



Reinhold Hatzinger
Herbert Nagel

Statistik mit SPSS

Fallbeispiele und Methoden

2., aktualisierte Auflage

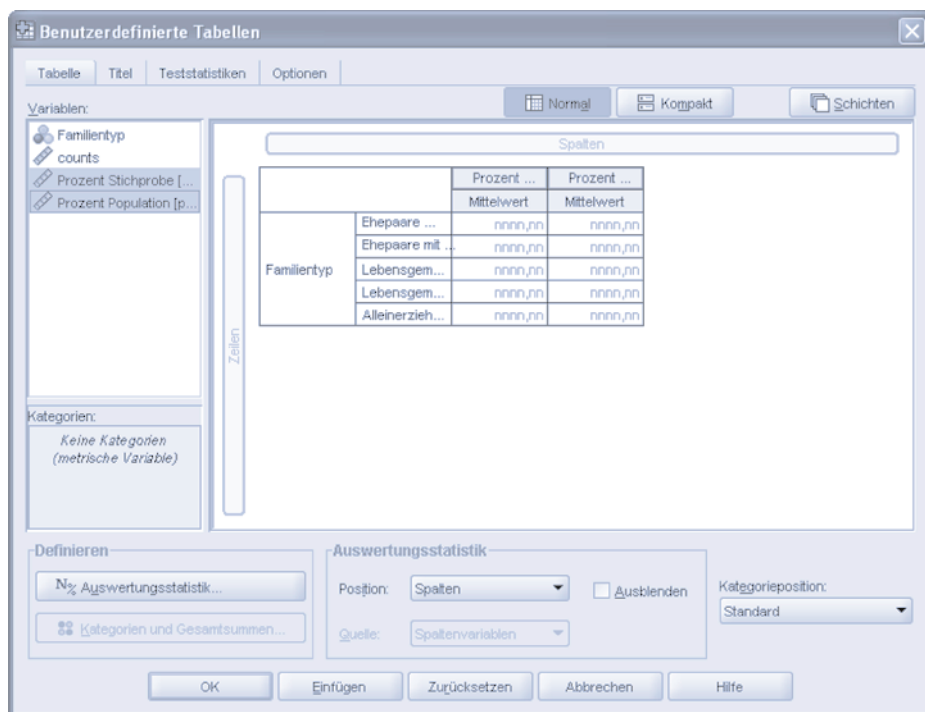


Abbildung 4.20: Dialogfenster Benutzerdefinierte Tabellen zur Erzeugung einer Tabelle aus zwei verschiedenen Variablen

- Aus dem Feld **Variablen** (links oben) zieht man die kategoriale Variable (hier **Familientyp**) auf die Fläche **Zeilen** (in der mittleren Fläche).
- Man markiert die beiden Variablen, für die man die Prozentsätze darstellen will (hier **s.perc** und **p.perc**), wobei man beim Anklicken die **(Strg)**-Taste gedrückt hält.
- Diese zieht man dann auf die Fläche **Spalten**.

Das Resultat ist die Tabelle in ► **Abbildung 4.21**, in der man die Prozentsätze für die Familienarten aus der Stichprobe der Meinungsforscherin und der österreichischen Bevölkerung ablesen kann.

Tabelle 1

		Prozent Stichprobe	Prozent Population
		Mittelwert	Mittelwert
Familientyp	Ehepaare ohne Kinder	21,00	31,20
	Ehepaare mit Kindern	49,00	42,40
	Lebensgemeinschaft ohne Kinder	3,00	7,30
	Lebensgemeinschaft mit Kindern	10,00	6,10
	Alleinerziehende Elternteile	17,00	13,00

Abbildung 4.21: Tabelle mit Prozentsätzen der Familienarten aus einer Stichprobe und der Population

Man erkennt, dass die Prozentsätze differieren. Es fällt auf, dass generell Familien mit Kindern stärker in der Stichprobe vertreten sind als jene ohne Kinder. Da die Umfrage zum Thema einer Gesetzesmaßnahme zur speziellen Förderung von Familien mit Kindern stattfand, könnte eventuell die Bereitschaft zur Beantwortung bei solchen Personen größer gewesen sein, die in einer Familie mit Kindern leben. Auch die Wahrscheinlichkeit, solche Personen eher zu Hause am Festnetz zu erreichen, könnte eine Rolle gespielt haben.

