ negativ: mehr von x , weniger von y ; weniger von x mehr von y


Welche Arten von Zusammenhängen gibt es?

- ▶ Unterschieds- vs. Zusammenhangshypothesen – strukturell identisch
- ▶ Durchschnittseinkommen von Männern/Frauen unterscheidet sich = Zusammenhang zwischen Geschlecht und Einkommen
- ▶ Gerichtete vs. ungerichtete Hypothesen → gerichtete vs. ungerichtete Zusammenhänge
 - ▶ Einkommen von Männern ist höher vs.
 - ▶ Einkommen unterscheidet sich
- ▶ Gerichtete Zusammenhänge
 - ▶ positiv: mehr von x , mehr von y ; weniger von x ... ?
 - ▶ negativ: mehr von x , weniger von y ; weniger von x mehr von y
- ▶ Starke (perfekte) vs. schwache Zusammenhänge


Welche Arten von Zusammenhängen gibt es? II

1. (Näherungsweise) lineare Zusammenhänge
2. (Monotone Zusammenhänge)
3. Kurvilineare und andere nicht-lineare Zusammenhänge

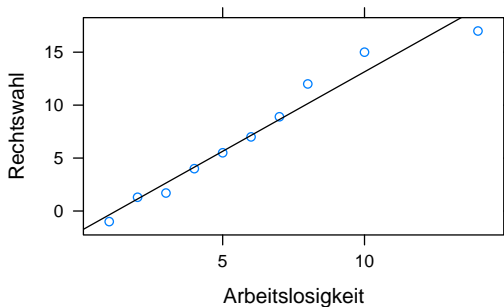
Was sind lineare Zusammenhänge?



Was sind lineare Zusammenhänge?



Was sind lineare Zusammenhänge?




- ▶ Zusammenhang zwischen zwei Variablen kann (näherungsweise) durch eine gerade Linie beschrieben werden

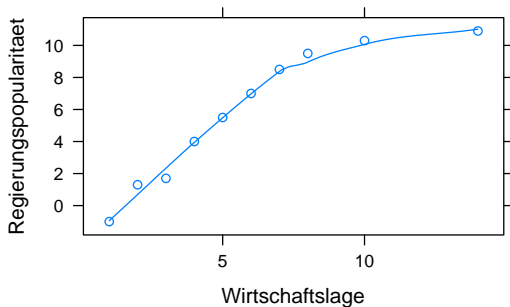
Was sind monotone Zusammenhänge

- ▶ Ändern ihre Richtung nicht
- ▶ Unabhängig vom Niveau von x Zunahme von x immer mit Zunahme (oder Abnahme) von y verbunden
- ▶ Linear oder nicht-linear

Monotoner nicht-linearer Zusammenhang



Monotoner nicht-linearer Zusammenhang



- ▶ Zusammenhang über gesamten Wertebereich von x positiv
- ▶ Aber nicht konstant (Anstieg schwächt sich ab)

Was sind nicht lineare Zusammenhänge?

- ▶ Zusammenhang nicht in Form einer Linie (Zusammenhang nicht über Wertebereich konstant)


Was sind nicht lineare Zusammenhänge?

- ▶ Zusammenhang nicht in Form einer Linie (Zusammenhang nicht über Wertebereich konstant)
- ▶ Monoton/nicht monoton

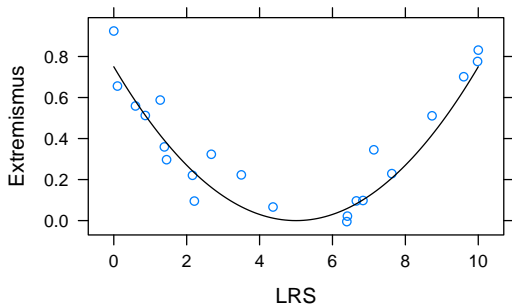
Was sind nicht lineare Zusammenhänge?

- ▶ Zusammenhang nicht in Form einer Linie (Zusammenhang nicht über Wertebereich konstant)
- ▶ Monoton/nicht monoton
- ▶ Einige wichtige Formen:
 1. Kurvilinear (U-förmig, nicht-monoton)
 2. Exponential (monoton)
 3. Sigmoidal (S-förmig, monoton)


