

Achim Bühl

# SPSS

Version 14

Einführung in die moderne Datenanalyse

10. überarbeitete Auflage

**Unser Online-Tipp  
für noch mehr Wissen ...**



... aktuelles Fachwissen rund  
um die Uhr – zum Probelesen,  
Downloaden oder auch auf Papier.

**[www.InformIT.de](http://www.InformIT.de)**

Anstatt über das Grafikmenü zu gehen, können Sie auch in der Dialogbox *Kreuztabellen* die Option *Gruppierte Balkendiagramme anzeigen* aktivieren. Sie erhalten dann in einem Diagramm zwei nach der Zeilenvariablen getrennte Darstellungen. Wünschen Sie im gegebenen Beispiel die Anordnung wie in Bild 10.9, müssen Sie Zeilen- und Spaltenvariable vertauschen.

## 10.3 Statistiken für Kreuztabellen

Um Statistiken für Kreuztabellen zu erhalten, klicken Sie auf die Schaltfläche *Statistik...* in der Dialogbox *Kreuztabellen*. Es öffnet sich die Dialogbox *Kreuztabellen: Statistik*.

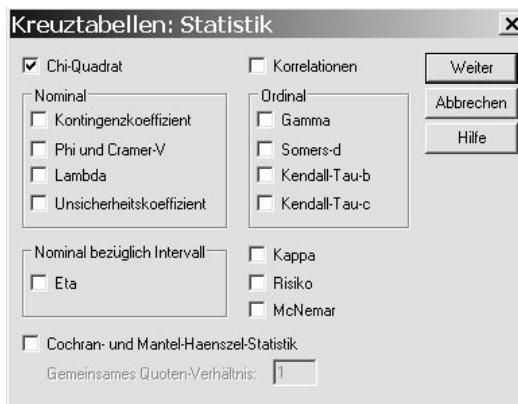


Bild 10.10: Dialogbox Kreuztabellen: Statistik

Die aufgeführten Kontrollfelder ermöglichen Ihnen die Wahl einer oder mehrerer der folgenden Statistiken.

- ▶ Chi-Quadrat-Test
- ▶ Korrelationen
- ▶ Assoziationsmaße für nominalskalierte Variablen
- ▶ Assoziationsmaße für ordinalskalierte Variablen
- ▶ Assoziationsmaße für intervallskalierte Variablen
- ▶ Kappa-Koeffizient
- ▶ Risiko
- ▶ Mc Nemar-Test
- ▶ Cochran- und Mantel-Haenszel-Statistik

Diese Statistiken sollen in den beiden folgenden Abschnitten behandelt werden, wobei dem Chi-Quadrat-Test seiner großen Bedeutung wegen ein eigener Abschnitt gewidmet ist.

### 10.3.1 Chi-Quadrat-Test

Der Chi-Quadrat-Test überprüft die Unabhängigkeit der beiden Variablen der Kreuztabelle und damit indirekt den Zusammenhang der beiden Merkmale. Zwei Variablen einer Kreuztabelle gelten dann als voneinander unabhängig, wenn die beobachteten Häufigkeiten ( $f_o$ ) der einzelnen Zeilen mit den erwarteten Häufigkeiten ( $f_e$ ) übereinstimmen.  $F_o$  steht hierbei für frequencies observed,  $f_e$  für frequencies expected. Um den Chi-Quadrat-Test aufzurufen, gehen Sie wie folgt vor:

- Wählen Sie aus dem Menü

*Analysieren*

*Deskriptive Statistiken*

*Kreuztabellen...*

- Übertragen Sie die Variable klasse in die Zeilenliste, die Variable überlebt in die Spaltenliste.
- Klicken Sie auf die Schaltfläche *Zellen...* Aktivieren Sie in der Dialogbox *Kreuztabellen: Zellen anzeigen* neben der voreingestellten Option *Beobachtet* die Optionen *Erwartet* und *Standardisiert*. Bestätigen Sie mit *Weiter*.
- Klicken Sie auf die Schaltfläche *Statistik...*

Es öffnet sich die bereits beschriebene Dialogbox *Kreuztabellen: Statistik*.

- Aktivieren Sie die Option *Chi-Quadrat*. Bestätigen Sie anschließend mit *Weiter* und klicken Sie in der Dialogbox *Kreuztabellen* auf *OK*.

