

Wiederholung/Einführung

Zwei ordinale Variablen

Eine nominale und eine intervallskalierte Variable

Zwei intervallskalierte Variablen

Zusammenfassung

# Zusammenhangsmaße II

Statistik I

Sommersemester 2009

Wiederholung/Einführung

Zwei ordinale Variablen

Eine nominale und eine intervallskalierte Variable

Zwei intervallskalierte Variablen

Zusammenfassung

Wiederholung/Einführung

Zwei ordinale Variablen

Einführung

$\gamma$

Andere Maße

Eine nominale und eine intervallskalierte  
Variable

Zwei intervallskalierte Variablen

Zusammenfassung

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

Wiederholung/Einführung

Zwei ordinale Variablen

Eine nominale und eine intervallskalierte Variable

Zwei intervallskalierte Variablen

Zusammenfassung

# Übung von Simone Reutzel

- ▶ *Heute* im HS1, altes ReWi-Haus

Wiederholung/Einführung

Zwei ordinale Variablen

Eine nominale und eine intervallskalierte Variable

Zwei intervallskalierte Variablen

Zusammenfassung

## Zum Nachlesen

- ▶ Agresti/Finlay: Kapitel 8.5, 9.4
- ▶ **Gehring/Weins**: Kapitel 7.2-7.4
- ▶ Schumann: Kapitel 8.2

# Was ist ein Zusammenhang?

- ▶ 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
- ▶ Unterschiedliche Maße für unterschiedliche Skalenniveaus
- ▶ PRE-Maß  $\lambda$  betrachtet Verbesserung gegenüber naiver Vorhersage und ist asymmetrisch

# Warum unterscheiden sich $\lambda$ und $V$ ?

- ▶ Beide gehen von Kreuztabelle (bivariate Verteilung) aus
- ▶  $V$  basiert auf  $\chi^2 \rightarrow$ 
  - ▶ Weichen interne/Randverteilungen voneinander ab  $\rightarrow$
  - ▶ Alle Zellen werden berücksichtigt
  - ▶ Vergleichbar mit arithmetischem Mittel: gesamte Information wird genutzt
- ▶  $\lambda$  betrachtet Modus der Randverteilung (abhängige Variable)
  - ▶ Vergleich mit Modus innerhalb von Subgruppen, definiert durch Ausprägungen unabhängige Variable (z. B. Ost/West)
  - ▶ Anschaulicher, aber weniger Information genutzt  $\rightarrow$
- ▶ Wenn Modus in Randverteilung und in Gruppen identisch  $\rightarrow$   
 $\lambda = 0$
- ▶ Höhe von  $\lambda$  hängt ab von Häufigkeit Modus vs. Häufigkeit aller anderen Kategorien zusammen innerhalb von Subgruppen

$\lambda = 0.57$  vs.  $\lambda = 0$ 

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

$\lambda = 0.57$  vs.  $\lambda = 0$

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

- ▶ Modus in den Subgruppen unterscheidet sich
- ▶ Innerhalb der Subgruppen Modus sehr häufig, alle anderen eher selten



$\lambda = 0.57$  vs.  $\lambda = 0$

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

- ▶ Modus in den Subgruppen unterscheidet sich
- ▶ Innerhalb der Subgruppen Modus sehr häufig, alle anderen eher selten
- ▶ In der Randverteilung auch andere Antworten („Fehler“) häufig
- ▶ Große „Fehlerreduktion“, hohes  $\lambda$

$\lambda = 0.57$  vs.  $\lambda = 0$

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

- ▶ Modus in den Subgruppen unterscheidet sich
- ▶ Innerhalb der Subgruppen Modus sehr häufig, alle anderen eher selten
- ▶ In der Randverteilung auch andere Antworten („Fehler“) häufig
- ▶ Große „Fehlerreduktion“, hohes  $\lambda$
- ▶ Einfluß der Kategorienbildung

$\lambda = 0.57$  vs.  $\lambda = 0$ 

Wahlabsicht	Region		$\Sigma$
	West	Ost	
PDS	4	116	120
Andere	1572	606	2178
$\Sigma$	1576	772	2298

