

Willkommen zur Vorlesung Statistik

Thema dieser Vorlesung:
Analyse von Kreuztabellen

Prof. Dr. Wolfgang Ludwig-Mayerhofer

Universität Siegen – Philosophische Fakultät, Seminar für Sozialwissenschaften

Inhaltsübersicht

- Einführung
- Maße für die Stärke des Zusammenhangs
- Drittvariablenkontrolle
- Inferenzstatistik, Teil I
- Assoziationsmaße
- Inferenzstatistik, Teil II

Organisatorisches (WiSe 2019/20)

- Die Frist für **Anmeldung der Studien- oder Prüfungsleistung** läuft seit gestern!
Achtung: Ich gewähre prinzipiell **keine** Möglichkeit zur Nachmeldung.
- Im **Januar (Beginn 8. 1.)** findet jeweils Mittwochs von 14 bis 16 Uhr ein mündliches Tutorium statt, in dem der Stoff noch einmal durchgesprochen / wiederholt wird. Besonders empfehlenswert für jene, die noch Fragen haben – aber es dürfen alle kommen, die an Wiederholung Interesse haben.
Raum: **AR-HB 101/102**.

Achtung: Prozentuierungsrichtung II

Hier die gleiche Tabelle mit Zeilenprozentwerten (innerhalb jeder Teiltabelle!).

	1990		2010	
	Arbeiter	Andere	Arbeiter	Andere
Berufliche Bildung	29	71	15	85
Studium	17	83	14	86
n	500	1500	300	1700

Die Aussage „Der Anteil der Arbeiterkinder unter den Studierenden ist zurückgegangen“ wird häufig so interpretiert, als hätten die Arbeiterkinder schlechtere Chancen, zu studieren. Tatsächlich ist aber einfach der Anteil der Arbeiter in der Bevölkerung zurückgegangen (während die Chancen der Arbeiterkinder stärker gestiegen sind als die der Kinder aus anderen Elternhäusern).

Achtung: Prozentuierungsrichtung III

Achtung: Es ist selbstverständlich erlaubt, die unabhängige Variable in den Zeilen (und die abhängige in den Spalten) abzutragen; dies empfiehlt sich vor allem, wenn die unabhängige Variable eine größere Zahl von Ausprägungen hat. Für Ursache-Wirkungs-Aussagen ist entscheidend:

Prozentuiert wird innerhalb der einzelnen Ausprägungen der unabhängigen Variablen über die verschiedenen Ausprägungen der abhängigen Variablen – gleichgültig, ob die unabhängige Variable in den Spalten oder in den Zeilen steht.

Und: Auch die Prozentuierung innerhalb der Ausprägungen der abhängigen Variablen kann sinnvoll sein – sie führt aber zu anderen Aussagen, nämlich solchen über die Zusammensetzung der unterschiedlichen Gruppen. Beispiel: Unter den Personen mit beruflicher Ausbildung waren im Jahr 1990 29 Prozent Arbeiterkinder.

Prozentsatzdifferenz, RR und OR im Vergleich

- Prozentsatzdifferenz: $0 = \text{kein}$, $> 0 = \text{positiver}$, $< 0 = \text{negativer}$ Zusammenhang
- RR: $1 = \text{kein}$, $> 1 = \text{positiver}$, $< 1 = \text{negativer}$ Zusammenhang
- OR: $1 = \text{kein}$, $> 1 = \text{positiver}$, $< 1 = \text{negativer}$ Zusammenhang

Aber: Richtung des Zusammenhang hängt davon ab, welche Ausprägungen wie zueinander in Beziehung gesetzt werden.

Abschließendes zu Prozentsatzdifferenz, RR oder OR?

Bei Berechnung von Prozentsatzdifferenz, relativem Risiko oder Odds Ratio muss immer angegeben werden, welche Ausprägungen zu einander in Beziehung gesetzt werden (z. B.: relatives Risiko der Arbeiterkinder im Vergleich zu den Angestelltenkindern hinsichtlich Haupt-/Realschulbesuch vs. Besuch eines Gymnasiums).

Das gilt erst recht bei größeren Tabellen (mehr Zeilen und/oder mehr Spalten). Für die Berechnung der hier diskutierten Größen muss man auch bei solchen Tabellen zwei Zeilen und zwei Spalten auswählen, die genau zu bezeichnen sind.