Die Tabelle (Abbildung 4.21) hat einen kleinen Schönheitsfehler, nämlich die Zeile, in der Mittelwert steht. Diese lässt sich leicht entfernen (Abschnitt 3.9.1), allerdings sollten wir damit warten, bis wir die Grafiken erzeugt haben, da SPSS die Mittelwertsfunktion dafür benötigt.

Darstellung verschiedener Variablen in einer Grafik

Zur grafischen Beschreibung der Daten aus Fallbeispiel 2 bieten sich **GRUPPIERTE BALKENDIAGRAMME** an. Sie sind eine Erweiterung der Balkendiagramme aus Abschnitt 4.2.2. Bei gruppierten Balkendiagrammen werden mehrere kategoriale Variablen gleichzeitig oder eine kategoriale Variable aufgeschlüsselt nach verschiedenen Gruppen dargestellt (im Detail gehen wir darauf in Kapitel 7 ein).

SPSS

Diagramme

Diagrammerstellung...

in Galerie auswählen von Balken

Doppelklick auf Galeriediagramm

(die Vorschau erscheint in der Zeichenfläche)

Variable Familientyp in das Feld X-Achse? ziehen

Variablen s.perc und p.perc gemeinsam nach Anzahl ziehen

(Dialogfeld Zusammenfassung erstellen ignorieren)

unter Eigenschaften bearbeiten von wählen von X-Achse1

unter Kleine/leere Kategorien wählen von

Nur in den Daten vorhandene Kategorien anzeigen

, dann

Das so hergestellte gruppierte Balkendiagramm findet sich in ► Abbildung 4.22. Es ist natürlich in dieser Form nicht geeignet für Publikationen, Berichte oder Präsentationen. Durch Verwendung des Diagramm-Editors kann man aber alle notwendig erscheinenden Modifikationen leicht durchführen (siehe Kapitel 1).

Abbildung 4.22 ist zum Vergleich der Prozentsätze aus der Stichprobe und der Population gut geeignet. Man kann sehr schön die Unterschiede und deren Größenordnung erkennen. Es bekräftigt sich der Eindruck, den wir schon aus der Tabelle in

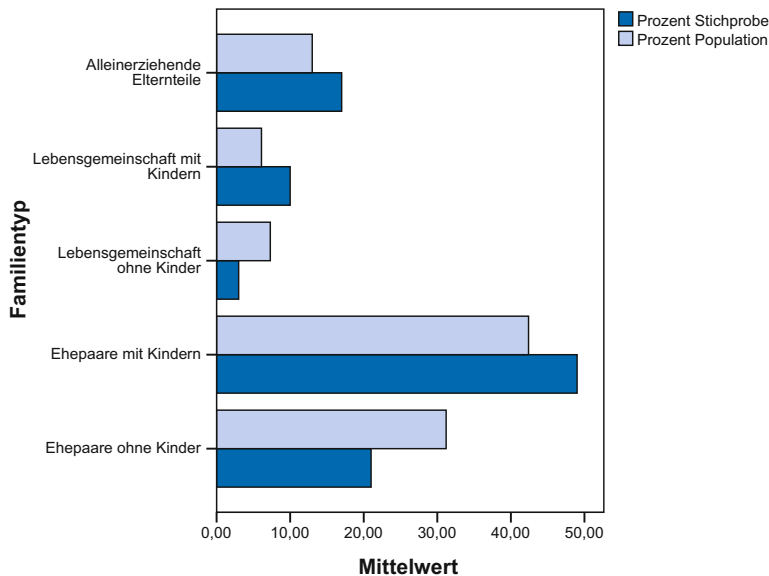


Abbildung 4.22: Transponiertes und umgruppiertes Balkendiagramm mit Prozentsätzen der Familienarten aus einer Stichprobe und der Population

Abbildung 4.21 gewonnen haben. In der Stichprobe sind jene Befragten überproportional vertreten, die in Familien mit Kindern leben. Gegenteiliges gilt für Ehepaare ohne Kinder, die in der Stichprobe unterrepräsentiert sind. Die Frage ist jetzt, sind diese Unterschiede bedeutsam oder nur auf Zufall zurückzuführen.