Beispiel für einen kurvilinearen Zusammenhang



Beispiel für einen kurvilinearen Zusammenhang




Beispiel für einen kurvilinearen Zusammenhang




- ▶ Negativer Zusammenhang für $x < 5$
- ▶ Positiver Zusammenhang für $x > 5$

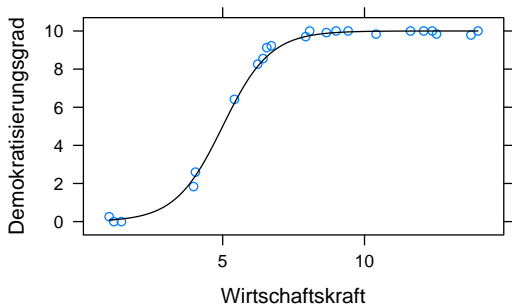
Beispiel für einen sigmoidalen Zusammenhang



Beispiel für einen sigmoidalen Zusammenhang



Beispiel für einen sigmoidalen Zusammenhang



- ▶ Zusammenhang schwach für $x < 3$
- ▶ Zusammenhang stark positiv für $4 < x < 6$
- ▶ Zusammenhang schwach für $x > 6$

Zusammenhänge und Skalenniveaus

- ▶ Gerichtete Zusammenhänge – geordnete Kategorien
- ▶ Für jedes Niveau passende Zusammenhangsmaße + Hierarchie
- ▶ Richtung im engeren Sinn setzt ordinales Skalenniveau voraus

Keine Richtung bei nominalen Daten?

- ▶ Katholiken sollten häufiger CDU wählen als Protestanten
- ▶ Protestanten sollten häufiger CDU wählen als Konfessionslose
- ▶ Warum?

Wenn Daten nominal sind ...

- ▶ Besteht der Zusammenhang darin, daß es Unterschiede gibt
- ▶ Bei wenigen Kategorien und klaren Hypothesen: Annahmen wo Unterschiede auftreten
- ▶ Können Daten für diesen Zweck dieser Hypothese als ordinal betrachtet werden?

Was sind Zusammenhangsmaße?

- ▶ Quantifizieren Stärke (und ggf. Richtung) eines Zusammenhanges
- ▶ Definierter Wertebereich → Vergleich von zwei Zusammenhänge
- ▶ Idealerweise zwischen 0 und 1 bzw. -1 und 1
- ▶ Vielzahl von Zusammenhangsmaßen für verschiedene Skalenniveaus
- ▶ Basieren auf *gemeinsamer Verteilung zweier Variablen* – besonders bei nominalen Variablen gut zu erkennen

Was ist ein Zusammenhang zwischen zwei nominalen Variablen?

Nominaler Zusammenhang

- ▶ Ausprägungen treten
- ▶ Häufiger/seltener gemeinsam auf
- ▶ Als bei *zufälliger* Verteilung zu erwarten wäre

Was ist ein Zusammenhang zwischen zwei nominalen Variablen?

Nominaler Zusammenhang

- ▶ Ausprägungen treten
- ▶ Häufiger/seltener gemeinsam auf
- ▶ Als bei *zufälliger* Verteilung zu erwarten wäre

- ▶ Verteilungen nicht unabhängig voneinander \rightarrow konditionale \neq marginale Verteilung

Was ist ein Zusammenhang zwischen zwei nominalen Variablen?

Nominaler Zusammenhang

- ▶ Ausprägungen treten
 - ▶ Häufiger/seltener gemeinsam auf
 - ▶ Als bei *zufälliger* Verteilung zu erwarten wäre
- ▶ Verteilungen nicht unabhängig voneinander \rightarrow konditionale \neq marginale Verteilung
 - ▶ Verteilung unter Annahme von Unabhängigkeit:
Wahrscheinlichkeiten für Ausprägungen miteinander multiplizieren

Was ist ein Zusammenhang zwischen zwei nominalen Variablen?

Nominaler Zusammenhang

- ▶ Ausprägungen treten
- ▶ Häufiger/seltener gemeinsam auf
- ▶ Als bei *zufälliger* Verteilung zu erwarten wäre

- ▶ Verteilungen nicht unabhängig voneinander \rightarrow konditionale \neq marginale Verteilung
- ▶ Verteilung unter Annahme von Unabhängigkeit:
Wahrscheinlichkeiten für Ausprägungen miteinander multiplizieren
- ▶ Wahrscheinlichkeit für Ausprägung:
relative Häufigkeit des Merkmals
(mehr dazu in einigen Wochen)

Ein einfaches Beispiel: Konfession und Geschlecht

- ▶ Der Anteil von Männern/Frauen in einer Gesellschaft (GG) beträgt 50%
- ▶ Der Anteil der Katholiken beträgt 40%
- ▶ *Wenn* kein Zusammenhang besteht/ beide Variablen unabhängig sind:
 - ▶ Wahrscheinlichkeit $p(m)$ daß eine zufällig ausgewählte Person männlich ist: ?
 - ▶ Wahrscheinlichkeit $p(k)$ daß eine zufällig ausgewählte Person katholisch ist: ?
 - ▶ Wahrscheinlichkeit $p(k)$ daß eine zufällig ausgewählte Person männlich **und** katholisch ist:

Ein einfaches Beispiel: Konfession und Geschlecht

- ▶ Der Anteil von Männern/Frauen in einer Gesellschaft (GG) beträgt 50%
- ▶ Der Anteil der Katholiken beträgt 40%
- ▶ *Wenn* kein Zusammenhang besteht/ beide Variablen unabhängig sind:
 - ▶ Wahrscheinlichkeit $p(m)$ daß eine zufällig ausgewählte Person männlich ist: 0.5
 - ▶ Wahrscheinlichkeit $p(k)$ daß eine zufällig ausgewählte Person katholisch ist: ?
 - ▶ Wahrscheinlichkeit $p(k)$ daß eine zufällig ausgewählte Person männlich **und** katholisch ist:

Ein einfaches Beispiel: Konfession und Geschlecht

- ▶ Der Anteil von Männern/Frauen in einer Gesellschaft (GG) beträgt 50%
- ▶ Der Anteil der Katholiken beträgt 40%
- ▶ *Wenn* kein Zusammenhang besteht/ beide Variablen unabhängig sind:
 - ▶ Wahrscheinlichkeit $p(m)$ daß eine zufällig ausgewählte Person männlich ist: 0.5
 - ▶ Wahrscheinlichkeit $p(k)$ daß eine zufällig ausgewählte Person katholisch ist: 0.4
 - ▶ Wahrscheinlichkeit $p(k)$ daß eine zufällig ausgewählte Person männlich **und** katholisch ist:

Ein einfaches Beispiel: Konfession und Geschlecht

- ▶ Der Anteil von Männern/Frauen in einer Gesellschaft (GG) beträgt 50%
- ▶ Der Anteil der Katholiken beträgt 40%
- ▶ *Wenn* kein Zusammenhang besteht/ beide Variablen unabhängig sind:
 - ▶ Wahrscheinlichkeit $p(m)$ daß eine zufällig ausgewählte Person männlich ist: 0.5
 - ▶ Wahrscheinlichkeit $p(k)$ daß eine zufällig ausgewählte Person katholisch ist: 0.4
 - ▶ Wahrscheinlichkeit $p(k)$ daß eine zufällig ausgewählte Person männlich **und** katholisch ist: $0.5 \times 0.4 = 0.2 = 20\%$

Was weiter?

- ▶ Wenn realer Anteil $\neq 20\%$ \rightarrow männliche Katholiken „überzufällig“ häufig/selten \rightarrow zusammenhang
- ▶ Statistischer Zusammenhang („Korrelation“)
 - ▶ Zusammenhang auch in GG vorhanden (Schätzung für GG, Stichprobenfehler)?
 - ▶ Starker/schwacher Zusammenhang?
- ▶ Logik des überzufällig häufigen gemeinsamen Auftretens (Verteilungen nicht unabhängig voneinander) unabhängig vom Skalenniveau

Maße auf der Basis von χ^2

- ▶ Verbindung zum „überzufällig häufigen“ gemeinsamen Auftreten besonders klar
- ▶ Vergleichen empirische Kreuztabelle
- ▶ Mit Tabelle die Häufigkeiten (gemeinsame Verteilung) unter Annahme zeigt
- ▶ Daß kein Zusammenhang besteht (Indifferenztable)

Was ist eine Kreuztabelle?

- ▶ „Kreuzt“ zwei kategoriale Variablen miteinander
- ▶ Gemeinsame Häufigkeitstabelle für zwei Variablen
- ▶ Am Rand Rand-/Gesamtverteilungen (marginale Verteilung)
- ▶ In der Mitte gemeinsame (konditionale) Verteilung(en)

Was ist eine Kreuztabelle II

Ausprägungen Variable 1

	West	Ost	Σ	
PDS	4	116	120	← Randsummen
nicht PDS	1572	606	2178	
Σ	1576	722	2298	

Gesamtsumme

Welche Prozentuierungsarten gibt es in der Kreuztabelle?