Sie erhalten die folgende Kreuztabelle.

			Überlebt?		Gesamt
Klasse	1. Klasse	Anzahl	Gerettet	Gestorben	
		Erwartete Anzahl	201	123	324
		Standardisierte Residuen	124,2	199,8	324,0
	2. Klasse	Anzahl	6,9	-5,4	
		Erwartete Anzahl	118	158	276
		Standardisierte Residuen	105,8	170,2	276,0
	3. Klasse	Anzahl	1,2	-.9	
		Erwartete Anzahl	183	527	710
		Standardisierte Residuen	272,1	437,9	710,0
	Gesamt	Anzahl	-5,4	4,3	
		Erwartete Anzahl	502	808	1310
			502,0	808,0	1310,0

Im Viewer werden ferner die Ergebnisse des Chi-Quadrat-Tests angezeigt:

Chi-Quadrat-Tests			
	Wert	df	Asymptotische Signifikanz (2-seitig)
Chi-Quadrat nach Pearson	126,679 <sup>a</sup>	2	,000
Likelihood-Quotient	126,533	2	,000
Zusammenhang linear-mit-linear	126,465	1	,000
Anzahl der gültigen Fälle	1310		

<sup>a</sup> 0 Zellen (,0%) haben eine erwartete Häufigkeit kleiner 5. Die minimale erwartete Häufigkeit ist 105,76.

Zur Berechnung des Chi-Quadrat-Werts werden drei verschiedene Formeln benutzt: die nach Pearson, Likelihood und linear-mit-linear. Handelt es sich bei der Kreuztabelle um eine Vierfeldertafel und ist eine erwartete Häufigkeit kleiner als 5, so wird zusätzlich der exakte Test nach Fisher ausgeführt.

### Chi-Quadrat nach Pearson

Die übliche Formel zur Berechnung des Chi-Quadrat-Werts ist diejenige nach Pearson:

$$\chi^2 = \sum \frac{(f_o - f_e)^2}{f_e}$$

Mathematisch äquivalent zu dieser Formel des Chi-Quadrat-Werts ist die folgende:

$$\chi^2 = \sum \left( \frac{f_o - f_e}{\sqrt{f_e}} \right)^2$$

Der Chi-Quadrat-Wert stellt somit die Summe der Quadrate der standardisierten Residuen dar, die über alle Felder der Kreuztabelle gebildet wird. Die Felder der Kreuztabelle mit hohen standardisierten Residuen liefern demnach einen hohen Beitrag zum Chi-Quadrat-Wert und damit zu einem signifikanten Ergebnis. Nach der bereits zitierten Faustregel zeigt ein standardisiertes Residuum von 2 oder größer eine signifikante Abweichung der beobachteten von der erwarteten Häufigkeit an.

Im gegebenen Beispiel ergibt sich nach Pearson ein höchst signifikanter Chi-Quadrat-Wert ( $p < 0,001$ ). Betrachtet man die standardisierten Residuen in den einzelnen Feldern der Kreuztabelle, so erkennt man, dass diese Signifikanz in den Feldern der ersten und zweiten Klasse (jeweils gerettet und gestorben) begründet liegt. Bei Passagieren der ersten Klasse ist die Überlebenswahrscheinlichkeit deutlich erhöht, während sie bei der dritten Klasse deutlich zu niedrig ist. Anhand der standardisierten Residuen zeigt sich noch einmal die Mittellage der zweiten Klasse.

Der Chi-Quadrat-Wert nach Pearson lässt sich auf Basis der Formel am Beispiel des Unterganges der Titanic wie folgt berechnen, wobei leichte Abweichungen vom Endergebnis des SPSS-Outputs durch Rundungen zustande kommen.