$\lambda = 0.57$  vs.  $\lambda = 0$

Wahlabsicht	Region		$\Sigma$
	West	Ost	
PDS	4	116	120
Andere	1572	606	2178
$\Sigma$	1576	772	2298

- ▶ Modus in Randverteilung und beiden Subgruppen identisch

$\lambda = 0.57$  vs.  $\lambda = 0$

Wahlabsicht	Region		$\Sigma$
	West	Ost	
PDS	4	116	120
Andere	1572	606	2178
$\Sigma$	1576	772	2298

- ▶ Modus in Randverteilung und beiden Subgruppen identisch
- ▶ Keine Fehlerreduktion,  $\lambda = 0$

$\lambda = 0.57$  vs.  $\lambda = 0$

Wahlabsicht	Region		$\Sigma$
	West	Ost	
PDS	4	116	120
Andere	1572	606	2178
$\Sigma$	1576	772	2298

- ▶ Modus in Randverteilung und beiden Subgruppen identisch
- ▶ Keine Fehlerreduktion,  $\lambda = 0$
- ▶ Aufteilung „Andere“  $\rightarrow \lambda > 0$  möglich

$\lambda = 0.57$  vs.  $\lambda = 0$

Wahlabsicht	Region		$\Sigma$
	West	Ost	
PDS	4	116	120
Andere	1572	606	2178
$\Sigma$	1576	772	2298

- ▶ Modus in Randverteilung und beiden Subgruppen identisch
- ▶ Keine Fehlerreduktion,  $\lambda = 0$
- ▶ Aufteilung „Andere“  $\rightarrow \lambda > 0$  möglich
- ▶ Aber nur wenn anderer Modus innerhalb von Subgruppe (einfache Mehrheit für PDS)

# Warum sind Maße für ordinale Daten wichtig?

- ▶ Viele politikwissenschaftlich interessante Variablen ordinal
  - ▶ Umfragedaten: „stimme voll zu“, „stimme zu“, „lehne ab“, „lehne voll ab“
  - ▶ Freedom house ranking: „free“, „partly free“, „not free“
  - ▶ Politische Parteien: „links“, „Mitte“, „rechts“
  - ▶ Effektivität internationaler Umweltschutzregime: „none“, „some“ ...
- ▶ Berechnung nominaler Maße ( $V, \lambda$ ) möglich
- ▶ Aber: Information über Ordnung der Kategorien wird ignoriert



# Was ist ein ordinaler Zusammenhang?

- ▶ Zwei ordinale Variablen  $\rightarrow$  Richtung
  - ▶ Mehr  $x$ , mehr  $y$ ; weniger  $x$ , weniger  $y$   $\rightarrow$  positiver Zusammenhang
  - ▶ Mehr  $x$ , weniger  $y$ ; weniger  $x$ , mehr  $y$   $\rightarrow$  negativer Zusammenhang

# Was ist ein ordinaler Zusammenhang?


- ▶ Zwei ordinale Variablen → Richtung
  - ▶ Mehr  $x$ , mehr  $y$ ; weniger  $x$ , weniger  $y$  → positiver Zusammenhang
  - ▶ Mehr  $x$ , weniger  $y$ ; weniger  $x$ , mehr  $y$  → negativer Zusammenhang
- ▶ Wie mißt man das?

# Was ist ein ordinaler Zusammenhang?

- ▶ Zwei ordinale Variablen → Richtung
  - ▶ Mehr  $x$ , mehr  $y$ ; weniger  $x$ , weniger  $y$  → positiver Zusammenhang
  - ▶ Mehr  $x$ , weniger  $y$ ; weniger  $x$ , mehr  $y$  → negativer Zusammenhang
- ▶ Wie mißt man das?
- ▶ Vergleich von Paaren von Beobachtungen

# Was ist ein ordinaler Zusammenhang?

- ▶ Zwei ordinale Variablen → Richtung
  - ▶ Mehr  $x$ , mehr  $y$ ; weniger  $x$ , weniger  $y$  → positiver Zusammenhang
  - ▶ Mehr  $x$ , weniger  $y$ ; weniger  $x$ , mehr  $y$  → negativer Zusammenhang
- ▶ Wie mißt man das?
- ▶ Vergleich von Paaren von Beobachtungen



