

Statistik für Ingenieure

Übung 7, 2. Teil

Prof. Dr. Hans-Jörg Starkloff

TU Bergakademie Freiberg
Institut für Stochastik

3. Februar 2020

1. Aufgabe

American Express Company glaubte, dass Personen mit Kreditkarten intensiver reisen als Personen ohne. Die Frage die jetzt untersucht wird ist, ob es einen Zusammenhang zwischen der Reisedistanz (Miles) und dem Kreditkartenumsatz (Dollars) gibt. Dazu wurden aus allen Karteninhabern 25 zufällig ausgewählt. Die Daten (in einem gewissen Zeitraum) sind in Miles.txt zu finden.

```
> miles<-read.table("D:/Miles.txt",header=T)
> miles
```



Daten

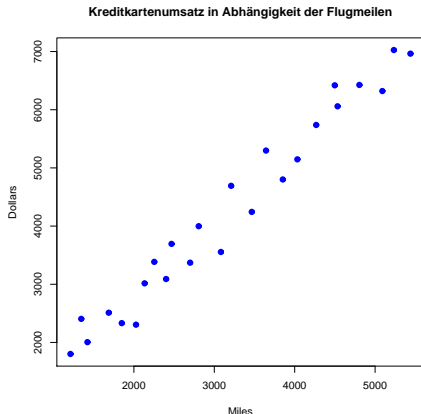
	Miles	Dollars		Miles	Dollars
1	1211	1802	16	3643	5298
2	1345	2405	17	3852	4801
3	1422	2005	18	4033	5147
4	1687	2511	19	4267	5738
5	1849	2332	20	4498	6420
6	2026	2305	21	4533	6059
7	2133	3016	22	4804	6426
8	2253	3385	23	5090	6321
9	2400	3090	24	5233	7026
10	2468	3694	25	5439	6964
11	2699	3371			
12	2806	3998			
13	3082	3555			
14	3209	4692			
15	3466	4244			



Teilaufgabe a)

a) Was können Sie aus der folgenden Grafik ablesen?

```
> attach(miles)
> plot(miles,col="blue",lwd=6,cex=0.5,
+ main="Kreditkartenumsatz in Abhängigkeit der Flugmeilen")
```



Antwort Teilaufgabe a)

Die Datenpunkte im Streudiagramm streuen nicht sehr stark um eine Gerade mit positivem Anstieg. Also scheint es einen Zusammenhang zwischen der Reisedstrecke und dem Kreditkartenumsatz zu geben, der auch gut durch eine lineare Funktion beschrieben werden kann.



Teilaufgabe b)

b) Testen Sie zum Niveau $\alpha = 0,05$, ob sowohl der zufällige Kreditkartenumsatz, als auch die zufälligen Flugmeilen normalverteilt sind.

```
> shapiro.test(miles$Dollars)
```

```
Shapiro-Wilk normality test
```

```
data: miles$Dollars W = 0.936, p-value = 0.1195
```

```
> shapiro.test(miles$Miles)
```

```
Shapiro-Wilk normality test
```

```
data: miles$Miles W = 0.9518, p-value = 0.275
```



Antwort Teilaufgabe b)

Bez.: X – Reisestrecke ("Miles"), Y – Kreditkartenumsatz ("Dollars").

$H_0 : Y \sim \mathbf{N}(\mu_Y, \sigma_Y^2)$ Kreditkartenumsatz ist normalverteilt.

$H_A : Y \not\sim \mathbf{N}(\mu_Y, \sigma_Y^2)$ Kreditkartenumsatz ist nicht normalverteilt.

$p = 0.1195 > 0.05 = \alpha \Rightarrow H_0$ wird nicht abgelehnt.

$H_0 : X \sim \mathbf{N}(\mu_X, \sigma_X^2)$ Reisestrecke ist normalverteilt.

$H_A : X \not\sim \mathbf{N}(\mu, \sigma_Y^2)$ Reisestrecke ist nicht normalverteilt.

$p = 0.275 > 0.05 = \alpha \Rightarrow H_0$ wird nicht abgelehnt.

Sowohl der Kreditkartenumsatz als auch die Reisestrecke unterscheiden sich nicht signifikant von einer Normalverteilung.

Unter Berücksichtigung der BONFERRONI-Korrektur:

$H_0 : X$ und Y sind beide normalverteilt.

H_A : mindestens eine der Zufallsgrößen X und Y ist nicht normalverteilt.

$p_Y = 0.1195 > 0.025 = \alpha/2$, $p_X = 0.275 > 0.025 = \alpha/2$,

folglich wird H_0 nicht abgelehnt.



Teilaufgabe c)

c) Welchen der 2 folgenden Tests würden Sie verwenden, um zu testen, ob es eine signifikante Abhängigkeit des Kreditkartenumsatzes von der Reisedstrecke gibt?

Wie lauten die Hypothesen und wie die Testentscheidung bei $\alpha = 0,01$?

(1)

```
> cor.test(miles$Dollars, miles$Miles)
```

```
    Pearson's product-moment correlation
```

```
data: miles$Dollars and miles$Miles
```

```
t = 25.2482, df = 23, p-value <2.2e-16
```

```
alternative hypothesis: true correlation is not equal to 0
```

```
95 percent confidence interval:
```

```
0.9599435 0.9923460
```

```
sample estimates:
```

```
cor
```

```
0.9824339
```



Fortsetzung Teilaufgabe c)

(2)

```
> cor.test(miles$Dollars, miles$Miles,method="spearman")
```

Spearman's rank correlation rho

data: miles\$Dollars and miles\$Miles

S = 62, p-value = 6.869e-07

alternative hypothesis: true rho is not equal to 0

sample estimates:

rho

0.9761538



Antwort Teilaufgabe c)

Falls X, Y normalverteilt \Rightarrow PEARSON; sonst SPEARMAN.