$f_o$	$f_e$	$f_o - f_e$	$\sqrt{f_e}$	$\frac{f_o - f_e}{\sqrt{f_e}}$	$\left( \frac{f_o - f_e}{\sqrt{f_e}} \right)^2$
201	124,2	76,8	11,14	6,89	47,47
123	199,8	-76,8	14,13	-5,43	29,48
118	105,8	12,2	10,28	1,19	1,42
158	170,2	-12,2	13,05	-0,93	0,86
183	272,1	-89,1	16,49	-5,40	29,16
527	437,9	89,1	20,93	4,26	18,15
$\Sigma$					126,54

Fassen wir noch einmal zusammen: Für jedes Feld der Tabelle werden die quadrierten Abweichungen der erwarteten von den tatsächlichen Häufigkeiten durch die erwarteten Häufigkeiten dividiert. Die Quotienten werden anschließend addiert. Das Quadrieren sorgt dafür, dass negative wie positive Abweichungen gleichermaßen in das Maß eingehen und sich nicht wechselseitig aufheben. Die Division durch die erwarteten Häufigkeiten erfolgt, da sich sonst bei vielen Beobachtungen auch mehr Abweichungen ergeben würden. Je größer die Abweichung in einem Feld der Tabelle ist, umso größer fällt auch das Chi-Quadrat aus. Ein großes Chi-Quadrat ist mit großen Abweichungen verbunden und deutet auf einen Zusammenhang zwischen den Variablen hin.

Aus wahrscheinlichkeitstheoretischen Überlegungen lässt sich angeben, mit welcher Wahrscheinlichkeit sich ein Chi-Quadrat bestimmter Größenordnung ergibt, wenn die Variablen unabhängig voneinander sind. Dieser Zusammenhang wird mit Hilfe der so genannten Freiheitsgrade (df) der Kreuztabelle dargestellt. Die Anzahl der Freiheitsgrade bestimmt sich wie folgt: Freiheitsgrade = (Zeilen – 1) \* (Spalten – 1). Eine Kreuztabelle wie in unserem Fall mit drei Zeilen und zwei Spalten besitzt also  $2 * 1 = 2$  Freiheitsgrade, die in der Tabelle des Chi-Quadrat-Tests ausgewiesen werden. Mit Hilfe des Chi-Quadrat-Werts und der Anzahl der Freiheitsgrade lässt sich die Wahrscheinlichkeit ermitteln, mit der sich die vorliegende Abweichung für unabhängige Variablen ergibt.

Der Chi-Quadrat-Test setzt voraus, dass nur in maximal 20% der Felder der Kreuztabelle erwartete Häufigkeiten < 5 auftreten dürfen. Zeilen- und Spaltensummen müssen stets größer als null sein. Im vorliegenden Beispiel ist diese Voraussetzung voll und ganz erfüllt.

Sollte die Voraussetzung auf der Basis der Kreuztabelle nicht erfüllt sein, so erfolgt eine entsprechende Warnung, welche angibt, wie viel Prozent der Felder der Kreuztabelle eine erwartete Häufigkeit kleiner als 5 besitzen.

### **Likelihood-Quotienten-Chi-Quadrat**

Eine Alternative zum Pearson'schen Chi-Quadrat-Wert ist das Likelihood-Quotienten-Chi-Quadrat:

$$\chi^2 = -2 \cdot \sum f_o \cdot \ln \frac{f_e}{f_o}$$

Für große Stichprobenumfänge ergeben das Pearson'sche Chi-Quadrat und das Likelihood-Quotienten-Chi-Quadrat sehr ähnliche Ergebnisse. In unserem Beispiel liegt ein Likelihood-Quotienten-Wert von 126,533 vor.

### **Mantel-Haenszel-Test**

Angezeigt wird zusätzlich unter der Bezeichnung »linear-mit-linear« noch der Wert der Mantel-Haenszel-Teststatistik (126,465). Das Mantel-Haenszel-Chi-Quadrat ist ein weiteres Maß für den linearen Zusammenhang zwischen den Zeilen und Spalten einer Kreuztabelle. Es wird berechnet, indem man das Quadrat des Pearson'schen Korrelationskoeffizienten mit der Anzahl der Fälle minus 1 multipliziert:

$$\chi^2 = r^2 \cdot (n - 1)$$

Die sich ergebende Statistik hat einen Freiheitsgrad. Die Mantel-Haenszel-Statistik wird stets mit ausgegeben, wenn in der Dialogbox *Kreuztabellen: Statistik* die Option *Chi-Quadrat* aktiviert wird. Für nominale Daten sollte jedoch die Mantel-Haenszel-Statistik nicht verwendet werden.