# Zusammenhangsmaß $\gamma$

- ▶ Systematisiert Paarvergleich
- ▶ Symmetrisch
- ▶ Kann ebenfalls als PRE-Maß interpretiert werden
- ▶ Vorzeichen

# Wie wird $\gamma$ berechnet?

- ▶ Paare von Objekten bilden

## Wie wird $\gamma$ berechnet?

- ▶ Paare von Objekten bilden
  - ▶ *Konkordantes* Paar  $A \Leftrightarrow B$ :  $B$  hat mehr von  $x$  (z. B. Bildung) und mehr von  $y$  (z. B. politisches Interesse) als  $A$

# Wie wird $\gamma$ berechnet?

- ▶ Paare von Objekten bilden
  - ▶ *Konkordantes* Paar  $A \Leftrightarrow B$ :  $B$  hat mehr von  $x$  (z. B. Bildung) und mehr von  $y$  (z. B. politisches Interesse) als  $A$
  - ▶ *Diskonkordantes* Paar  $A \Leftrightarrow B$ :  $B$  hat mehr von  $x$  (z. B. Bildung) als  $A$ , aber *weniger* von  $y$  (z. B. politisches Interesse) als  $A$



## Wie wird $\gamma$ berechnet?

- ▶ Paare von Objekten bilden
  - ▶ *Konkordantes* Paar  $A \Leftrightarrow B$ :  $B$  hat mehr von  $x$  (z. B. Bildung) und mehr von  $y$  (z. B. politisches Interesse) als  $A$
  - ▶ *Diskonkordantes* Paar  $A \Leftrightarrow B$ :  $B$  hat mehr von  $x$  (z. B. Bildung) als  $A$ , aber *weniger* von  $y$  (z. B. politisches Interesse) als  $A$
- ▶  $\gamma$ : Verhältnis konkordante – diskonkordante Paare

# Wie wird $\gamma$ berechnet?

- ▶ Paare von Objekten bilden
  - ▶ *Konkordantes* Paar  $A \Leftrightarrow B$ :  $B$  hat mehr von  $x$  (z. B. Bildung) und mehr von  $y$  (z. B. politisches Interesse) als  $A$
  - ▶ *Diskonkordantes* Paar  $A \Leftrightarrow B$ :  $B$  hat mehr von  $x$  (z. B. Bildung) als  $A$ , aber *weniger* von  $y$  (z. B. politisches Interesse) als  $A$
- ▶  $\gamma$ : Verhältnis konkordante – diskonkordante Paare
  - ▶ Konkordante Paare überwiegen: positiver Zusammenhang
  - ▶ Diskonkordante Paare überwiegen: negativer Zusammenhang

# Wie wird $\gamma$ berechnet?

- ▶ Paare von Objekten bilden
  - ▶ *Konkordantes* Paar  $A \Leftrightarrow B$ :  $B$  hat mehr von  $x$  (z. B. Bildung) und mehr von  $y$  (z. B. politisches Interesse) als  $A$
  - ▶ *Diskonkordantes* Paar  $A \Leftrightarrow B$ :  $B$  hat mehr von  $x$  (z. B. Bildung) als  $A$ , aber *weniger* von  $y$  (z. B. politisches Interesse) als  $A$
- ▶  $\gamma$ : Verhältnis konkordante – diskonkordante Paare
  - ▶ Konkordante Paare überwiegen: positiver Zusammenhang
  - ▶ Diskonkordante Paare überwiegen: negativer Zusammenhang
- ▶ Paare mit identischen Werten für eine oder beide Variablen: „ties“

# Wie wird $\gamma$ berechnet?

- ▶ Paare von Objekten bilden
  - ▶ *Konkordantes* Paar  $A \Leftrightarrow B$ :  $B$  hat mehr von  $x$  (z. B. Bildung) und mehr von  $y$  (z. B. politisches Interesse) als  $A$
  - ▶ *Diskonkordantes* Paar  $A \Leftrightarrow B$ :  $B$  hat mehr von  $x$  (z. B. Bildung) als  $A$ , aber *weniger* von  $y$  (z. B. politisches Interesse) als  $A$
- ▶  $\gamma$ : Verhältnis konkordante – diskonkordante Paare
  - ▶ Konkordante Paare überwiegen: positiver Zusammenhang
  - ▶ Diskonkordante Paare überwiegen: negativer Zusammenhang
- ▶ Paare mit identischen Werten für eine oder beide Variablen: „ties“
- ▶ Werden bei  $\gamma$  ignoriert