- ▶ Zeilenprozent setzen den Inhalt einer Zelle zur Zeilensumme ins Verhältnis
 - ▶ Wieviel Prozent aller PDS-Wähler sind Westdeutsche?
 - ▶ Wieviel Prozent aller Wähler insgesamt sind Westdeutsche
- ▶ Spaltenprozent setzen den Inhalt einer Zelle zur Spaltensumme ins Verhältnis
 - ▶ Wieviel Prozent der westdeutschen Wähler stimmen für die PDS?
 - ▶ Wie hoch ist der Anteil der PDS-Wähler insgesamt?
- ▶ Totalprozent setzen den Inhalt einer Zelle zur Gesamtsumme ins Verhältnis
 - ▶ Wie hoch ist der Anteil der westdeutschen PDS-Wähler an allen Wählern

Zeilenprozente →

	West	Ost	Σ
PDS	4/120=3.3%	116/120=96.6%	120/120=100%
nicht PDS	1572/2178=72.1%	606/2178=27.8%	2178/2178=100%
Σ	1576/2298=68.6%	722/2298=31.4%	2298/2298=100%

Spaltenprozente ↓

	West	Ost	Σ
PDS	$4/1576=0.3\%$	$116/722=16.1\%$	$120/2298=5.2\%$
nicht PDS	$1572/1576=99.7\%$	$606/722=83.9\%$	$2178/2298=94.8\%$
Σ	$1576/1576=100\%$	$722/722=100\%$	$2298/2298=100\%$

Spaltenprozente ↓

	West	Ost	Σ
PDS	$4/1576=0.3\%$	$116/722=16.1\%$	$120/2298=5.2\%$
nicht PDS	$1572/1576=99.7\%$	$606/722=83.9\%$	$2178/2298=94.8\%$
Σ	$1576/1576=100\%$	$722/722=100\%$	$2298/2298=100\%$

- ▶ Zweimal dieselbe Information:

Spaltenprozentage ↓

	West	Ost	Σ
PDS	$4/1576=0.3\%$	$116/722=16.1\%$	$120/2298=5.2\%$
nicht PDS	$1572/1576=99.7\%$	$606/722=83.9\%$	$2178/2298=94.8\%$
Σ	$1576/1576=100\%$	$722/722=100\%$	$2298/2298=100\%$

- ▶ Zweimal dieselbe Information:
- ▶ Verteilungen der beiden Variablen sind nicht unabhängig voneinander
- ▶ Bzw. weichen von zufälligem Muster (Indifferenztabelle) ab

Wie wird die Indifferenztabelle konstruiert?

	West	Ost	Σ	↓
PDS	4	116	120	5.2%
nicht PDS	1572	606	2178	94.8%
<hr/>				
Σ	1576	722	2298	
→	72.1%	31.4%	2298	

- ▶ Verteilung des ersten Merkmals: **Zeilensummen** am unteren Rand → Wahrscheinlichkeit ostdeutsch/westdeutsch
- ▶ Verteilung des zweiten Merkmals: **Spaltensummen** am rechten Rand → Wahrscheinlichkeit PDS-Wahl/nicht-PDS-Wahl

Wie wird die Indifferenztabelle konstruiert?

	West	Ost	Σ	↓
PDS	4	116	120	5.2%
nicht PDS	1572	606	2178	94.8%
<hr/>				
Σ	1576	722	2298	
→	72.1%	31.4%	2298	

- ▶ Verteilung des ersten Merkmals: **Zeilensummen** am unteren Rand → Wahrscheinlichkeit ostdeutsch/westdeutsch
- ▶ Verteilung des zweiten Merkmals: **Spaltensummen** am rechten Rand → Wahrscheinlichkeit PDS-Wahl/nicht-PDS-Wahl
- ▶ Wahrscheinlichkeit ostdeutsch PDS-Wähler (bei Unabhängigkeit der Variablen): $0.314 \times 0.052 = 0.016328 \approx \frac{1}{3} \times \frac{1}{20}$

Wie wird die Indifferenztabelle konstruiert?

	West	Ost	Σ	↓
PDS	4	116	120	5.2%
nicht PDS	1572	606	2178	94.8%
<hr/>				
Σ	1576	722	2298	
→	72.1%	31.4%	2298	

- ▶ Verteilung des ersten Merkmals: **Zeilensummen** am unteren Rand → Wahrscheinlichkeit ostdeutsch/westdeutsch
- ▶ Verteilung des zweiten Merkmals: **Spaltensummen** am rechten Rand → Wahrscheinlichkeit PDS-Wahl/nicht-PDS-Wahl
- ▶ Wahrscheinlichkeit ostdeutsch PDS-Wähler (bei Unabhängigkeit der Variablen): $0.314 \times 0.052 = 0.016328 \approx \frac{1}{3} \times \frac{1}{20}$
- ▶ Absolute zu erwartende Zahl der ostdeutschen PDS-Wähler: $0.016328 \times 2298 \approx 37.5$