### 10.3.2 Korrelationsmaße

Bislang haben wir nur die Existenz eines statistischen Zusammenhangs zwischen zwei Merkmalen überprüft. Im Folgenden wollen wir uns mit der Frage beschäftigen, welche Aussagen wir über die Stärke bzw. Schwäche eines Zusammenhangs sowie über die Art und die Richtung der Beziehung treffen können. Maßzahlen zur Quantifizierung eines solchen Zusammenhangs zwischen Variablen nennt man Korrelations- bzw. Assoziationsmaße. Zwei Variablen sind positiv korreliert, wenn eine gleichläufige bzw. gleichsinnige Beziehung vorliegt. Bei einer gleichsinnigen Beziehung gehen niedrige Werte bei der einen Variablen mit niedrigen Werten bei der anderen Variablen einher, hohe Werte mit hohen Werten. Zwei Variablen sind negativ korreliert, wenn eine gegenläufige bzw. gegensinnige Beziehung vorliegt. Bei einer gegensinnigen Beziehung gehen niedrige Werte bei der einen Variablen mit hohen Werten bei der anderen Variablen einher und umgekehrt. Korrelationsmaße nehmen stets Werte zwischen -1 und +1 an.

Als Korrelationsmaß zwischen ordinalen Variablen wird der Spearman'sche Korrelationskoeffizient benutzt, bei intervallskalierten und normalverteilten Variablen der Pearson'sche Produkt-Moment-Korrelationskoeffizient. Zu beachten ist dabei, dass jede nominalskalierte Variable, die zweifach abgestuft (dichotom) ist, als ordinalskalierte Variable betrachtet werden kann.

Wir wollen zunächst die Variablen klasse und überlebt der Datei titanic.sav auf Korrelation prüfen. Beachten Sie dabei, dass die dichotome Variable sex als gleichsam ordinalskaliert angesehen werden kann. Gehen Sie wie folgt vor:

- Wählen Sie aus dem Menü

*Analysieren*

*Deskriptive Statistiken*  
*Kreuztabellen...*

- Übertragen Sie die Variable klasse in die Zeilenliste und die Variable überlebt in die Spaltenliste.
- Klicken Sie auf die Schaltfläche *Statistik...* Aktivieren Sie in der Dialogbox *Kreuztabellen: Statistik* die Option *Korrelationen*. Bestätigen Sie mit *Weiter*.
- Deaktivieren Sie in der Dialogbox *Kreuztabellen* die Ausgabe von Tabellen durch Anklicken der Option *Keine Tabellen*. Bestätigen Sie anschließend mit *OK*.

Es werden der Spearman'sche sowie der Pearson'sche Korrelationskoeffizient berechnet sowie ihre Signifikanzüberprüfung ausgegeben:

## Symmetrische Maße

		Wert	Asymptotischer Standardfehler <sup>a</sup>	Näherungsweises $t^b$	Näherungsweise Signifikanz
Intervall- bzgl. Intervallmaß	Pearson-R	,311	,027	11,827	,000 <sup>c</sup>
Ordinal- bzgl. Ordinalmaß Anzahl der gültigen Fälle	Korrelation nach Spearman	,308 1310	,027	11,698	,000 <sup>c</sup>

a. Die Null-Hypothese wird nicht angenommen.

b. Unter Annahme der Null-Hypothese wird der asymptotische Standardfehler verwendet.

c. Basierend auf normaler Näherung

Da keine intervallskalierten Variablen vorliegen, betrachten wir den Spearman'schen Korrelationskoeffizienten. Er beträgt 0,308 und ist höchst signifikant ( $p < 0,001$ ).

Ziehen Sie zur verbalen Beschreibung der Größe des jeweiligen Korrelationskoeffizienten folgende Tabelle zu Rate:

Werte des Korrelationskoeffizienten r	Interpretation
0 < r <= 0,2	Sehr geringe Korrelation
0,2 < r <= 0,5	Geringe Korrelation
0,5 < r <= 0,7	Mittlere Korrelation
0,7 < r <= 0,9	Hohe Korrelation
0,9 < r <= 1	Sehr hohe Korrelation

Ausgehend von der obigen Tabelle können wir folgende Aussagen treffen: Zwischen den Variablen klasse und überlebt liegt eine geringe Korrelation vor (Aussage über die Stärke der Beziehung), die Variablen sind positiv korreliert (Aussage über die Richtung der Beziehung).