# Wie berechnet man die Anzahl der Paare?

- ▶ Kreuztabelle aufstellen
- ▶ Anordnung der Kategorien: niedrigste oben/links, höchste unten/rechts
  - ▶ Bildung konkordanter Paare möglich mit allen Objekten rechts und unterhalb der eigenen Zelle
  - ▶ Bildung diskordanter Paare möglich mit Objekten in den Zellen links und unterhalb der eigenen Zelle
- ▶ Zahl der möglichen Paare für zwei Zellen: Produkt der Häufigkeiten beider Zellen
- ▶ Z. B. 10 Personen in der ersten Zelle, 5 in der zweiten Zelle,  $10 \times 5$  verschiedene Paare möglich
- ▶ Auf diese Weise Summe aller konkordanten und dann aller diskordanten Paare bilden

# Beispiel $\gamma$ : Bildung und Nationalstolz

- ▶ Was erwarten Sie?

## Beispiel $\gamma$ : Bildung und Nationalstolz

- ▶ Was erwarten Sie?

	niedrig	mittel	hoch
gar nicht stolz	115	128	181
nicht sehr stolz	267	267	209
ziemlich stolz	731	463	260
sehr stolz	416	138	58

- ▶ Wo sind die **konkordanten Paare**?

## Beispiel $\gamma$ : Bildung und Nationalstolz

- ▶ Was erwarten Sie?

	niedrig	mittel	hoch
gar nicht stolz	115	128	181
nicht sehr stolz	267	267	209
ziemlich stolz	731	463	260
sehr stolz	416	138	58

- ▶ Wo sind die **konkordanten Paare**?
- ▶ Z. B. hier ...



## Beispiel $\gamma$ : Bildung und Nationalstolz

- ▶ Was erwarten Sie?

	niedrig	mittel	hoch
gar nicht stolz	115	128	181
nicht sehr stolz	267	267	209
ziemlich stolz	731	463	260
sehr stolz	416	138	58

- ▶ Wo sind die **konkordanten Paare**?
- ▶ Z. B. hier ... oder hier ...

## Beispiel $\gamma$ : Bildung und Nationalstolz

- ▶ Was erwarten Sie?

	niedrig	mittel	hoch
gar nicht stolz	115	128	181
nicht sehr stolz	267	267	209
ziemlich stolz	731	463	260
sehr stolz	416	138	58

- ▶ Wo sind die **konkordanten Paare**?
- ▶ Z. B. hier ... oder hier ... oder hier

## Beispiel $\gamma$ : Bildung und Nationalstolz

- ▶ Was erwarten Sie?

	niedrig	mittel	hoch
gar nicht stolz	115	128	181
nicht sehr stolz	267	267	209
ziemlich stolz	731	463	260
sehr stolz	416	138	58

- ▶ Wo sind die **konkordanten Paare**?
- ▶ Z. B. hier ... oder hier ... oder hier
- ▶ **Diskonkordante Paare** ...

## Beispiel $\gamma$ : Bildung und Nationalstolz

- ▶ Was erwarten Sie?

	niedrig	mittel	hoch
gar nicht stolz	115	128	181
nicht sehr stolz	267	267	209
ziemlich stolz	731	463	260
sehr stolz	416	138	58

- ▶ Wo sind die **konkordanten Paare**?
- ▶ Z. B. hier ... oder hier ... oder hier
- ▶ **Diskonkordante Paare** ... oder hier

## Beispiel $\gamma$ : Bildung und Nationalstolz

- ▶ Was erwarten Sie?

	niedrig	mittel	hoch
gar nicht stolz	115	128	181
nicht sehr stolz	267	267	209
ziemlich stolz	731	463	260
sehr stolz	416	138	58

- ▶ Konkordant:

## Beispiel $\gamma$ : Bildung und Nationalstolz

- ▶ Was erwarten Sie?

	niedrig	mittel	hoch
gar nicht stolz	115	128	181
nicht sehr stolz	267	267	209
ziemlich stolz	731	463	260
sehr stolz	416	138	58