Auf der Suche nach Kausalität: Mehrdimensionale Tabellen

Bivariate Tabellen können über den wahren Ursache-Wirkungs-Zusammenhang täuschen.

Ein fiktives Beispiel: Zusammenhang zwischen Aufsuchen eines Arztes bei Erkältung und Geschwindigkeit der Heilung.

Heilung	absolute Zahlen			Spaltenprozent	
	Arzt	kein Arzt	n	Arzt	kein Arzt
Rasch	262	232	494	44	59
Langsam	328	159	487	56	41
n	590	391	981	100	100

Nach Benninghaus, Hans: Deskriptive Statistik. Eine Einführung für Sozialwissenschaftler. 9. überarbeitete Auflage. Wiesbaden: Westdeutscher Verlag, 2002, S. 263.

Auf der Suche nach Kausalität: Drittvariablenkontrolle

Leichte Erkältung

Heilung	absolute Zahlen			Spaltenprozent	
	Arzt	kein Arzt	n	Arzt	kein Arzt
Rasch	126	188	314	85	83
Langsam	23	38	61	15	17
n	149	226	375	100	100

Schwere Erkältung

Heilung	absolute Zahlen			Spaltenprozent	
	Arzt	kein Arzt	n	Arzt	kein Arzt
Rasch	136	44	180	31	27
Langsam	305	121	426	69	73
n	441	165	606	100	100

Mehr zu Drittvariablenkontrolle

Das Beispiel der vorstehenden Folien zeigt die Aufdeckung von nur scheinbar bestehenden Zusammenhängen („Scheinkorrelation“).

Drittvariablenkontrolle dient auch der Aufdeckung nur scheinbarer Nicht-Zusammenhänge bzw. dem Nachweis unterschiedlicher Wirkungen. Dazu noch ein (wiederum fiktives, aber nicht unrealistisches) Beispiel: Zusammenhang zwischen Besuch des Tutoriums und Bestehen der Statistik-Klausur.

Klausur	absolute Zahlen			Spaltenprozent	
	Tutorium	kein Tut.	n	Tutorium	kein Tut.
Nicht bestanden	20	40	60	20	20
Bestanden	80	160	240	80	80
n	100	200	300	100	100

Drittvariablenkontrolle

Angst vor Statistik

Klausur	absolute Zahlen			Spaltenprozent	
	Tutorium	kein Tut.	n	Tutorium	kein Tut.
Nicht bestanden	15	16	31	25	44
Bestanden	45	20	65	75	56
n	60	36	96	100	100

Keine Angst vor Statistik

Klausur	absolute Zahlen			Spaltenprozent	
	Tutorium	kein Tut.	n	Tutorium	kein Tut.
Nicht bestanden	5	24	29	12,5	15
Bestanden	35	140	175	87,5	85
n	40	164	204	100	100

Grenzen der Drittvariablenkontrolle

Die Drittvariablenkontrolle durch Kreuztabellenanalyse ist beschränkt:

- Ein viertes Merkmal ist nur mehr sehr schwer kontrollierbar, weitere praktisch gar nicht mehr.
- Es fehlt eine Möglichkeit, den relativen Einfluss der Merkmale zu beurteilen.
- Metrische Merkmale (vor allem mit vielen Merkmalen) müssen (u.U. stark) zusammengefasst werden (Informationsverlust!).

Die Lösung: Multivariate Modellierung → Auf Wiedersehen im Master-Studium!

Einen ersten Einblick gibt es aber in der Vorlesung über lineare Regressionsanalyse (beschränkt auf metrische abhängige Variable).

Der χ^2 -Test nach Karl Pearson

Liegt in Stichprobendaten ein Zusammenhang vor, wollen wir in der Regel prüfen, ob wir annehmen können, dass auch in der Grundgesamtheit ein Zusammenhang besteht. Im Falle von Kreuztabellen kann hierfür der χ^2 -Test nach Karl Pearson geeignet sein.

Zur Erinnerung die vier Schritte bei Signifikanztests:

- 1 Formulierung der Hypothesen
- 2 Festlegung der Teststatistik
- 3 Festlegung des Signifikanzniveaus
- 4 Berechnung der Teststatistik und Entscheidung

Der χ^2 -Test: Schritt 1

Unsere Frage: Können wir annehmen, dass der Unterschied in den Anteilswerten in unserer Stichprobe auch in der Grundgesamtheit besteht?

Schritt 1: Formulierung der Hypothesen.