Wie wird die Indifferenztafel konstruiert? II

- ▶ Allgemein: Multiplikation der Randwahrscheinlichkeiten \rightarrow gemeinsame Wahrscheinlichkeit
- ▶ Gemeinsame Wahrscheinlichkeit mal Gesamtzahl Beobachtungen \rightarrow erwartete Häufigkeit
- ▶ Vereinfacht:

$$\frac{\frac{\text{Spaltensumme}}{\text{Gesamtsumme}} \times \frac{\text{Zeilensumme}}{\text{Gesamtsumme}} \times \text{Gesamtsumme} = \frac{\text{Spaltensumme} \times \text{Zeilensumme}}{\text{Gesamtsumme}}}$$

- ▶ Berechnung wird für alle Zellen im Inneren der Tabelle vorgenommen
- ▶ Randsummen und Gesamtsummen bleiben konstant

Wie wird die Indifferenztabelle konstruiert? III

	West	Ost	Σ
PDS	$\frac{1576 \times 120}{2298} = 82.3$	$\frac{722 \times 120}{2298} = 37.7$	120
nicht PDS	$\frac{1576 \times 2178}{2298} = 1493.7$	$\frac{722 \times 2178}{2298} = 684.3$	2178
Σ	1576	722	2298

Wie kommt man zum Wert χ^2 ?

- ▶ Für jede Zelle der 2×2 Tabelle Differenz zwischen beobachteten/erwarteten Werten ermitteln → einfache Abweichungen
- ▶ Summe der einfachen Abweichungen = 0
- ▶ Quadrieren
 - ▶ Damit das Vorzeichen verschwindet
 - ▶ Um größere Abweichungen stärker zu gewichten
- ▶ Quadrierte Abweichungen durch erwarteten Werte teilen
 - ▶ Größere erwartete Werte → größere zufällige Schwankungen
 - ▶ Quadrierte Abweichungen werden auf eine Art gemeinsame Skala gebracht
- ▶ Standardisierte quadrierte Abweichungen in jeder Zelle (Beitrag)
- ▶ Summe der Beiträge: χ^2

Wie kommt man zum Wert χ^2 ? II

	beobachtet				erwartet		
	West	Ost	Σ		West	Ost	Σ
PDS	4	116	120	PDS	82.3	37.7	120
nicht PDS	1572	606	2178	nicht PDS	1493.7	684.3	2178
Σ	1576	722	2298	Σ	1576	722	2298

Wie kommt man zum Wert χ^2 ? II

	beobachtet				erwartet		
	West	Ost	Σ		West	Ost	Σ
PDS	4	116	120	PDS	82.3	37.7	120
nicht PDS	1572	606	2178	nicht PDS	1493.7	684.3	2178
Σ	1576	722	2298	Σ	1576	722	2298

$$\begin{aligned}\chi^2 &= \frac{(4 - 82.3)^2}{82.3} \dots \\ &= 74.49 \dots\end{aligned}$$

Wie kommt man zum Wert χ^2 ? II

	beobachtet				erwartet		
	West	Ost	Σ		West	Ost	Σ
PDS	4	116	120	PDS	82.3	37.7	120
nicht PDS	1572	606	2178	nicht PDS	1493.7	684.3	2178
Σ	1576	722	2298	Σ	1576	722	2298

$$\begin{aligned}\chi^2 &= \frac{(4 - 82.3)^2}{82.3} \dots \\ &= 74.49 \dots\end{aligned}$$

Wie kommt man zum Wert χ^2 ? II

	beobachtet			erwartet		
	West	Ost	Σ	West	Ost	Σ
PDS	4	116	120	82.3	37.7	120
nicht PDS	1572	606	2178	1493.7	684.3	2178
Σ	1576	722	2298	1576	722	2298

$$\begin{aligned}\chi^2 &= \frac{(4 - 82.3)^2}{82.3} \dots \\ &= 74.49 \dots\end{aligned}$$

Wie kommt man zum Wert χ^2 ? II

	beobachtet				erwartet		
	West	Ost	Σ		West	Ost	Σ
PDS	4	116	120	PDS	82.3	37.7	120
nicht PDS	1572	606	2178	nicht PDS	1493.7	684.3	2178
Σ	1576	722	2298	Σ	1576	722	2298

$$\chi^2 = \frac{(4 - 82.3)^2}{82.3} \dots$$

$$= 74.49 \dots$$

Wie kommt man zum Wert χ^2 ? II

	beobachtet				erwartet		
	West	Ost	Σ		West	Ost	Σ
PDS	4	116	120	PDS	82.3	37.7	120
nicht PDS	1572	606	2178	nicht PDS	1493.7	684.3	2178
Σ	1576	722	2298	Σ	1576	722	2298

$$\chi^2 = \frac{(4 - 82.3)^2}{82.3} + \frac{(116 - 37.7)^2}{37.7} + \frac{(1572 - 1493.7)^2}{1493.7} + \frac{(606 - 684.3)^2}{684.3}$$

$$= 74.49 + 162.62 + 4.10 + 8.96 = 250.16$$

Eigenschaften von χ^2

χ^2

- ▶ ... ist eine Maßzahl
- ▶ ... hat keine Dimension
- ▶ Sein Wert hängt ab von
 1. Der Stärke des Zusammenhangs
 2. Der Zahl der Kategorien
 3. Der Zahl der Fälle