4.3.2 Statistische Analyse der Problemstellung

Ganz ähnliche Überlegungen, wie wir sie schon im Abschnitt 4.2.3 angestellt haben, treffen auch hier zu. Allerdings ist die Annahme jetzt nicht, dass alle Kategorien gleich häufig vorkommen (Nullhypothese), sondern dass sie in bestimmter Weise festgelegt sind. In unserem Beispiel, der Frage nach Repräsentativität der Stichprobe, sind die festgelegten Anteile jene der Familientypen in der Population. Wir können zwar die Formel (4.1) verwenden, aber wir müssen die erwarteten Häufigkeiten anders bestimmen.

Wir kennen die Anteile in der Population, nämlich 0,312 für Ehepaare ohne Kinder, 0,424 für Ehepaare mit Kindern etc. Wir können aus diesen jene Häufigkeiten bestimmen, die wir erwarten würden, wenn in der Stichprobe der 200 Personen die Stichprobenhäufigkeiten mit den Populationswerten übereinstimmen würden. Wir müssen dazu nur die Populationsanteile mit der Stichprobengröße 200 multiplizieren. Wenn wir eine bezüglich der Familienstruktur repräsentative Stichprobe hätten, dann müssten $200 \times 0,312 = 62,4$, also 62 Befragte der Kategorie Ehepaar kinderlos angehören. Allgemein gilt

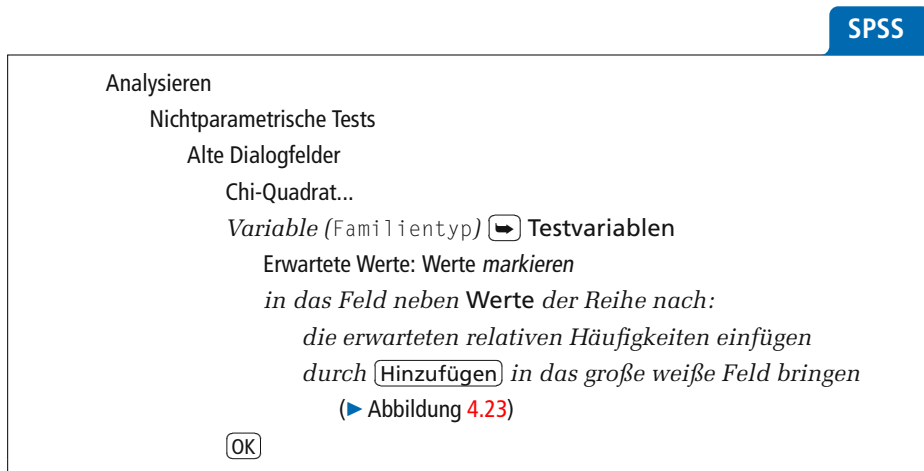
Berechnung von erwarteten Häufigkeiten

$$e_j = n\pi_j \quad (4.2)$$

- e_j ... erwartete Häufigkeit für die Kategorie j
- n ... Stichprobengröße
- π_j ... relative Häufigkeit in der Population
(Wahrscheinlichkeit für Kategorie j)

Die weiteren Schritte sind analog zu Abschnitt 4.2.3. Wenn die Abweichungen zwischen beobachteten und erwarteten Häufigkeiten zu groß werden, verwerfen wir die Nullhypothese, dass die beobachteten Werte mit den erwarteten übereinstimmen. Die Abweichungen werden dann nicht mehr dem Zufall zugeschrieben, sondern man glaubt an einen systematischen Unterschied.

Die Berechnung des Tests in SPSS erfolgt über



Das Ergebnis des Chi-Quadrat-Tests ist in ► Abbildung 4.24 zu sehen. In der oberen Tabelle werden die beobachteten und erwarteten Häufigkeiten dargestellt.

Die untere Tabelle gibt uns das Resultat des Tests. Wie wir am Signifikanzwert sehen, ist die Plausibilität der Nullhypothese sehr klein (der p -Wert ist zumindest kleiner als 0,001, ganz null kann er nie werden). Daher verwerfen wir die Annahme, dass die Stichprobenanteile der einzelnen Familientyp-Kategorien jenen in der Population entsprechen.

Fallbeispiel 2: Interpretation

Der Chi-Quadrat-Test zur Überprüfung der Nullhypothese, dass die Häufigkeiten für die Familienarten in der Stichprobe jenen in der Population entsprechen, zeigt ein signifikantes Ergebnis ($X^2 = 21,2$, $df = 4$, $p < 0,001$). Demnach ist nicht davon auszugehen, dass die Stichprobe bezüglich der Familienarten repräsentativ ist. Familien mit Kindern sind stärker in der Stichprobe vertreten als in der Population.