- ▶ Konkordanz:

- ▶  $115 \times (267+209+463+260+138+58) = 160\,425$
- ▶  $128 \times (209+260+58) = 67\,456$
- ▶  $267 \times (463+260+138+58) = 245\,373$
- ▶  $267 \times (260+58) = 84\,906$
- ▶  $731 \times (138+58) = 143\,276$
- ▶  $463 \times 58 = 26\,854$

## Beispiel $\gamma$ : Bildung und Nationalstolz

- ▶ Was erwarten Sie?

	niedrig	mittel	hoch
gar nicht stolz	115	128	181
nicht sehr stolz	267	267	209
ziemlich stolz	731	463	260
sehr stolz	416	138	58

- ▶ Konkordanz: 728 290

- ▶  $115 \times (267+209+463+260+138+58) = 160\,425$
- ▶  $128 \times (209+260+58) = 67\,456$
- ▶  $267 \times (463+260+138+58) = 245\,373$
- ▶  $267 \times (260+58) = 84\,906$
- ▶  $731 \times (138+58) = 143\,276$
- ▶  $463 \times 58 = 26\,854$

## Beispiel $\gamma$ : Bildung und Nationalstolz

- ▶ Was erwarten Sie?

	niedrig	mittel	hoch
gar nicht stolz	115	128	181
nicht sehr stolz	267	267	209
ziemlich stolz	731	463	260
sehr stolz	416	138	58

- ▶ Diskonkordant:



## Beispiel $\gamma$ : Bildung und Nationalstolz

- ▶ Was erwarten Sie?

	niedrig	mittel	hoch
gar nicht stolz	115	128	181
nicht sehr stolz	267	267	209
ziemlich stolz	731	463	260
sehr stolz	416	138	58

- ▶ Diskonkordant:

- ▶  $128 \times (267 + 731 + 416) = 180\,992$
- ▶  $181 \times (267 + 267 + 731 + 463 + 416 + 138) = 413\,042$
- ▶  $267 \times (731 + 416) = 306\,249$
- ▶  $209 \times (731 + 463 + 416 + 138) = 365\,332$
- ▶  $463 \times 416 = 192\,608$
- ▶  $260 \times (416 + 138) = 144\,040$

## Beispiel $\gamma$ : Bildung und Nationalstolz

- ▶ Was erwarten Sie?

	niedrig	mittel	hoch
gar nicht stolz	115	128	181
nicht sehr stolz	267	267	209
ziemlich stolz	731	463	260
sehr stolz	416	138	58

- ▶ Diskonkordant: 1 602 263

- ▶  $128 \times (267 + 731 + 416) = 180\,992$
- ▶  $181 \times (267 + 267 + 731 + 463 + 416 + 138) = 413\,042$
- ▶  $267 \times (731 + 416) = 306\,249$
- ▶  $209 \times (731 + 463 + 416 + 138) = 365\,332$
- ▶  $463 \times 416 = 192\,608$
- ▶  $260 \times (416 + 138) = 144\,040$

## Beispiel $\gamma$ : Bildung und Nationalstolz

- ▶ Was erwarten Sie?

	niedrig	mittel	hoch
gar nicht stolz	115	128	181
nicht sehr stolz	267	267	209
ziemlich stolz	731	463	260
sehr stolz	416	138	58

$$\gamma = \frac{N_c - N_D}{N_C + N_D} = \frac{728290 - 1602263}{728290 + 1602263} = -0.375$$

# Interpretation von $\gamma$

►  $N_c = N_D \rightarrow \gamma = 0$

## Interpretation von $\gamma$

- ▶  $N_c = N_D \rightarrow \gamma = 0$
- ▶  $\gamma$  meist relativ hoch
- ▶  $\frac{75-25}{75+25} = 0.5$

## Interpretation von $\gamma$

- ▶  $N_c = N_D \rightarrow \gamma = 0$
- ▶  $\gamma$  meist relativ hoch
- ▶  $\frac{75-25}{75+25} = 0.5$
- ▶ Ties werden komplett ignoriert
- ▶ Potentiell viel verlorene Information
  - ▶ Irreführende Werte möglich
  - ▶  $\gamma$  reagiert u. U. nicht auf Veränderungen in Tabelle

