

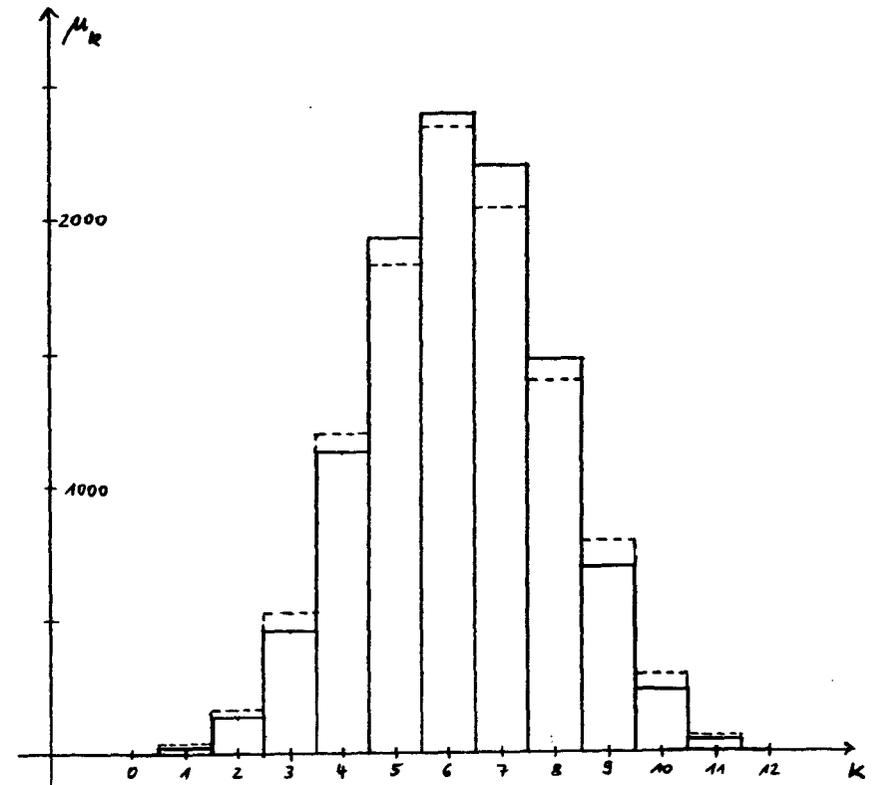
VERTEILUNG DER GESCHLECHTER IN FAMILIEN

von HEINZ KLAUS STRICK

Um 1880 gab es in Sachsen 10690 Familien mit 12 Kindern. Von den insgesamt 128.280 Kindern waren 66299 Jungen (51,68%) und 61981 Mädchen (48,32%). Die folgende Tabelle enthält die theoretische und die empirische Geschlechterverteilung dieser Familien.

Anzahl der Jungen	Anzahl der Mädchen	Wahrscheinlichkeit	theoretische Verteilung	empirische Verteilung
0	12	0,00016	1,7	6
1	11	0,0021	22,2	29
2	10	0,0122	130,7	160
3	9	0,0436	466,1	521
4	8	0,1049	1121,7	1198
5	7	0,1796	1919,6	1821
6	6	0,2241	2395,2	2360
7	5	0,2054	2195,8	2033
8	4	0,1373	1467,8	1398
9	3	0,0653	697,7	799
10	2	0,0209	223,9	298
11	1	0,0041	43,5	60
12	0	0,00036	3,9	7

Hierbei wurde mit dem Binomial-Ansatz gerechnet:
 $p=0,5168$ (Wahrscheinlichkeit einer Jungengeburt), $q=0,4832$ (Wahrscheinlichkeit für eine Mädchengeburt),
 X : Anzahl der Jungen in einer Familie mit 12 Kindern,
 $P(X=k) = \binom{12}{k} p^k q^{12-k}$ Wahrscheinlichkeit für k Jungen in einer Familie mit 12 Kindern
 und $\mu_k = 10690 \cdot P(X=k)$ Erwartungswert der Anzahl der Familien mit k Jungen und $12-k$ Mädchen.