Bei der Variablen klasse liegen die Werte »1« für die erste Klasse, »2« für die zweite Klasse und »3« für die dritte Klasse vor, die Variable überlebt verfügt über die Merkmalsausprägung »1« für gerettet sowie »2« für gestorben.

Die Gleichläufigkeit der Beziehung kann demzufolge so interpretiert werden, dass niedrige Werte der Variablen klasse mit niedrigen Werten der Variablen überlebt einhergehen sowie hohe Werte der einen Variablen mit hohen Werten der anderen Variablen, dass also Passagiere der ersten Klasse häufiger zu den Überlebenden zählen als Passagiere der dritten Klasse.

Prüfen wir nun die Variablen sex und überlebt auf Korrelation. Gehen Sie dabei wie oben beschrieben vor. Sie erhalten folgende Korrelationskoeffizienten:

Symmetrische Maße

		Wert	Asymptotischer Standardfehler <sup>a</sup>	Näherungsweises T <sup>b</sup>	Näherungsweise Signifikanz
Intervall- bzgl. Intervallmaß	Pearson-R	-,525	,024	-22,289	,000 <sup>c</sup>
Ordinal- bzgl. Ordinalmaß	Korrelation nach Spearman	-,525	,024	-22,289	,000 <sup>c</sup>
Anzahl der gültigen Fälle		1310			

a. Die Null-Hypothese wird nicht angenommen.

b. Unter Annahme der Null-Hypothese wird der asymptotische Standardfehler verwendet.

c. Basierend auf normaler Näherung

Da es sich bei den Variablen sex und überlebt um zwei nominalskalierte dichotome Variablen handelt, die wir als gleichsam (»quasi«) ordinal behandeln, betrachten wir auch hier den Korrelationskoeffizienten nach Spearman. Er beträgt -0,525. Zwischen den Variablen sex und überlebt liegt somit eine mittlere Korrelation vor. Die Variablen sind negativ korreliert. Niedrige Werte der Variablen sex gehen folglich mit hohen Werten der Variablen überlebt einher, hohe Werte der Variablen sex mit niedrigen Werten der Variablen überlebt. Berücksichtigt man die Codierung der beiden Variablen (»1« = männlich und »2« = weiblich bei der Variablen sex sowie »1« = gerettet und »2« = gestorben bei der Variablen überlebt), so ergibt sich die Tatsache, dass die Überlebenswahrscheinlichkeit der Frauen an Bord der Titanic höher gewesen ist als die der Männer.

Prüfen wir abschließend die Variablen klasse und alter auf Korrelation. Sie erhalten folgende Korrelationskoeffizienten:

Symmetrische Maße

		Wert	Asymptotischer Standardfehler <sup>a</sup>	Näherungsweises T <sup>b</sup>	Näherungsweise Signifikanz
Intervall- bzgl. Intervallmaß	Pearson-R	-,413	,025	-15,608	,000 <sup>c</sup>
Ordinal- bzgl. Ordinalmaß	Korrelation nach Spearman	-,402	,026	-15,097	,000 <sup>c</sup>
Anzahl der gültigen Fälle		1187			

a. Die Null-Hypothese wird nicht angenommen.

b. Unter Annahme der Null-Hypothese wird der asymptotische Standardfehler verwendet.

c. Basierend auf normaler Näherung

Da die Variable klasse lediglich ordinalskaliert ist, betrachten wir auch hier wieder den Spearman'schen Korrelationskoeffizienten; er beträgt -0,402. Zwischen den Variablen klasse und alter liegt eine geringe Korrelation vor. Die Variablen korrelieren negativ (gegenläufig), d.h., je größer die Werte der ersten Variablen sind, umso niedriger sind die Werte der zweiten Variablen und umgekehrt. Berücksichtigt man die Codierung der beiden Variablen, so ist davon auszugehen, dass ältere Personen eher in der ersten Klasse zu finden sind sowie jüngere Passagiere häufiger in der dritten Klasse, was eine entsprechende Kreuztabelle zwischen der Klassenzugehörigkeit an Bord der Titanic und dem Alter gruppiert nach Altersklassen verdeutlicht.