## Was sind ties?

	niedrig	mittel	hoch
gar nicht stolz	115	128	181
nicht sehr stolz	267	267	209
ziemlich stolz	731	463	260
sehr stolz	416	138	58

- ▶ Paare mit identischem Wert für Spaltenvariable ( $x$ ) – „tied in  $x$ “,  $T_x$
- ▶ Paare mit identischem Wert für Zeilenvariable ( $y$ ) – „tied in  $y$ “,  $T_y$
- ▶ Paare mit identischen Werten für beide Variablen – relativ uninteressant
- ▶ Verschiedene alternative Koeffizienten berücksichtigen ties

$\tau_b$ 

$$\tau_b = \frac{N_C - N_D}{\sqrt{(N_C + N_D + T_x) \times (N_C + N_D + T_Y)}}$$



$\tau_b$ 

$$\tau_b = \frac{N_C - N_D}{\sqrt{(N_C + N_D + T_x) \times (N_C + N_D + T_Y)}}$$

- ▶ Identisch mit  $\gamma$  wenn keine ties

$\tau_b$ 

$$\tau_b = \frac{N_C - N_D}{\sqrt{(N_C + N_D + T_x) \times (N_C + N_D + T_Y)}}$$

- ▶ Identisch mit  $\gamma$  wenn keine ties
- ▶ Ansonsten kleiner als  $\gamma$  weil Nenner größer

$\tau_b$ 

$$\tau_b = \frac{N_C - N_D}{\sqrt{(N_C + N_D + T_x) \times (N_C + N_D + T_Y)}}$$

- ▶ Identisch mit  $\gamma$  wenn keine ties
- ▶ Ansonsten kleiner als  $\gamma$  weil Nenner größer
- ▶ Somers'  $D$  – asymmetrische Variante von  $\tau_b$

## Somers' $D$

$$D_{yx} = \frac{N_C - N_D}{N_C + N_D + T_Y} \quad \text{mit } y \text{ als abhängiger Variable}$$

- ▶ Identisch mit  $\gamma$  wenn keine ties
- ▶ Ansonsten kleiner als  $\gamma$  weil Nenner größer
- ▶ Somers'  $D$  – asymmetrische Variante von  $\tau_b$

## Somers' $D$

$$D_{yx} = \frac{N_C - N_D}{N_C + N_D + T_Y} \quad \text{mit } y \text{ als abhängiger Variable}$$

- ▶ Identisch mit  $\gamma$  wenn keine ties
- ▶ Ansonsten kleiner als  $\gamma$  weil Nenner größer
- ▶ Somers'  $D$  – asymmetrische Variante von  $\tau_b$
- ▶ Zahlreiche andere Maße

## Warum nominale/intervallskalierte Variable?

- ▶ Viele Variablen (näherungsweise) intervallskaliert
- ▶ Z. B. Einkommen, Testwerte, LRS ...
- ▶ Vergleich über Gruppen (Geschlecht, Länder etc.)
- ▶ Zusammenhangsmaß:  $\eta$  bzw.  $\eta^2$
- ▶ PRE-Maß/asymmetrisch
- ▶ Kann Gruppenzugehörigkeit Vorhersage der abhängigen Variablen verbessern?

## Wie wird $\eta$ berechnet?

- ▶ Beste Prognose für intervallskalierte Variable?

# Wie wird $\eta$ berechnet?

- ▶ Beste Prognose für intervallskalierte Variable?
- ▶ Arithmetisches Mittel
  - ▶ Summe einfache Abweichungen = 0
  - ▶ Summe quadrierte Abweichungen minimal



# Wie wird $\eta$ berechnet?

- ▶ Beste Prognose für intervallskalierte Variable?
- ▶ Arithmetisches Mittel
  - ▶ Summe einfache Abweichungen = 0
  - ▶ Summe quadrierte Abweichungen minimal
- ▶ Maß für Vorhersagefehler: SAQ

# Wie wird $\eta$ berechnet?

- ▶ Beste Prognose für intervallskalierte Variable?
- ▶ Arithmetisches Mittel
  - ▶ Summe einfache Abweichungen = 0
  - ▶ Summe quadrierte Abweichungen minimal
- ▶ Maß für Vorhersagefehler: SAQ
- ▶ Reduktion SAQ bei Kenntnis der Gruppenzugehörigkeit?
  - ▶ Vorhersage globaler Mittelwert
  - ▶ Vs. Vorhersage Gruppenmittelwerte