- Nullhypothese: Es besteht *kein* Zusammenhang zwischen den beiden Merkmalen.
Präziser: Die Verteilung der abhängigen Variablen ist über alle Ausprägungen der unabhängigen Variablen identisch.
- Alternativhypothese: Es besteht (irgend)ein Zusammenhang zwischen den beiden Merkmalen.
Präziser: Die Verteilung der abhängigen Variablen unterscheidet sich je nach Ausprägung der unabhängigen Variablen.

Es wird also keine gerichtete Hypothese formuliert!

Der χ^2 -Test: Schritt 2

Die **Teststatistik** zur Prüfung der Nullhypothese bezieht sich auf die Abweichung der absoluten Häufigkeiten, die unter der Nullhypothese zu erwarten wären, von den beobachteten Häufigkeiten. Je größer die Abweichung, desto unplausibler ist die Nullhypothese.

Werte, die bei Gültigkeit der Nullhypothese (Unabhängigkeit der Merkmale) zu erwarten wären:

	Arbeiter	Angestellter	n
Haupt-/Realschule	252	378	630
	63 %	63 %	63 %
Gymnasium	148	222	370
	37 %	37 %	37 %
n	400	600	1000

Die Verteilung der Werte in den Spalten entspricht der prozentualen Randverteilung über alle Gruppen.

Der χ^2 -Test: Schritt 2

Die genaue Formel zur Berechnung der Teststatistik finden Sie in Schritt 4. Diese Teststatistik folgt der sog. χ^2 -Verteilung; diese hat unterschiedliche Werte je nach Zahl der Freiheitsgrade (siehe dazu Schritt 3).

Anwendungsvoraussetzungen des χ^2 -Tests:

- Der Test ist nur gültig, wenn gilt: $e_{ij} > 5$ für alle (oder: die meisten) e_{ij} .
- Außerdem soll evtl. bei $n < 60$ die sog. Kontinuitätskorrektur nach Yates verwendet werden (das ist aber unter Statistikern umstritten). Bei sehr kleinen Fallzahlen ($n < 30$) muss zu sog. exakten Testverfahren gegriffen werden (hier nicht behandelt).

Im vorliegenden Fall gibt es in beiden Hinsichten keine Probleme, wir können also den χ^2 -Test bedenkenlos anwenden.

Assoziationsmaße

Zusammenhänge in größeren Kreuztabellen lassen sich im Prinzip durch eine Vielzahl von Prozentsatzdifferenzen/Relativen Risiken/Odds Ratios ausdrücken. Diese sind dann aber kaum mehr zusammenhängend zu interpretieren. Assoziationsmaße (die es im übrigen auch für Vier-Felder-Tabellen gibt) sind Versuche, die Stärke des Zusammenhanges in einer einzigen Maßzahl auszudrücken.

Die Vielzahl entsprechender Maßzahlen verbietet eine ausführliche Diskussion. Die folgende Übersicht gibt nur einige Hinweise. Die meisten Maßzahlen sind aus statistischer Sicht auch wenig sinnvoll, sie werden jedoch immer wieder verwendet.

Die wichtigste Unterscheidung betrifft das Messniveau (Skalenniveau): Maße für nominalskalierte Variablen (oder eine nominal- und eine ordinalskalierte Variable) sind von Maßen für zwei ordinalskalierte Variable zu unterscheiden.

Bei den erstgenannten unterscheiden wir zwischen χ^2 -basierten und sonstigen Maßen.

χ^2 -basierte Assoziationsmaße

Die χ^2 -Teststatistik wird bei gegebenen Fallzahlen umso größer, je stärker der Zusammenhang ist. Sie wird jedoch grundsätzlich ganz wesentlich von der Fallzahl beeinflusst.

χ^2 -basierte Assoziationsmaße korrigieren daher den χ^2 -Wert um die Fallzahl.

Sie nehmen idealerweise Werte zwischen 0 (kein Zusammenhang) und 1 (perfekter Zusammenhang) an. Dies gilt jedoch nicht für C. Für den Koeffizienten ϕ gibt es auch Berechnungsformeln, nach denen er Werte zwischen -1 (perfekter negativer) und $+1$ (perfekter positiver) Zusammenhang annehmen kann.

χ^2 -basierte Assoziationsmaße sind nicht sinnvoll, wenn beide Merkmale ordinalskaliert sind, weil es dann besser geeignete Maßzahlen gibt.