Klasse \* Alter in Klassen Kreuztabelle

			Alter in Klassen				Gesamt	
			Bis 14 Jahre	15-30 Jahre	31-50 Jahre	Über 50 Jahre		
Klasse	1. Klasse	Anzahl	7	81	143	67	298	
		Erwartete Anzahl	28,6	148,4	95,0	26,1	298,0	
		Standardisierte Residuen	-4,0	-5,5	4,9	8,0		
	2. Klasse	Anzahl	26	123	89	20	258	
		Erwartete Anzahl	24,7	128,5	82,2	22,6	258,0	
		Standardisierte Residuen	,3	-,5	,7	-,5		
	3. Klasse	Anzahl	81	388	147	17	633	
		Erwartete Anzahl	60,7	315,2	201,8	55,4	633,0	
		Standardisierte Residuen	2,6	4,1	-3,9	-5,2		
Gesamt		Anzahl	114	592	379	104	1189	
		Erwartete Anzahl	114,0	592,0	379,0	104,0	1189,0	

Während in der zweiten Klasse keine Auffälligkeiten festzustellen sind, liegt der Anteil der Passagiere in der ersten Klasse, die 30 Jahre und jünger sind, deutlich zu niedrig, der Anteil der Passagiere, die 31 Jahre und älter sind, deutlich zu hoch. In der dritten Klasse zeigt sich ein gegenläufiger Trend. Besonders stark in das Chi-Quadrat-Maß geht die Kategorie der über 50-Jährigen ein mit einem standardisierten Residuum von +8,0 bei der ersten Klasse und -5,2 bei der dritten Klasse.

### 10.3.3 Assoziationsmaße für nominalskalierte Variablen

Der Korrelationskoeffizient als Maß für den Zusammenhang zwischen zwei Variablen ist nicht anwendbar bei nominalskalierten Variablen mit mehr als zwei Kategorien, da die betreffenden Kodierungen keiner Ordnungsrelation folgen und somit nicht sinnvollerweise in einer Richtung angeordnet werden können.

Als bestes Mittel, solche Zusammenhänge zu analysieren, halten wir den in Kap. 10.3.1 vorgestellten Chi-Quadrat-Test mit gegebenenfalls nachfolgender Analyse der beobachteten und erwarteten Häufigkeiten sowie der standardisierten Residuen.

Dennoch versuchte man auch hier, Maßzahlen für den Grad der »Assoziation« der beiden in Beziehung gesetzten Variablen zu entwickeln. Diese geben dann den Grad der Abhängigkeit bzw. Unabhängigkeit zwischen den beiden nominalskalierten Variablen an, wobei ein Wert um 0 völlige Unabhängigkeit der Variablen bedeutet und ein Wert um 1 größte Abhängigkeit. Negative Werte treten bei den Assoziationsmaßen nicht auf, da die Frage nach einer Richtung der Assoziation wegen des Fehlens einer Ordnungsrelation sinnlos ist.

In einer Mitgliederbefragung des Stadtverbands einer politischen Partei wurde u.a. nach dem Beruf gefragt und danach, ob die Befragten eine Parteifunktion ausüben oder nicht. Die Antworten der männlichen Befragten sind auszugsweise in der Datei *partei.sav* enthalten.

- Laden Sie die Datei *partei.sav* und erstellen Sie eine Kreuztabelle mit der Variablen *funk* als Zeilen- und der Variablen *beruf* als Spaltenvariable.
- Aktivieren Sie die Ausgabe der erwarteten Häufigkeiten, der standardisierten Residuen, der Spaltenprozente und des Chi-Quadrat-Tests.

Sie erhalten die folgende Ausgabe:

Partefunktion \* Beruf Kreuztabelle

			Beruf			Gesamt
			Angestellter	Beamter	Selbstständiger	
Partefunktion	Ja	Anzahl	13	16	7	36
		Erwartete Anzahl	12,4	10,1	13,5	36,0
		% von Beruf	59,1%	88,9%	29,2%	56,3%
		Standardisierte Residuen	,2	1,8	-1,8	
	Nein	Anzahl	9	2	17	28
		Erwartete Anzahl	9,6	7,9	10,5	28,0
		% von Beruf	40,9%	11,1%	70,8%	43,8%
		Standardisierte Residuen	-,2	-2,1	2,0	
Gesamt	Anzahl	22	18	24	64	
	Erwartete Anzahl	22,0	18,0	24,0	64,0	
	% von Beruf	100,0%	100,0%	100,0%	100,0%	