Zum Vergleich: Empirische (---) und theoretische Verteilung

Wie man aus der letzten Spalte und der Abbildung entnimmt, ist die Abweichung der theoretischen Verteilung von der der Erhebung z.T. beträchtlich: Eine Untersuchung mit Hilfe des χ^2 -Anpassungstest zeigt, daß die Abweichung signifikant auf sehr hohem Niveau ist ($\chi^2_{emp} \approx 99$; $P(\chi^2 \leq 32,91) = 0,999$).

Der Genetiker STERN bietet für die Verformung der empirischen Verteilung (außen zu hoch, innen zu flach) eine Erklärung an: Man könne sich die Verteilung entstanden denken als 'Summe' von 2 (oder mehr)

Binomialverteilungen. In der Bevölkerung gebe es 2 (oder mehr) gleich große Gruppen von Familien mit 12 Kindern. In der einen Gruppe sei z.B. die Wahrscheinlichkeit für eine Jungengeburt $p_1 = 0,6168$, in der anderen $p_2 = 0,4168$; dann liegt im Mittel eine Wahrscheinlichkeit von $p = 0,5168$ für eine Jungengeburt vor.

In der Tat stellt man an Beispielen fest, daß die so konstruierte Überlagerung zweier Binomialverteilungen gegenüber der Verteilung der zugehörigen 'mittleren' Erfolgswahrscheinlichkeit $p = \frac{1}{2}(p_1+p_2)$ eine ähnlich geartete Verformung aufweist wie die des obigen Beispiels.

Man betrachte etwa das Beispiel mit $p_1 = 0,4$; $p_2 = 0,6$; $p = \frac{1}{2} (0,4 + 0,6) = 0,5$ und $n = 12$:

k	$P(X_1=k)$	$P(X_2=k)$	$\frac{1}{2} (P(X_1=k)+P(X_2=k))$	$P(X=k)$
0	0,0022	0,0000	0,0011	0,0002
1	0,0174	0,0003	0,0089	0,0029
2	0,0639	0,0025	0,0332	0,0161
3	0,1419	0,0125	0,0772	0,0537
4	0,2126	0,0420	0,1274	0,1208
5	0,2270	0,1009	0,1640	0,1934
6	0,1766	0,1766	0,1766	0,2256
7	0,1009	0,2270	0,1640	0,1934
8	0,0420	0,2126	0,1274	0,1208
9	0,0125	0,1419	0,0772	0,0537
10	0,0025	0,0639	0,0332	0,0161
11	0,0003	0,0174	0,0089	0,0029
12	0,0000	0,0022	0,0011	0,0002

Mit Hilfe eines Computers wurden nun solche Paare (p_1, p_2) gesucht, daß die Anpassung der theoretischen Verteilung an die empirische Geschlechterverteilung des Einpaarbeispiels besser wird.

Die Anpassung wurde mit Hilfe der Größe χ^2 gemessen (vgl. die nachfolgende Ergänzung). Einige Paare (p_1, p_2) mit den zugehörigen Werten von χ^2 sind in der folgenden Tabelle abgedruckt:

p_1	p_2	χ^2
0,53	0,5036	68,4
0,54	0,4936	68,2
0,55	0,4836	44,6
0,56	0,4736	25,7
0,57	0,4636	20,3
0,58	0,4536	36,6
0,575	0,4586	25,2
0,565	0,4686	20,8
0,568	0,4656	19,9

Der χ^2 -Wert der besten Anpassung liegt knapp unterhalb des kritischen Werts zum 95%-Niveau ($P(\chi^2 \leq 21,03) = 0,95$) ! Eine Untersuchung der Anpassung zu einer 'mittleren' Verteilung von 3 Binomialverteilungen zeigt, daß der kleinste zugehörige χ^2 -Wert ebenfalls noch zwischen 19 und 20 liegt.

