

Wahrscheinlichkeit und Statistik - Lösung

D-INFK

1. (10 Punkte)

Bei den folgenden 10 Fragen gibt es pro richtig beantwortete Frage 1 Punkt. Pro falsche Antwort gibt es 1/2 Punkt Abzug. Minimal erhält man für die gesamte Aufgabe 0 Punkte.

- a) Eine faire Münze wird zweimal geworfen. Für $i = 1, 2$ sei K_i das Ereignis, dass beim i -ten Wurf Kopf erscheint. Dann gilt:
1. K_1 und K_2 sind unabhängig.
 2. K_1 und K_2 sind disjunkt.
 3. K_1 und K_2 sind unabhängig und $K_1 \cup K_2 = \Omega$.
- b) Seien A und B zwei Ereignisse mit $P[A] > 0$ und $A \cap B = \emptyset$. Die Aussage $P[B|A] = 0$ ist
1. wahr.
 2. nicht wahr.
- c) Wir untersuchen eine Bodenprobe auf zwei Schadstoffe X und Y . Wir definieren die Ereignisse A : "Bodenprobe enthält X " und B : "Bodenprobe enthält Y ". Es sei $P[A] = 0.1$ und $P[B] = 0.3$. Zusätzlich wissen wir, dass die Wahrscheinlichkeit, dass die Bodenprobe keinen der beiden Schadstoffe enthält, 0.7 beträgt. Dann gilt:
1. $P[A \cap B] = 0.03$.
 2. $P[A \cap B] = 0.1$.
 3. Es gibt zu wenig Information, um $P[A \cap B]$ zu berechnen.

Siehe nächste Seite!

d) Es sei X eine Zufallsvariable mit $E[X] = 2$, $\text{Var}(X) = 3$. Dann gilt:

1. $E[X^2] = 4$.
2. $E[X^2] = 7$.
3. Es gibt zu wenig Information, um $E[X^2]$ zu berechnen.

e) Wie oft muss man einen fairen Würfel im Schnitt werfen, bis man zum ersten Mal eine 3 erhält?

1. 6 mal.
2. 6^6 mal.
3. $6!$ mal.

f) Sei X eine Zufallsvariable mit Verteilungsfunktion

$$F_X(x) = \begin{cases} 1 - e^{-cx}, & x \geq 0, \\ 0, & x < 0, \end{cases}$$

für ein $c > 0$. Der Median (d.h. $F_X^{-1}(\frac{1}{2})$) dieser Verteilung beträgt

1. $\frac{1}{2}$
2. $\frac{1}{c} \ln 2$
3. $1 - e^{-\frac{1}{2}c}$

g) Angenommen, 10% der Bevölkerung sind Raucher. Die Zufallsvariable X sei die Anzahl der Raucher unter 100 zufällig ausgewählten Personen. Wie gross ist die Standardabweichung von X ?

1. 3
2. $\sqrt{10}$
3. 10

h) Seien X und Y unabhängig und lognormalverteilt (eine Zufallsvariable Z ist lognormalverteilt, falls $\ln Z$ normalverteilt ist). Welche Aussage ist korrekt?

- 1) XY ist lognormalverteilt.
- 2) XY ist normalverteilt.
- 3) e^{X+Y} ist normalverteilt.

Siehe nächste Seite!

- i) Die stetige Zufallsvariable X habe die kumulative Verteilungsfunktion

$$F(x) = 1 - e^{-2x}, \quad x \geq 0.$$

Welche der folgenden Aussagen ist richtig?

1. Die Dichte von X ist $f(x) = 2xe^{-2x}$, $x \geq 0$.
 2. Es ist $P[X \geq 0.5] = e^{-0.5}$.
 3. Es ist $P[X = 1] = 1 - e^{-2}$.
 4. Für $Y = 2X$ gilt $P[Y \leq 2] = 1 - e^{-2}$.
- j) Bei der Berechnung des realisierten p -Wertes eines Tests
1. muss man wissen, ob der Test einseitig oder zweiseitig ist.
 2. braucht man die konkreten Daten nicht.
 3. muss man das Signifikanzniveau α kennen.