Eigenschaften von χ^2

χ^2

- ▶ ... ist eine Maßzahl
- ▶ ... hat keine Dimension
- ▶ Sein Wert hängt ab von
 1. Der Stärke des Zusammenhangs
 2. Der Zahl der Kategorien
 3. Der Zahl der Fälle

Eigenschaften von χ^2

χ^2

- ▶ ... ist eine Maßzahl
- ▶ ... hat keine Dimension
- ▶ Sein Wert hängt ab von
 1. Der Stärke des Zusammenhangs
 2. Der Zahl der Kategorien
 3. Der Zahl der Fälle
- ▶ Als Zusammenhangsmaß ungeeignet, aber *Basis* für eine Reihe von Zusammenhangsmaßen

Maße auf der Basis von χ^2

1. ϕ
 2. Kontingenzkoeffizient C
 3. Cramer's V
- ▶ Versuchen χ^2 zu standardisieren
 - ▶ Korrektur für Zahl der Fälle:
$$\phi = \sqrt{\chi^2/n} =$$

Maße auf der Basis von χ^2

1. ϕ
 2. Kontingenzkoeffizient C
 3. Cramer's V
- ▶ Versuchen χ^2 zu standardisieren
 - ▶ Korrektur für Zahl der Fälle:
$$\phi = \sqrt{\chi^2/n} = \sqrt{250.2/2298} = 0.33$$

Maße auf der Basis von χ^2

1. ϕ
 2. Kontingenzkoeffizient C
 3. Cramer's V
- ▶ Versuchen χ^2 zu standardisieren
 - ▶ Korrektur für Zahl der Fälle:
$$\phi = \sqrt{\chi^2/n} = \sqrt{250.2/2298} = 0.33$$
 - ▶ Korrektur von ϕ für große Tabellen (viele Kategorien):
$$C = \sqrt{\chi^2/(\chi^2 + n)} =$$

Maße auf der Basis von χ^2

1. ϕ
 2. Kontingenzkoeffizient C
 3. Cramer's V
- ▶ Versuchen χ^2 zu standardisieren
 - ▶ Korrektur für Zahl der Fälle:
$$\phi = \sqrt{\chi^2/n} = \sqrt{250.2/2298} = 0.33$$
 - ▶ Korrektur von ϕ für große Tabellen (viele Kategorien):
$$C = \sqrt{\chi^2/(\chi^2 + n)} = \sqrt{250.2/(250.2 + 2298)} = 0.31$$

Maße auf der Basis von χ^2

1. ϕ
2. Kontingenzkoeffizient C
3. Cramer's V
 - ▶ Versuchen χ^2 zu standardisieren
 - ▶ Korrektur für Zahl der Fälle:
$$\phi = \sqrt{\chi^2/n} = \sqrt{250.2/2298} = 0.33$$
 - ▶ Korrektur von ϕ für große Tabellen (viele Kategorien):
$$C = \sqrt{\chi^2/(\chi^2 + n)} = \sqrt{250.2/(250.2 + 2298)} = 0.31$$
 - ▶ Cramer's V

Wie berechnet man Cramer's V ?

Cramer's V

$$\begin{aligned} V &= \sqrt{\frac{\chi^2}{n \times (R - 1)}} \\ &= \sqrt{\frac{250.2}{2298 \times (2 - 1)}} \\ &= \sqrt{\frac{250.2}{2298}} \\ &= 0.33 \end{aligned}$$

- ▶ R = Minimum der Zeilen/Spalten
- ▶ V berücksichtigt n und R (vs. C)
- ▶ Wertebereich $[0;1]$
- ▶ Symmetrisch
- ▶ Für 2×2 Tabellen mit ϕ identisch

Was ist ein PRE-Maß?