Aufgrund der gegebenen Daten ist keine Bewertung des STERN-schen Modells möglich. Es wäre nützlich, wenn weitere empirische Daten über die Geschlechterverteilung vorlägen.

WELCHER LESER KANN WEITERHELFFEN ?

Literatur:

- STERN : Grundlagen der Humangenetik, Gustav-Fischer-Verlag, Stuttgart, 1968
- STRICK: Einführung in die Beurteilende Statistik, Schroedel-Verlag, Hannover, 1980

Ergänzung zu: Verteilung der Geschlechter in Familien

Zur Benutzung des χ^2 -Anpassungstests

Hat man einen n-stufigen Zufallsversuch vorliegen, bei dem auf jeder Stufe r verschiedene Ausgänge möglich sind, die mit den festen Wahrscheinlichkeiten p_1, p_2, \dots, p_r auftreten, dann kann man nach n Stufen $\mu_1 = n \cdot p_1$ -mal mit Ausgang Nr.1, $\mu_2 = n \cdot p_2$ -mal mit Ausgang Nr.2 ... , $\mu_r = n \cdot p_r$ -mal mit Ausgang Nr.r rechnen.

Abweichungen von diesen Erwartungswerten kann man mit Hilfe der Größe

χ^2 messen:

$$\chi^2 = \frac{(\mu_1 - k_1)^2}{\mu_1} + \frac{(\mu_2 - k_2)^2}{\mu_2} + \dots + \frac{(\mu_r - k_r)^2}{\mu_r}$$

Wenn bei einem konkreten Zufallsversuch k_1 -mal Ausgang Nr.1, ... ,
 k_r -mal Ausgang Nr.r auftritt.

Liegt für einen Zufallsversuch eine Hypothese über die zugrundelie-
genden p_1, \dots, p_r vor, dann deuten kleine Werte von χ^2 auf eine gute
Anpassung und große Werte auf eine schlechte Anpassung des Modells
(der Hypothese) hin.

Es mag überraschend erscheinen, daß es unter bestimmten Voraussetzungen
für nahezu beliebige p_1, \dots, p_r, n gemeinsame kritische Werte für χ^2 gibt,
die nur von r abhängen, dh. daß man für diese Werte von p_1, \dots, p_r und
 n trotzdem dieselbe Tabelle von χ^2 verwenden kann !

Liegen in unserem Beispiel dem 10690-stufigen Zufallsversuch für die
13 möglichen Ausgänge (0 Jungen, ..., 12 Jungen) tatsächlich die Wahr-
scheinlichkeiten 0,00016; 0,0021; ... ; 0,00036 zugrunde (vgl. erste
Tabelle), dann erhält man mit der Wahrscheinlichkeit 0,95 eine Realisier-
ung mit einem χ^2 -Wert, der kleiner oder gleich 21,03 ist. Ledig-
lich mit der Wahrscheinlichkeit 0,05 erhält man einen größeren Wert
für χ^2 . (In 99,9% der Stichproben treten χ^2 -Werte kleiner/gleich
32,91 auf und nur in 0,1% der Stichproben treten zufällig größere
 χ^2 -Werte auf.)

(Im vorliegenden Beispiel wurde der Wert für p (=0,5168) aus der
Stichprobe geschätzt - dadurch reduziert sich die Anzahl der Frei-
heitsgrade auf $f=11$. Die zugehörigen kritischen Werte von χ^2 sind:
zum 95%-Niveau: 19,68 ; zum 99,9%-Niveau: 31,26.)

Literaturhinweis:

STRICK: Der Chiquadrat-Anpassungstest im Mathematik- und im
Biologieunterricht der Sekundarstufe II,
MNU 1981, Heft 3 (S. 133-147)