χ^2 -basierte Assoziationsmaße

Name	Berechnung	Anmerkungen
ϕ (phi)	$\sqrt{\frac{\chi^2}{n}}$	Nur für 2x2-Tabellen geeignet; kann bei alternativer Berechnung auch Werte bis -1 annehmen.
V	$\sqrt{\frac{\chi^2}{n \cdot (\min(I, J) - 1)}}$	I: Zahl der Werte von X; J: Zahl der Werte von Y Voller Name: Cramérs V
C	$\sqrt{\frac{\chi^2}{\chi^2 + n}}$	Voller Name: Kontingenzkoeffizient. Achtung: $\text{Max}(C) < 1!$

Weitere Assoziationsmaße I: Yules Q

Die Maßzahl Q (ebenfalls für Vier-Felder-Tabellen geeignet) wird u. a. in den Lehrbüchern von Kühnel & Krebs oder Andreas Diekmann (Empirische Sozialforschung) empfohlen.

Sie ist jedoch mit größter Vorsicht zu genießen: Sie nimmt den Wert 1 (oder -1) an, wenn eine einzige Zelle die Häufigkeit Null aufweist. Daher kann Q nicht zwischen den beiden folgenden Tabellen (angegeben sind absolute Zahlen) unterscheiden:

	Arbeiter	Angestellte	Arbeiter	Angestellte
Haupt-/Realschule	400	590	400	0
Gymnasium	0	10	0	600

Weitere Assoziationsmaße II: λ

Die Maßzahl λ (lambda) wird ebenfalls von Kühnel & Krebs empfohlen. Der Nachteil: Sie nimmt den Wert 0 an, wenn die Modalwerte pro Spalte alle in der gleichen Zeile auftreten. So beträgt der Wert von Lambda in beiden folgenden Tabellen 0:

	Arbeiter	Angestellte	Arbeiter	Angestellte
Haupt-/Realschule	210	310	400	310
Gymnasium	190	290	0	290

Alternatives Maß mit ähnlicher Logik: Goodmans und Kruskals Tau (nicht mit den nachfolgenden diskutierten Tau-a, -b und -c zu verwechseln).

Assoziationsmaße für ordinalskalierte Merkmale II

Weil man bei zwei ordinalskalierten Merkmalen die Richtung des Zusammenhangs angeben kann, sollten Assoziationsmaße verwendet werden, die die Richtung durch das Vorzeichen ausdrücken.

Für die folgenden Maße gilt, dass sie zwischen minimal -1 (perfekt negativer Zusammenhang) und maximal $+1$ (perfekt positiver Zusammenhang) liegen können. Der Wert 0 signalisiert einen fehlenden (gerichteten) Zusammenhang.

- Kendalls τ (tau) in den Varianten tau-a, tau-b und tau-c (am häufigsten verwendet: τ -b).
- Goodmans und Kruskals Gamma (wird gerne von Angebern verwendet, weil es große Werte annimmt; leidet an ähnlichem Problem wie Yules Q).
- Somers' d (unterscheidet zwischen unabhängiger und abhängiger Variable, wird aber besonders selten verwendet).

Für die Tabelle auf der vorherigen Folie beträgt Gamma $0,32$, tau-b $0,23$.

Assoziationsmaße für ordinalskalierte Merkmale III

Leider ist die Erläuterung dieser Assoziationsmaße recht aufwändig. Sie steht in keiner Relation zu ihrer statistischen Bedeutung (sie werden zwar immer wieder eingesetzt, sind jedoch veraltet).

Daher verzichte ich auf diese Erläuterung (wer will, kann bei Kühnel & Krebs nachlesen) und bespreche lieber das Problem der statistischen Absicherung von Zusammenhängen in Kreuztabellen mit zwei ordinalskalierten Merkmalen.

Hat man es mit ordinalskalierten Merkmalen zu tun und nimmt man einen gerichteten Zusammenhang an (je ... desto [weniger]), ist der Signifikanztest für das verwendete Assoziationsmaß dem χ^2 -Test vorzuziehen, da letzterer auf Abweichungen von den erwarteten Werten in *beliebiger* Richtung reagiert.

Es kann daher vorkommen, dass der χ^2 -Test einen signifikanten Zusammenhang andeutet, obwohl der *theoretisch angenommene* Zusammenhang keineswegs signifikant ist, und umgekehrt.