## Wie wird $\eta$ berechnet?

- ▶  $SAQ_{gesamt}$ : Summe der quadrierte Abweichungen vom *gemeinsamen* Durchschnitt
- ▶  $SAQ_{Kategorien}$ : Summe der Summen der quadrierten Abweichungen vom jeweiligen Gruppendurchschnitt

 $\eta^2$ 

$$\eta^2 = \frac{SAQ_{gesamt} - SAQ_{Kategorien}}{SAQ_{gesamt}}$$

# Ein Beispiel: FN 2004 (drei Regionen)

Region	$x$	$(x - \bar{x}_{kat})$	$(x - \bar{x}_{kat})^2$	$(x - \bar{x}_{ges})$	$(x - \bar{x}_{ges})^2$
Basse-Normandie	12.6	-1.9	3.4	-2.9	8.3
$\bar{x}_{B-N} = 14.5$	14.1	-0.4	0.1	-1.4	2.0
	16.7	2.2	5.0	1.2	1.5
$\Sigma$		0.0	8.6		
Limousin	8.3	-0.9	0.8	-7.2	52.0
$\bar{x}_L = 9.2$	9.2	0.0	0.0	-6.3	40.3
	10.1	0.9	0.8	-5.4	29.6
$\Sigma$		0.0	1.6		
Picardie	24.1	1.2	1.5	8.6	73.5
$\bar{x}_P = 22.9$	24.9	2.1	4.2	9.4	88.6
	19.6	-3.3	10.8	4.1	16.6
$\Sigma$		0.0	16.5		
$\Sigma\Sigma$			26.7	0.0	312.4

$$\bar{x}_{ges} = 15.5$$

# Ein Beispiel: FN 2004 (drei Regionen)

Region	$x$	$(x - \bar{x}_{kat})$	$(x - \bar{x}_{kat})^2$	$(x - \bar{x}_{ges})$	$(x - \bar{x}_{ges})^2$
Basse-Normandie	12.6	-1.9	3.4	-2.9	8.3
$\bar{x}_{B-N} = 14.5$	14.1	-0.4	0.1	-1.4	2.0
	16.7	2.2	5.0	1.2	1.5
$\Sigma$		0.0	8.6		
Limousin	8.3	-0.9	0.8	-7.2	52.0
$\bar{x}_L = 9.2$	9.2	0.0	0.0	-6.3	40.3
	10.1	0.9	0.8	-5.4	29.6
$\Sigma$		0.0	1.6		
Picardie	24.1	1.2	1.5	8.6	73.5
$\bar{x}_P = 22.9$	24.9	2.1	4.2	9.4	88.6
	19.6	-3.3	10.8	4.1	16.6
$\Sigma$		0.0	16.5		
$\Sigma\Sigma$			26.7	0.0	312.4

$$\bar{x}_{ges} = 15.5$$

$$\eta^2 = \frac{312.4 - 26.7}{312.4} = 0.91$$


# Warum zwei intervallskalierte Variablen?

- ▶ *Wenn* Intervallskalierung plausible Annahme, eine der häufigsten Konstellationen
- ▶ LRS  $\Leftrightarrow$  Konservatismus-Skala
- ▶ Proportionalität des Wahlsystems  $\Leftrightarrow$  (effektive) Zahl der Parteien
- ▶ (Relative) Größe des tertiären Sektors  $\Leftrightarrow$  Anteil der Postmaterialisten
- ▶ Arbeitslosenquote  $\Leftrightarrow$  Stimmenanteil Extreme Rechte

## Was ist die Logik von Pearson's $r$ (Korrelationskoeffizient)?

- ▶ Beste unbedingte Vorhersage: arithmetisches Mittel; SAQ = Vorhersagefehler
- ▶ Zwei intervallskalierte Variablen  $\rightarrow$  zwei Mittelwerte, zwei SAQ
- ▶ Visualisierung durch Streudiagramm
  - ▶ Positiver Zusammenhang: überdurchschnittliche Werte von  $x$ , überdurchschnittliche Werte von  $y$  und umgekehrt
  - ▶ Negativer Zusammenhang: überdurchschnittliche Werte von  $x$ , *unter*durchschnittliche Werte von  $y$  und umgekehrt
- ▶ Starke Zusammenhänge mit bloßem Auge erkennbar
- ▶  $r$ : quantifiziert Stärke, symmetrisch, PRE-Maß