Hier also Test (1) aufgrund der Ergebnisse von b).

$$H_0 : \rho_{X,Y} = 0 \quad (X, Y \text{ unabhängig})$$

$$H_A : \rho_{X,Y} \neq 0 \quad (X, Y \text{ abhängig})$$

$$p = 2.2 \cdot 10^{-16} < 0.01 = \alpha$$

H_0 wird abgelehnt, d.h. es gibt eine signifikante Abhängigkeit zwischen der Reisedecke und dem Kreditkartenumsatz.



Teilaufgabe d)

d) Wie muss man den R-Befehl in c) erweitern, um die Richtung des Zusammenhanges zwischen Kreditkartenumsatz und Reisstrecke signifikant zeigen zu können?



Antwort Teilaufgabe d)

Einseitiger Test, so dass man bei Ablehnung der Nullhypothese auf eine signifikante positive Korrelation schließen kann.

```
> cor.test(miles$Dollars, miles$Miles,  
+ alternative="greater")
```



2. Aufgabe

In der Weinabteilung eines englischen Supermarktes, der sowohl deutsche als auch französische Weine feilbot, wurde an aufeinanderfolgenden Tagen entweder deutsche oder französische Musik gespielt. In der ersten Woche waren die deutschen Weine auf der linken Seite des Regals, die französischen rechts, in der zweiten Woche war es umgekehrt. Nationalflaggen an den Regalen machten den Herkunftsort der Weine unmissverständlich klar. Die Musik der ersten Woche war französische (im Wesentlichen Akkordeon-Musik) und in der zweiten Woche deutsche (im Wesentlichen Blaskapellen-Musik).

Herkunft des Weins	Musik	
	französische	deutsche
Frankreich	39	12
Deutschland	8	22

(nach M. Spitzer: *Musik, Wein und Bahnungseffekte*, Geist & Gehirn, dabei ist die Studie aus: North A., Hargreaves D., McKendrick J. *The influence of in-store music on wine selections*. Journal of Applied Psychology 1999; 84: 271-276.)



R-Code

```
> Tabelle <- matrix(c(39,12,8,22), 2, 2, byrow=TRUE)
> rownames(Tabelle) <- c("Frankreich","Deutschland")
> colnames(Tabelle) <- c("französische","deutsche")
> Tabelle # Counts
```

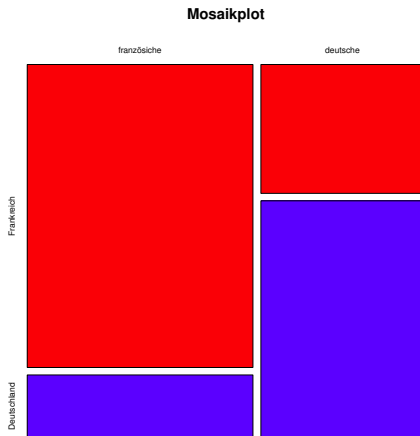
	französische	deutsche
Frankreich	39	12
Deutschland	8	22



Teilaufgabe a)

a) Was können Sie aus folgender Grafik ablesen?

```
> mosaicplot(t(Tabelle),main="Mosaikplot",color=c(2,4))
```



Antwort Teilaufgabe a)

Erkennbar sind bedingte Verteilungen in der Stichprobe:

unter der Bedingung, dass französische Musik gespielt wird:

großer Anteil von Wein aus Frankreich,
kleiner Anteil von Wein aus Deutschland;

unter der Bedingung, dass deutsche Musik gespielt wird:

großer Anteil von Wein aus Deutschland,
kleiner Anteil von Wein aus Frankreich.



Teilaufgabe b)

b) Testen Sie zum Niveau $\alpha = 0,01$, ob die Wahl des Weines durch die Musik beeinflusst wird.

```
> chisq.test(Tabelle, correct=FALSE)
```

```
    Pearson's Chi-squared test
```

```
data: Tabelle
```

```
X-squared = 19.2365, df = 1, p-value = 1.155e-05
```

```
> fisher.test(Tabelle)
```

```
    Fisher's Exact Test for Count Data
```

```
data: Tabelle p-value = 1.806e-05
```

```
alternative hypothesis: true odds ratio is not equal to 1
```

```
95 percent confidence interval:
```

```
 2.854093 28.966755
```

```
sample estimates:
```

```
odds ratio
```

```
 8.64643
```



Antwort Teilaufgabe b)

H_0 : Die Wahl des Weines ist von der gespielten Musik unabhängig.

H_A : Die Wahl des Weines ist von der gespielten Musik abhängig.

`fisher.test`: Der exakte Test von Fisher geht nur bei 2×2 -Tafeln (Vierfeldertafeln).

$p = 1.806 \cdot 10^{-5} < 0.01 = \alpha \Rightarrow H_0$ wird abgelehnt.

`chisq.test`: Der χ^2 -Test ist ein asymptotischer Test, geht bei „großen“ Stichproben immer und nicht nur bei 2×2 -Tafeln (Vierfeldertafeln).

$p = 1.155 \cdot 10^{-5} < 0.01 = \alpha \Rightarrow H_0$ wird abgelehnt.

Die Wahl des Weines und die gespielte Musik sind abhängig. Es gibt eine signifikante Abhängigkeit der Wahl des Weines (nach Herkunftsland) von der gespielten Musik.