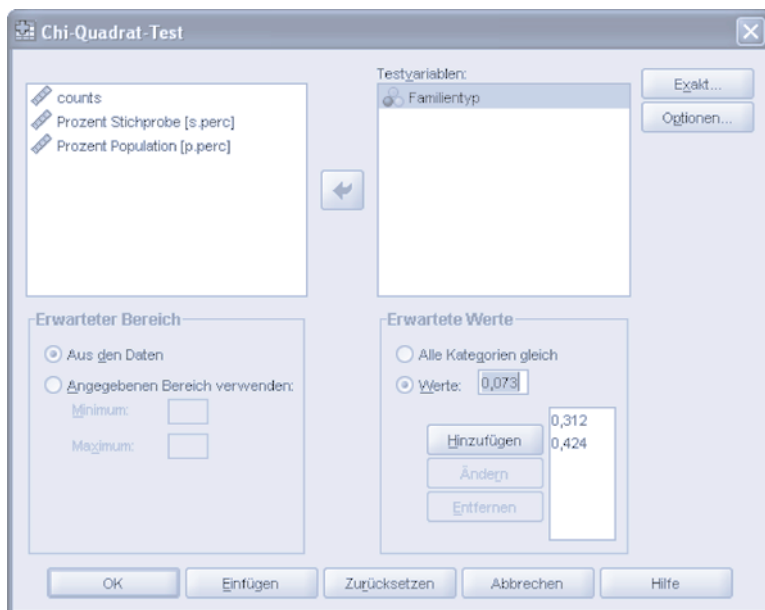


Abbildung 4.23: Chi-Quadrat-Test: Variableauswahl und Spezifikation der erwarteten Anteile

Familiotyp			
	Beobachtetes N	Erwartete Anzahl	Residuum
Ehepaare ohne Kinder	42	62,4	-20,4
Ehepaare mit Kindern	98	84,8	13,2
Lebensgemeinschaft ohne Kinder	6	14,6	-8,6
Lebensgemeinschaft mit Kindern	20	12,2	7,8
Alleinerziehende Elternteile	34	26,0	8,0
Gesamt	200		

Statistik für Test	
Statistik	Variablen Familiotyp
Chi-Quadrat	21,238
df	4
Asymptotische Signifikanz	,000

Abbildung 4.24: Ergebnis des Chi-Quadrat-Tests zur Prüfung der Repräsentativität einer Stichprobe

Alternative Berechnung in SPSS

Auch hier können wir die neuen Prozeduren verwenden, aber so einfach wie in Abschnitt 4.2 und völlig automatisiert geht es jetzt nicht mehr. Zunächst müssen wir unseren Datensatz, wenn Sie das nicht schon gemacht haben, mit der Variable

counts gewichten (vgl. Abschnitt 3.7). Den entsprechenden Test kann man über folgende SPSS-Menüpunkte anfordern:

SPSS

Analysieren

Nichtparametrische Tests

Eine Stichprobe...

unter Ziel: Analyse anpassen

unter Felder: Benutzerdefinierte Feldzuweisungen verwenden,
nur Familientyp im Feld Testfelder

unter Einstellungen und Element auswählen:

Tests anpassen, ... (Test auf Chi-Quadrat-Test), Optionen

markieren von Erwartete Wahrscheinlichkeit anpassen

Werte für erwartete relative Häufigkeiten eintragen

(siehe unten im Text)

OK

Ausführen

Das Subfenster Chi-Quadrat-Test: Optionen, bei dem man dem obigen Ablauf entsprechend die erwarteten relativen Häufigkeiten eintragen soll, sieht folgendermaßen aus (► Abbildung 4.25):

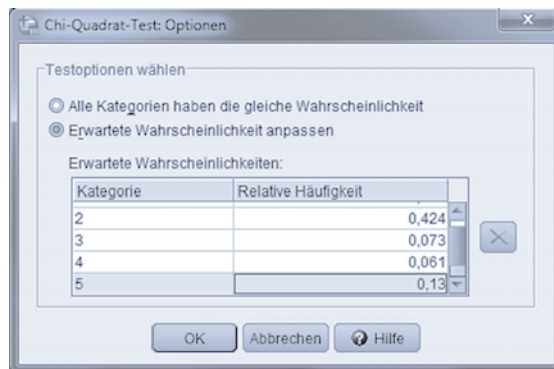


Abbildung 4.25: Eintragen der erwarteten relativen Häufigkeiten

Hier haben wir schon einige Werte eingetragen.