# ALQ und FN 2004 in 9 Départements



$$\bar{x} = 6.7; \bar{y} = 15.5$$



# ALQ und FN 2004 in 9 Départements




$$\bar{x} = 6.7; \bar{y} = 15.5$$

# Wie läßt sich die *gemeinsame* Streuung zweier Variablen erfassen?

- ▶ Ein Fall ist nicht mit dem Mittelwert identisch
- ▶ Für eine Variable: quadrierte Abweichung vom Mittelwert  $\bar{x}$
- ▶ Für zwei Variablen: Produkt der Abweichungen von *beiden* Mittelwerten  $\bar{x}, \bar{y}$  – „Abweichungsprodukt“
  - ▶ Positives Abweichungsprodukt: bezüglich beider Variablen über- oder unterdurchschnittlich
  - ▶ Negatives Abweichungsprodukt: überdurchschnittlich bei einer, unterdurchschnittlich bei anderer Variablen
  - ▶ Vgl. mit  $\gamma$

# Abweichungsprodukt für einen Fall



$$AP = (x_i - \bar{x}) \times (y_i - \bar{y}) = (8.5 - 6.7) \times (24.1 - 15.5) = 15.6$$

# Abweichungsprodukte für alle Fälle: Summe Abweichungsprodukte

No.	$x_i$	$x_i - \bar{x}$	$y_i$	$y_i - \bar{y}$	$(x_i - \bar{x}) \times (y_i - \bar{y})$
2	8.5	1.8	24.1	8.6	15.6
14	7.4	0.7	12.6	-2.9	-2.1
19	5.1	-1.6	8.3	-7.2	11.4
23	5.5	-1.2	9.2	-6.3	7.5
50	6.1	-0.6	14.1	-1.4	0.8
60	7.4	0.7	24.9	9.4	6.8
61	6.2	-0.5	16.7	1.2	-0.6
80	8.4	1.7	19.6	4.1	7.0
87	5.5	-1.2	10.1	-5.4	6.4
		0.0		0.0	52.8

# Kovarianz und Korrelation

- ▶ Kovarianz =  $\frac{SAP}{n} = \frac{52.8}{9} = 5.9 = \text{cov}(x, y)$ 
  - ▶ Wertebereich  $-\infty; +\infty$
  - ▶ Vgl.  $\chi^2$
  - ▶ Abhängig von Stärke und Skalierung
- ▶ Kovarianz durch Produkt beider Standardabweichungen teilen  
→ Korrelationskoeffizient  $r$

## Korrelationskoeffizient

$$r = \frac{\text{cov}(x, y)}{s_x \times s_y} = \frac{\frac{SAP}{n}}{\sqrt{\frac{SAQ_x}{n}} \times \sqrt{\frac{SAQ_y}{n}}} = \frac{SAP}{\sqrt{SAQ_x \times SAQ_y}}$$

# Kovarianz und Korrelation II

## Korrelationskoeffizient

$$\frac{SAP}{\sqrt{SAQ_x \times SAQ_y}} = \frac{52.8}{\sqrt{13.1 \times 312.2}} = \frac{52.8}{64.1} = 0.82$$

- ▶ Bringt Kovarianz auf standardisierten Wertebereich
- ▶ Wertebereich [-1;+1]
- ▶ 0 = kein Zusammenhang
- ▶  $r^2$  symmetrisches PRE-Maß
- ▶ Wie stark reduziert Kenntnis von  $x$  Vorhersagefehler von  $y$  (SAQ) und umgekehrt?
- ▶  $\eta^2 \Leftrightarrow r^2$ , unterschiedliche Skalenniveaus/Berechnungsvorschriften

# Zusammenfassung

- ▶ Zusammenhang – gemeinsame Verteilung zweier Variablen
- ▶ Vielzahl von Zusammenhangsmaßen
- ▶ Skalenniveau beachten