Chi-Quadrat-Tests

	Wert	df	Asymptotische Signifikanz (2-seitig)
Chi-Quadrat nach Pearson	15,017 <sup>a</sup>	2	,001
Likelihood-Quotient	16,421	2	,000
Zusammenhang linear-mit-linear	4,420	1	,036
Anzahl der gültigen Fälle	64		

a. 0 Zellen (,0%) haben eine erwartete Häufigkeit kleiner 5. Die minimale erwartete Häufigkeit ist 7,88.

Es liegt ein höchst signifikantes Ergebnis vor, und zwar sind die Partefunktionen bei den Beamten über- und bei den Selbstständigen unterrepräsentiert, während die Angestellten im Schnitt liegen. Fordern Sie nun zusätzlich über den Schalter *Statistik...* die Ausgabe sämtlicher Assoziationsmaße für nominalskalierte Variablen an.

Richtungsmaße

			Wert	Asymptotischer Standardfehler <sup>a</sup>	Näherungsweise T <sup>b</sup>	Näherungsweise Signifikanz
Nominal- bzgl. Nominalmaß	Lambda	Symmetrisch	,279	,104	2,554	,011
		Partefunktion abhängig	,357	,140	2,111	,035
		Beruf abhängig	,225	,106	1,930	,054
	Goodman-und-Kruskal- Tau	Partefunktion abhängig	,235	,093		,001 <sup>c</sup>
		Beruf abhängig	,116	,051		,001 <sup>c</sup>

a. Die Null-Hypothese wird nicht angenommen.

b. Unter Annahme der Null-Hypothese wird der asymptotische Standardfehler verwendet.

c. Basierend auf Chi-Quadrat-Näherung

**Symmetrische Maße**

		Wert	Näherungsweise Signifikanz
Nominal- bzgl.	Phi	,484	,001
Nominalmaß	Cramer-V	,484	,001
	Kontingenzkoeffizient	,436	,001
Anzahl der gültigen Fälle		64	

- a. Die Null-Hypothese wird nicht angenommen.
- b. Unter Annahme der Null-Hypothese wird der asymptotische Standardfehler verwendet.

Die in den beiden obigen Tabellen wiedergegebenen Assoziationsmaße sollen im Folgenden erläutert werden.

**Kontingenzkoeffizient**

Sein Wert liegt stets zwischen 0 und 1 und berechnet sich – ebenso wie bei Phi und Cramers V – aus dem Chi-Quadrat-Wert:

$$c = \sqrt{\frac{\chi^2}{\chi^2 + N}}$$

N ist dabei die Gesamthäufigkeit der Kreuztabelle. Da N immer größer als Null ist, wird der Wert 1 nie erreicht. Der maximale Wert ist von der Zeilen- und Spaltenzahl der Kreuztabelle abhängig und beträgt z.B. bei einer 3 \* 2 -Tabelle (wie im gegebenen Beispiel) 0,762. Aus diesem Grund ist der Kontingenzkoeffizient zwischen Kreuztabellen mit verschiedenen Felderzahlen nicht vergleichbar.

**Phi**

Dieser Koeffizient ist nur für 2\*2-Tabellen verwendbar, da er sonst den Wert 1 übersteigen kann:

$$\varphi = \sqrt{\frac{\chi^2}{N}}$$

**Cramers V**

Diese Größe ist eine Variante von Phi, die für beliebige Kreuztabellen einen Wert zwischen 0 und 1 ergibt, wobei der Wert 1 auch erreicht werden kann:

$$V = \sqrt{\frac{\chi^2}{N \cdot (k - 1)}}$$

Dabei ist k die kleinere der beiden Anzahlen der Zeilen und Spalten.

Die drei genannten Maße basieren auf der Teststatistik Chi-Quadrat, wobei auf unterschiedliche Weise versucht wird, den Wert auf die Stichprobengröße zu normieren. Da im gegebenen Beispiel in der Formel für Cramers V  $k = 2$  ist, stimmen die Werte für Phi und Cramers V miteinander überein. Die Berechnung der Signifikanz basiert auf dem Chi-Quadrat-Wert.