- ▶ Logik: Wieviel besser können wir eine abhängige Variable vorhersagen, wenn Wert der unabhängigen Variablen bekannt ist?
- ▶ (Bzw.: Wie unterscheiden sich marginale und konditionale Verteilung?)
- ▶ Wie stark reduziert sich der Vorhersagefehler – **Proportionate Reduction in Error**
- ▶ PRE-Maß für nominalskalierte Daten: λ
- ▶ Logik von λ :
 - ▶ Ohne Kenntnis unabhängiger Variablen ist Modalkategorie beste Vorhersage → Vorhersagefehler
 - ▶ Reduziert sich Zahl der Fehler durch Kenntnis unabhängiger Variablen?

Wahlabsicht und Kanzlerpräferenz

Wahlabsicht	Σ
Union	350
SPD	345
Andere	186
	881

- ▶ Beste Vorhersage ohne Kenntnis der Kanzlerpräferenz: Union

Wahlabsicht und Kanzlerpräferenz

Wahlabsicht	Σ
Union	350
SPD	345
Andere	186
	881

- ▶ Beste Vorhersage ohne Kenntnis der Kanzlerpräferenz: Union

Wahlabsicht und Kanzlerpräferenz

Wahlabsicht	Σ
Union	350
SPD	345
Andere	186
	881

- ▶ Beste Vorhersage ohne Kenntnis der Kanzlerpräferenz: Union
- ▶ $345+186=531$ Vorhersagefehler

Wahlabsicht und Kanzlerpräferenz

Wahlabsicht	Kanzlerpräferenz		Σ
	Merkel	Steinmeier	
Union	335	15	350
SPD	25	320	345
Andere	84	102	186
Σ	444	437	881

- ▶ Beste Vorhersage ohne Kenntnis der Kanzlerpräferenz: Union
- ▶ $345+186=531$ Vorhersagefehler

Wahlabsicht und Kanzlerpräferenz

Wahlabsicht	Kanzlerpräferenz		Σ
	Merkel	Steinmeier	
Union	335	15	350
SPD	25	320	345
Andere	84	102	186
Σ	444	437	881

- ▶ Bei Kenntnis der Präferenz

Wahlabsicht und Kanzlerpräferenz

Wahlabsicht	Kanzlerpräferenz		Σ
	Merkel	Steinmeier	
Union	335	15	350
SPD	25	320	345
Andere	84	102	186
Σ	444	437	881

- ▶ Bei Kenntnis der Präferenz
 - ▶ Vorhersage „Union“ für Merkel-Anhänger

Wahlabsicht und Kanzlerpräferenz

Wahlabsicht	Kanzlerpräferenz		Σ
	Merkel	Steinmeier	
Union	335	15	350
SPD	25	320	345
Andere	84	102	186
Σ	444	437	881

- ▶ Bei Kenntnis der Präferenz
 - ▶ Vorhersage „Union“ für Merkel-Anhänger
 - ▶ $25+84 = 109$ Vorhersagefehler

Wahlabsicht und Kanzlerpräferenz

Wahlabsicht	Kanzlerpräferenz		Σ
	Merkel	Steinmeier	
Union	335	15	350
SPD	25	320	345
Andere	84	102	186
Σ	444	437	881

- ▶ Bei Kenntnis der Präferenz
 - ▶ Vorhersage „Union“ für Merkel-Anhänger
 - ▶ $25+84 = 109$ Vorhersagefehler
 - ▶ Vorhersage „SPD“ für Steinmeier-Anhänger

Wahlabsicht und Kanzlerpräferenz

Wahlabsicht	Kanzlerpräferenz		Σ
	Merkel	Steinmeier	
Union	335	15	350
SPD	25	320	345
Andere	84	102	186
Σ	444	437	881

- ▶ Bei Kenntnis der Präferenz
 - ▶ Vorhersage „Union“ für Merkel-Anhänger
 - ▶ $25+84 = 109$ Vorhersagefehler
 - ▶ Vorhersage „SPD“ für Steinmeier-Anhänger
 - ▶ $15+102= 117$ Vorhersagefehler

Wahlabsicht und Kanzlerpräferenz

Wahlabsicht	Kanzlerpräferenz		Σ
	Merkel	Steinmeier	
Union	335	15	350
SPD	25	320	345
Andere	84	102	186
Σ	444	437	881

- ▶ Bei Kenntnis der Präferenz
 - ▶ Vorhersage „Union“ für Merkel-Anhänger
 - ▶ $25+84 = 109$ Vorhersagefehler
 - ▶ Vorhersage „SPD“ für Steinmeier-Anhänger
 - ▶ $15+102 = 117$ Vorhersagefehler
- ▶ $(84+25)+(15+102) = 226$ Vorhersagefehler

Wahlabsicht und Kanzlerpräferenz

Wahlabsicht	Kanzlerpräferenz		Σ
	Merkel	Steinmeier	
Union	335	15	350
SPD	25	320	345
Andere	84	102	186
Σ	444	437	881

