

Hinweise zur 15. Übung No 1 - Poissonverteilung -

1.] In einem Saal mit 10 Maschinen werde die Anzahl ausgefallener Maschinen registriert. Bei 200 Kontrollen ergaben sich folgende Werte:

Anzahl Ausfall	0	1	2	3	4	5	6	7	8	9	10
Absolute Häufigkeit h_m	41	62	45	22	16	8	4	2	0	0	0

Es wird vermutet, daß die Anzahl eine Poisson-verteilte Zufallsgröße ist, da unter normalen Produktionsbedingungen ein Maschinenschaden ein seltenes Ereignis ist, das auch vom Ausfall einer anderen Maschine unabhängig ist. Geben Sie eine Schätzung für den Parameter der Poisson-Verteilung an.

Überprüfen Sie, ob die Anzahl der ausgefallenen Maschinen als eine mit dem geschätzten Parameter Poisson-verteilte Zufallsgröße angesehen werden kann.

Hinweis: χ^2 - Test

Man kann zwei Versionen der Lösung der Aufgabe angehen: einmal die Formeln des χ^2 - Tests direkt berechnen, oder diesen χ^2 - Test in SPSS aufrufen. Bei beiden Wegen braucht man den Vergleich mit der angenommenen theoretischen Poisson-Verteilung

$$H_0 : P(X = m) = \frac{\lambda^m}{m!} e^{-\lambda}, \quad m = 0, 1, 2, \dots$$

für den Ausfall einer Maschine. Bei 200 Maschinen also die Werte $200 P(X = m)$. Dazu muß als Schätzung der Parameter λ bestimmt werden.

```
GET FILE='D:\spss151.sav'.  
EXECUTE .  
WEIGHT BY h_m .  
FREQUENCIES VARIABLES=ausfall  
/STATISTICS=MEAN .
```

Die 11 Zeilen der Datentabelle werden durch die Wichtung der Variablen "Ausfall" mit deren absoluter Häufigkeit sozusagen auf die wirklichen 200 Fälle aufgebläht, in →Daten, → Fälle wichten. Mit einem einfachen Aufruf der beschreibenden Statistik kann dann der Mittelwert von Ausfall berechnet werden: 1,8.

AUSFALL				Valid	Cum
Value	Label	Value	Frequency	Percent	Percent
0		0	41	20,5	20,5
1		1	62	31,0	51,5
2		2	45	22,5	74,0
3		3	22	11,0	85,0
4		4	16	8,0	93,0
5		5	8	4,0	97,0
6		6	4	2,0	99,0
7		7	2	1,0	100,0

		Total	200	100,0	100,0
Mean	1,800	Valid cases	200	Missing cases	0

Der Mittelwert dient als Schätzung des Erwartungswertes der Poisson-Verteilung, der gleich λ ist. Mit $\text{VerP}=\text{CDF.POISSON}(\text{ausfall}, 1.8)$ ergibt sich die zugehörige theoretische Verteilungsfunktion, und in \rightarrow Berechnen, \rightarrow Zeitreihen kann man diese Variable differenzieren, um die Dichte "pm" zu erhalten. Mit $\text{pm200}=\text{pm}*200$ sind die theoretischen Häufigkeiten einer Poissonverteilung zu $\lambda = 1.8$ bereitgestellt. Die Test-Statistik für den χ^2 - Test ist

$$\frac{(\text{pm200} - h_m)^2}{\text{pm200}}$$

welche noch über alle Zeilen kumulativ aufzusummieren ist: wieder in \rightarrow Berechnen, \rightarrow Zeitreihen mit der Funktion Kumulative Summe. Dabei ergibt sich eine Spalte dieser kumulativen Werte. Wird nun noch eine Spalte dagegengesetzt, die den kritischen Wert des χ^2 - Tests zu $1 - \alpha = 0.95$ und 10 Freiheitsgraden berücksichtigt, was mit der inversen Verteilungsfunktion des χ^2 - Tests machbar ist: $k_c=\text{IDF.CHI}(0.95, 10)$, dann zeigt sich, daß in Zeile 8 dieser Wert 18,3 von der kumulativen χ^2 -Summe überschritten wird. Also kann die Nullhypothese, daß die Ausfälle Poisson-verteilt zu $\lambda = 1.8$ sind, nicht aufrecht erhalten werden.

In der **zweiten Version** der Lösung wird der χ^2 - Test direkt in SPSS aufgerufen, in \rightarrow Nichtparametrische Tests. Dort ist die Variable *ausfall* zu verwenden, aber im Gegensatz zur Würfelaufgabe von Serie 12, No 3, haben wir hier nun in den einzelnen Zeilen von *ausfall* verschiedene Wahrscheinlichkeiten zu erwarten! Dies muß direkt Zeile für Zeile eingetragen werden. Die Werte für die Häufigkeiten der Poissonverteilung zu $\lambda = 1.8$ sind schon in der Datentabelle mit *pm200* berechnet. Vorher sind in der Datentabelle diejenigen Zeilen zu löschen, die Nullhäufigkeit haben, das betrifft die Werte 8, 9 und 10 für *ausfall*.

```
WEIGHT BY h_m .
NPAR TEST
  /CHISQUARE=ausfall
  /EXPECTED=33.06 59.51 53.56 32.13 14.46 5.21 1.56 0.4
  /MISSING ANALYSIS.
```

Es erfolgt eine Fehlermeldung: 2 Zellen haben erwartete Häufigkeiten kleiner als 5. Diese Voraussetzung war im χ^2 - Test gefordert: Man muß somit noch in der Datentabelle weiter zusammenfassen, etwa die Zeilen 5, 6, und 7 zu einer Zeile mit dem durchschnittlichen *ausfall* 6, und der beobachteten absoluten Häufigkeit 14, und der theoretischen Häufigkeit $\text{pm200}(5+6+7)=7.17$.

```

NPAR TEST
/CHISQUARE=ausfall
/EXPECTED=33.06 59.51 53.56 32.13 14.46 7.17
/MISSING ANALYSIS.

```

Dieser Test liefert letztendlich das erwartete Resultat

```

- - - - - Chi-Square Test AUSFALL
          Cases
Category  Observed  Expected  Residual
          0         41      33,08      7,92
          1         62      59,54      2,46
          2         45      53,59     -8,59
          3         22      32,15     -10,15
          4         16      14,47      1,53
          6         14       7,17      6,83
          ---
          Total      200
          Chi-Square          D.F.          Significance
          13,2358              5              ,0213

```

da die " Significance" 0,02 kleiner als die geforderte 0,05 ist.

Lädt man die gelöschten Zeilen neu, kann man sich auch noch ein Bild der Verhältnisse verschaffen: In →LinienPlot ist → mehrfach anzuklicken, und • Werte einzelner Fälle.

```

GRAPH
/LINE(MULTIPLE)= VALUE( h_m pm200 ) BY ausfall .

```

Obwohl die Kurven sich durchaus ähnlich sehen, kann man für h_m nicht die Poissonverteilung annehmen.

Bemerkung: Würde man den KS-Test auf Poissonverteilung verwenden, bekäme man eine positive Aussage für h_m , und diese mit sehr hoher Signifikanz. Dies zeigt aber nur, daß der KS-Test sehr grob ist. (Und wenn er denn zu einer Ablehnung führt, dann müssen die Daten in der Tat sehr "schlecht" gewesen sein.)