Das Resultat im Ausgabefenster ist nicht sehr informativ, da es nur das Ergebnis des Tests beschreibt, nämlich die Angabe des p -Werts und ob die Nullhypothese verworfen oder beibehalten wird (► Abbildung 4.26).

Etwas mehr Information gibt die Modellanzeige (► Abbildung 4.27) her, die man wieder durch Doppelklick auf die Ergebnistabelle (Abbildung 4.26) öffnet.

Von Interesse ist hierbei das rechte Fenster in Abbildung 4.27. Hier findet man ein gruppiertes Balkendiagramm, das die beobachteten und erwarteten (hypothetischen)

Übersicht über Hypothesentest

	Nullhypothese	Test	Sig.	Entscheidung
1	Die Kategorien von Familientyp treten mit den angegebenen Wahrscheinlichkeiten auf.	Chi-Quadrat-Test einer Stichprobe	,000	Nullhypothese ablehnen.

Asymptotische Signifikanzen werden angezeigt. Das Signifikanzniveau ist ,05.

Abbildung 4.26: Ergebnis des Chi-Quadrat-Tests

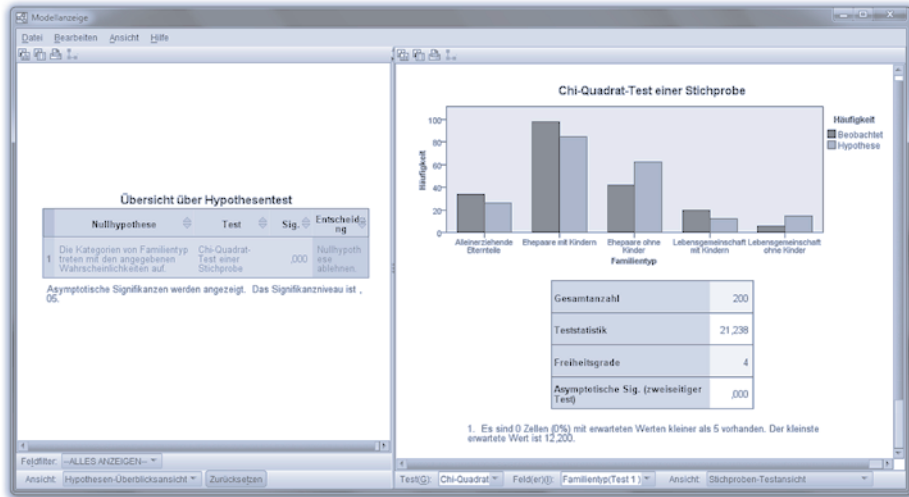


Abbildung 4.27: Ergebnis des Chi-Quadrat-Tests

Häufigkeiten darstellt sowie Informationen zum Chi-Quadrat-Test, wie wir sie auch schon in Abbildung 4.24 erhalten haben. Wenn man den Cursor über die Balken in der Grafik bewegt, erhält man Informationen zu der jeweiligen Kategorie, insbesondere die beobachteten und erwarteten Häufigkeiten.

4.4 Hat ein Prozentsatz (Anteil) einen bestimmten Wert?

Bisher haben wir untersucht, wie man analysieren kann, ob Häufigkeiten bzw. Anteile mehrerer Kategorien bestimmten Vorgaben entsprechen. Jetzt wollen wir uns auf einzelne Kategorien konzentrieren.