- ▶ Bei Kenntnis der Präferenz
 - ▶ Vorhersage „Union“ für Merkel-Anhänger
 - ▶ $25+84 = 109$ Vorhersagefehler
 - ▶ Vorhersage „SPD“ für Steinmeier-Anhänger
 - ▶ $15+102 = 117$ Vorhersagefehler
- ▶ $(84+25)+(15+102) = 226$ Vorhersagefehler
- ▶ $\lambda = \frac{\text{Fehler1-Fehler2}}{\text{Fehler1}} = \frac{531-226}{531} = 0.57$

Wahlabsicht und Kanzlerpräferenz

Wahlabsicht	Kanzlerpräferenz		Σ
	Merkel	Steinmeier	
Union	335	15	350
SPD	25	320	345
Andere	84	102	186
Σ	444	437	881

- ▶ Bei Kenntnis der Präferenz
 - ▶ Vorhersage „Union“ für Merkel-Anhänger
 - ▶ $25+84 = 109$ Vorhersagefehler
 - ▶ Vorhersage „SPD“ für Steinmeier-Anhänger
 - ▶ $15+102 = 117$ Vorhersagefehler
- ▶ $(84+25)+(15+102) = 226$ Vorhersagefehler
- ▶ $\lambda = \frac{\text{Fehler1}-\text{Fehler2}}{\text{Fehler1}} = \frac{531-226}{531} = 0.57$
- ▶ Fehler reduziert sich um 57%

Mehr zu λ

- ▶ Asymmetrisches Maß; theoretische Unterscheidung zwischen abhängiger/unabhängiger Variable
- ▶ Kann Wert 0 annehmen obwohl Zusammenhang besteht
- ▶ Wenn Modalkategorie der abhängigen Variablen über Kategorien der unabhängigen Variablen hinweg gleich
- ▶ Beispiel Region → PDS-Wahl

„Versagen“ von λ

	Region		
Wahlabsicht	West	Ost	Σ
PDS	4	116	120
Andere	1572	606	2178
Σ	1576	772	2298

- ▶ Vorhersage gesamt: Andere \rightarrow 120 Fehler

„Versagen“ von λ

Wahlabsicht	Region		Σ
	West	Ost	
PDS	4	116	120
Andere	1572	606	2178
Σ	1576	772	2298

- ▶ Vorhersage gesamt: Andere \rightarrow 120 Fehler
- ▶ Vorhersage West: Andere \rightarrow 4 Fehler

„Versagen“ von λ

Wahlabsicht	Region		Σ
	West	Ost	
PDS	4	116	120
Andere	1572	606	2178
Σ	1576	772	2298

- ▶ Vorhersage gesamt: Andere \rightarrow 120 Fehler
- ▶ Vorhersage West: Andere \rightarrow 4 Fehler
- ▶ Vorhersage Ost: Andere \rightarrow 116 Fehler

„Versagen“ von λ

	Region		
Wahlabsicht	West	Ost	Σ
PDS	4	116	120
Andere	1572	606	2178
Σ	1576	772	2298

- ▶ Vorhersage gesamt: Andere \rightarrow 120 Fehler
- ▶ Vorhersage West: Andere \rightarrow 4 Fehler
- ▶ Vorhersage Ost: Andere \rightarrow 116 Fehler
- ▶ $\lambda = \frac{120 - (116 + 4)}{120} = 0$ (vs. $V = \phi = 0.33$)

„Versagen“ von λ

	Region		
Wahlabsicht	West	Ost	Σ
PDS	4	116	120
Andere	1572	606	2178
Σ	1576	772	2298

- ▶ Vorhersage gesamt: Andere \rightarrow 120 Fehler
- ▶ Vorhersage West: Andere \rightarrow 4 Fehler
- ▶ Vorhersage Ost: Andere \rightarrow 116 Fehler
- ▶ $\lambda = \frac{120 - (116 + 4)}{120} = 0$ (vs. $V = \phi = 0.33$)
- ▶ Anschaulich, aber nicht unproblematisch

Zusammenfassung

- ▶ Zusammenhang = Verteilungen zweier Variablen nicht unabhängig voneinander
- ▶ Kategorien treten häufiger gemeinsam auf als bei rein zufälliger Verteilung zu erwarten
- ▶ Zusammenhangs*maße* quantifizieren Stärke und ggf. Richtung des Zusammenhangs
- ▶ χ^2 -basierte Maße betrachten direkt Abweichungen von zufälliger Verteilung und sind symmetrisch
- ▶ PRE-Maß λ betrachtet Verbesserung gegenüber naiver Vorhersage und ist asymmetrisch