Bei der Beurteilung der erhaltenen Maßzahlen (zwischen 0,4 und 0,5) ist zu bedenken, dass der Wert 1 nicht oder nur sehr schwer zu erreichen ist. Die anderen Assoziationsmaße (Lambda, Goodman-und-Kruskal-Tau und Unsicherheitskoeffizient) werden nach dem Konzept der so genannten proportionalen Fehlerreduktion berechnet. Bei diesen Maßen wird jeweils eine Variable als abhängige Variable betrachtet; aus diesem Grunde werden diese Maße auch »Richtungsmaße« genannt.

## Lambda

Im gegebenen Beispiel wird man die Frage nach der Partefunktion als abhängige Variable betrachten können, und zwar abhängig vom ausgeübten Beruf. Soll für eine beliebige Person eine Vorhersage darüber getroffen werden, ob sie ein Parteiamt ausübt oder nicht, so wird man natürlich die bestmögliche Vorhersage treffen, wenn man die am häufigsten gegebene Antwort heranzieht, hier also die Ausübung eines Parteiamtes vorhersagen. Es haben nämlich 56,3% der Personen diese Antwort gegeben; in 43,7% der Fälle wird man jedoch eine falsche Vorhersage treffen.

Die Vorhersage kann man verbessern, wenn man die andere Variable, also den Beruf, mit einbezieht. Bei den Angestellten würde man ebenso ein Parteiamt prognostizieren wie bei den Beamten, wobei bei neun Angestellten und bei zwei Beamten eine falsche Vorhersage getroffen würde. Bei den Selbstständigen würde man vorhersagen, dass diese Personen keine Partefunktion ausüben und dabei in sieben Fällen irren. Bei den insgesamt 64 Personen würde also in  $9 + 2 + 7 = 18$  Fällen, das sind 28,1%, eine falsche Prognose gestellt. Die ursprüngliche Fehlerwahrscheinlichkeit von 43,7 % ist also deutlich reduziert worden.

Aus den beiden Fehlerwahrscheinlichkeiten wird die relative Fehlerreduktion berechnet und Lambda genannt:

$$\text{Lambda} = \frac{\text{Fehler bei erster Prognose} - \text{Fehler bei zweiter Prognose}}{\text{Fehler bei erster Prognose}}$$

In unserem Beispiel ergibt sich:

$$\text{Lambda} = \frac{43,7\% - 28,1\%}{43,7\%} = 0,357$$

Erreicht der Fehler bei der zweiten Diagnose den Wert 0, wird Lambda = 1. Ist der Fehler bei der zweiten Prognose gleich dem der ersten Prognose, wird Lambda = 0. Hier liefert die zweite Variable keinerlei Unterstützung bei der Vorhersage der ersten (abhängigen) Variablen; beide Variablen sind völlig unabhängig voneinander.

## **Copyright**

Daten, Texte, Design und Grafiken dieses eBooks, sowie die eventuell angebotenen eBook-Zusatzdaten sind urheberrechtlich geschützt. Dieses eBook stellen wir lediglich als persönliche Einzelplatz-Lizenz zur Verfügung!

Jede andere Verwendung dieses eBooks oder zugehöriger Materialien und Informationen, einschliesslich

- der Reproduktion,
- der Weitergabe,
- des Weitervertriebs,
- der Platzierung im Internet, in Intranets, in Extranets,
- der Veränderung,
- des Weiterverkaufs
- und der Veröffentlichung

bedarf der schriftlichen Genehmigung des Verlags.

Insbesondere ist die Entfernung oder Änderung des vom Verlag vergebenen Passwortschutzes ausdrücklich untersagt!

Bei Fragen zu diesem Thema wenden Sie sich bitte an: [info@pearson.de](mailto:info@pearson.de)

## **Zusatzdaten**

Möglicherweise liegt dem gedruckten Buch eine CD-ROM mit Zusatzdaten bei. Die Zurverfügungstellung dieser Daten auf unseren Websites ist eine freiwillige Leistung des Verlags. Der Rechtsweg ist ausgeschlossen.

## **Hinweis**

Dieses und viele weitere eBooks können Sie rund um die Uhr und legal auf unserer Website



herunterladen