Fallbeispiel 3: Fehlerrate bei Lügendetektoren

Datenfile: `detektor.sav`

Nach wie vor gibt es in den USA Bemühungen, den perfekten Lügendetektor zu entwickeln. Neuere Ansätze stammen von Pavlidis et al. (2002), die versuchten, mit einer hochauflösenden, temperatursensiblen Kamera aus Gesichtsaufnahmen Lügen zu entdecken. Rosenfeld (2002) verwendete sogenannte ERPs (ereigniskorrelierte Potentiale), bestimmte Gehirnaktivitätssignale, die mittels an der Kopfhaut angebrachten Elektroden gemessen werden. Er untersuchte Studierende, die unter anderem Sätze, wie *Verwenden Sie einen gefälschten Ausweis?* vorlesen mussten. Es wurde erwartet, dass bei Studierenden, die tatsächlich einen gefälschten Ausweis verwenden, ein entsprechendes Hirnsignal auftritt. Von insgesamt $N = 17$ „Schuldigen“ wurden 13 (77%) richtig erkannt. Bei einer vergleichbaren Studie des amerikanischen Verteidigungsministeriums wurden 75% der „Schuldigen“ mithilfe eines traditionellen klassischen Lügendetektors (Polygraphen) richtig erkannt.

Liefert der neue Lügendetektor bessere Ergebnisse als der traditionelle?

Wenn man die Daten einer einzelnen Kategorie analysieren möchte, dann kann man im Wesentlichen die gleichen Methoden verwenden wie in den vorhergehenden Abschnitt 4.2.3 und Abschnitt 4.3.2. Man muss sich nur vor Augen halten, dass es für diese einzelne Kategorie eigentlich zwei Möglichkeiten gibt, nämlich *trifft zu* bzw. *trifft nicht zu*. Wenn man also eine einzelne Kategorie untersucht, dann verhält sich diese wie eine „neue“ Variable mit zwei Kategorien.

Numerische und grafische Beschreibung

Zur numerischen Beschreibung wird es wohl genügen, eine Häufigkeitstabelle über die Menüpunkte Analysieren ▷ Deskriptive Statistiken ▷ Häufigkeiten wie in Abschnitt 4.2.1 zu erstellen.

Als grafische Darstellung bietet sich wieder ein Balkendiagramm an. In Analogie zu Abschnitt 4.2.2 kann es folgendermaßen erstellt werden.

Diagramme

Diagrammerstellung...

*in Galerie auswählen von Balken**Doppelklick auf linkes oberes Galeriediagramm* *(die Vorschau erscheint in der Zeichenfläche)**Variable ueberfuehrt in das Feld X-Achse? ziehen**unter Eigenschaften bearbeiten von auswählen von Balken**unter Statistiken auswählen von Prozentsatz**unter Eigenschaften bearbeiten von auswählen von X-Achse1**unter Kleine/leere Kategorien wählen von**Nur in den Daten vorhandene Kategorien anzeigen* , dann

Das Resultat findet sich in ► [Abbildung 4.28](#).

Allerdings interessiert für die Fragestellung eigentlich nur die Kategorie ja (überführt). Dazu könnte man ein gestapeltes Balkendiagramm verwenden (diese werden in Abschnitt 5.1.2 genauer erklärt). Und man möchte vielleicht auch noch die 75%-Erfolgsrate der traditionellen Methode darstellen. Das Resultat könnte so aussehen (► [Abbildung 4.29](#)).

Man sieht, dass die Erfolgsrate des neuen Lügendetektors nur unwesentlich höher als jene traditioneller Detektoren ist. Die entsprechende statistische Methode, im




Abbildung 4.28: Balkendiagramm für Erfolg mit neuem Lügendetektor




Abbildung 4.29: Gestapeltes Balkendiagramm mit zweiter Achse und Referenzlinie

nächsten Abschnitt, wird uns darüber Aufschluss geben, ob die Erfolgsrate tatsächlich höher ist oder nicht.

Die Grafik in Abbildung 4.29 ist keine Standard-SPSS-Grafik und ihre Erstellung ist ein wenig komplizierter als das bisher Beschriebene. (Versuchen Sie, diese Abbildung durch Anwenden und Ausprobieren der entsprechenden Bedienelemente im Grafik-Editor zu erstellen. Der Aufwand lohnt sich.)

4.4.1 Statistische Analyse der Problemstellung

Die Frage, die wir untersuchen wollen, lautet: Liefert der neue Lügendetektor bessere Ergebnisse als der traditionelle? Übersetzt in eine statistische Fragestellung, könnte man auch so formulieren: Ist die relative Häufigkeit des Erfolgs des neuen Lügendetektors (in Wirklichkeit) höher als die relative Häufigkeit des Erfolgs nach der traditionellen Methode.

Als statistische Hypothesen formuliert:

- Nullhypothese $H_0: \pi = 0,75$
Die relative Häufigkeit des Erfolgs nach der neuen Methode, π , entspricht der relativen Häufigkeit des Erfolgs nach der traditionellen Methode ($\pi_0 = 0,75$).
- Alternativhypothese $H_A: \pi > 0,75$
Die relative Häufigkeit des Erfolgs nach der neuen Methode, π , ist größer als die relative Häufigkeit des Erfolgs nach der traditionellen Methode ($\pi_0 = 0,75$).

Allgemein würde man schreiben:

Hypothesen beim Test eines Anteils

$H_0: \pi = \pi_0$ (Nullhypothese)

$H_A: \pi > \pi_0$ (Alternativhypothese)

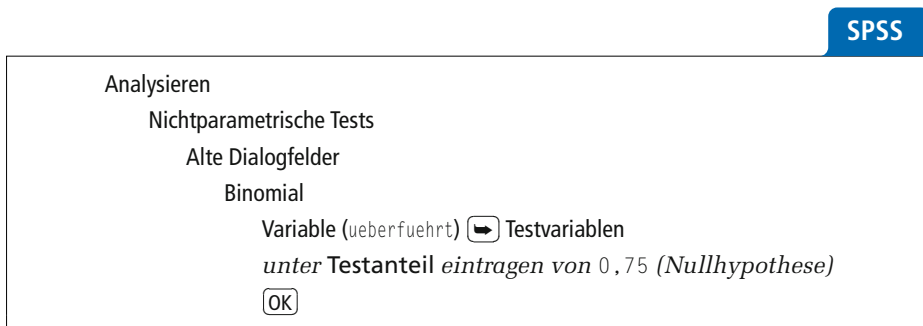
- π ... die unbekannte wirkliche relative Häufigkeit des Erfolgs mit der neuen Methode
Da wir sie nicht kennen, aber etwas über sie wissen wollen, verwenden wir für sie r , die beobachtete relative Häufigkeit aus der Stichprobe.
- π_0 ... der Wert, den wir kennen (oder den wir festlegen) und gegen den wir prüfen wollen, in unserem Beispiel ist er 0,75.

Die statistische Problemstellung ist von der Idee her gleich, wie wir sie schon in Abschnitt 4.2.3 kennengelernt haben:

- Wir gehen davon aus, dass in Wirklichkeit die relative Häufigkeit des Erfolgs nach der neuen Methode jener der traditionellen Methode entspricht, dass also tatsächlich H_0 gilt.
- Wir sammeln Daten aus einer Stichprobe (nach der neuen Methode), berechnen die relative Häufigkeit r (sie ist die beste Information, die wir für das unbekannte π haben) und vergleichen sie mit jener Zahl, die wir kennen, nämlich 0,75. Allgemein können wir π_0 statt 0,75 einsetzen.
- Da wir ja eine Zufallsstichprobe verwenden, wird r nicht genauso groß wie π sein, sondern ein wenig abweichen. Wenn die Abweichung aber zu groß wird, dann werden wir nicht glauben, dass H_0 , sondern eher dass H_A gilt.
- Die Prüfmethode zur Entscheidung, welche der beiden Hypothesen zutrifft, nennen wir statistischer Test.

Im Unterschied zum Chi-Quadrat-Test aus Abschnitt 4.2.3 und Abschnitt 4.3.2, wo wir absolute Häufigkeiten (beobachtete und erwartete) verglichen haben, beschäftigen wir uns jetzt mit Anteilen oder relativen Häufigkeiten (auch beobachtete, nämlich r , und erwartete, nämlich π_0). Der Test, den wir jetzt verwenden werden, heißt **EIN-STICHPROBEN-TEST FÜR ANTEILE** bzw. **BINOMIAL-TEST**.

In SPSS führen wir diesen Test folgendermaßen durch:



Das Ergebnis ist in ► Abbildung 4.30 dargestellt. Neben den absoluten (N) finden wir die relativen Häufigkeiten (Beobachteter Anteil), den Wert, den wir für die H_0 spezifiziert haben (Testanteil) sowie den p -Wert (Exakte Signifikanz 1-seitig). Dieser ist 0,574 und damit wesentlich größer als 0,05. Wir behalten daher die Nullhypothese bei. Die Erfolgsrate beim neuen Lügendetektor ist demnach nicht höher als beim traditionellen Lügendetektor.

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

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:

<http://ebooks.pearson.de>