Lösung:

- a) 1. Punkt 2. und 3. stimmen nicht, da bei beiden Versuchen Kopf auftreten kann bzw. Kopf nicht auftreten muss.
- b) 1. $P[B|A] = P[A \cap B]/P[A] = 0/P[A] = 0$.
- c) 2. Es ist gegeben, dass $P[A^c \cap B^c] = 0.7$. Also $P[A \cup B] = 1 - P[(A \cup B)^c] = 1 - P[A^c \cap B^c] = 1 - 0.7 = 0.3$. Weiterhin gilt für beliebige Ereignisse A, B immer $P[A \cup B] = P[A] + P[B] - P[A \cap B]$. Also $0.3 = 0.1 + 0.3 - P[A \cap B]$. Also folgt $P[A \cap B] = 0.1$.
- d) 2. $\text{Var}(X) = E[X^2] - (E[X])^2$. Also

$$E[X^2] = \text{Var}(X) + (E[X])^2 = 3 + 2^2 = 7.$$

- e) 1. Sei X die Anzahl der Würfe, bis zum ersten Mal eine 3 erscheint. Dann ist $X \sim \text{Geom}(1/6)$. Also ist $E[X] = 1/(1/6) = 6$.
- f) 2. Wegen $F_X(x) = 1 - \exp(-cx) = z \iff x = -\ln(1 - z)/c$ gilt, dass $F_X^{-1}(z) = -\ln(1 - z)/c$. Somit folgt $F_X^{-1}(0.5) = \ln(2)/c$.
- g) 1. Es gilt $X \sim \text{Bin}(100, 0.1)$. Daher ergibt sich

$$\text{Var}(X) = 100 \cdot 0.1 \cdot 0.9 = 9.$$

Somit ist $\text{sd}(X) = \sqrt{\text{Var}(X)} = 3$.

- h) 1. $\ln(XY) = \ln X + \ln Y$ ist als Summe der unabhängigen normalverteilten Zufallsvariablen $\ln X$ und $\ln Y$ normalverteilt.

i) 4.

1. Falsch. Die Dichte ist $f(x) = 2e^{-2x}$, $x \geq 0$.
2. Falsch. $P[X \geq 0.5] = e^{-2 \cdot 0.5} = e^{-1}$.
3. Falsch. Für stetige Verteilungen gilt immer $P[X = x] = 0$ für alle x .
4. Richtig. $P[Y \leq 2] = P[2X \leq 2] = P[X \leq 1] = 1 - e^{-2}$.

j) 1. Man muss wissen, was es bedeutet, dass die Teststatistik T einen extremeren Wert als den beobachteten Wert $t = T(\omega)$ annimmt. Bei zweiseitigen Tests betrachtet man demnach das Ereignis $\{|T| < t\}$ (bzw. $\{|T| > t\}$), während für einseitige Tests das Ereignis $\{T < t\}$ (bzw. $\{T > t\}$) für die Berechnung des p -Wertes herangezogen wird.

Siehe nächste Seite!

2. (8 Punkte)

Eine Zufallsvariable Y heisst χ^2 -verteilt mit Freiheitsgrad $\nu \in \mathbb{N}$ (geschrieben $Y \sim \chi_\nu^2$), falls

$$Y = \sum_{k=1}^{\nu} Z_k^2,$$

wobei Z_1, \dots, Z_ν i.i.d. $\mathcal{N}(0, 1)$ -verteilt sind.

a) (3 Punkte) Zeige, dass

$$E[Y] = \nu \quad \text{und} \quad \text{Var}[Y] = 2\nu$$

gilt.

b) (1.5 Punkte) Gib mit Hilfe der Chebyshev-Ungleichung eine untere Schranke für die Wahrscheinlichkeit

$$\mathbb{P} \left[\left| \frac{Y}{\nu} - 1 \right| \leq \frac{3}{4} \right]$$

an. Wie lautet der konkrete Wert der Schranke für $\nu = 12$?

c) (3.5 Punkte) Leite eine Annäherung für die obige Wahrscheinlichkeit mit Hilfe des zentralen Grenzwertsatzes her. Wie lautet der konkrete Wert der Approximation für $\nu = 12$?

Lösung:

a) Für ganzzahlige Werte von ν kann Y geschrieben werden als $Y = \sum_{k=1}^{\nu} Z_k^2$ mit Z_1, \dots, Z_ν i.i.d. $\mathcal{N}(0, 1)$.

Daraus folgt einerseits

$$E[Y] = \sum_{k=1}^{\nu} E[Z_k^2] = \nu \cdot 1 = \nu. \quad (1P)$$

Andererseits ist wegen der Unabhängigkeit und identischen Verteilung der Z_k

$$E[Y^2] = E[(Z_1^2 + Z_2^2 + \dots + Z_\nu^2)^2] = \nu E[Z_1^4] + \nu(\nu - 1)(E[Z_1^2])^2, \quad (0.5P)$$

oder alternativ

$$\text{Var}[Y] = \text{Var} \left[\sum_{k=1}^{\nu} Z_k^2 \right] = \sum_{k=1}^{\nu} \text{Var} [Z_1^2] = \nu (E[Z_1^4] - E[Z_1^2]^2). \quad (0.5P)$$

Mit $E[Z_1^2] = 1$ und

Siehe nächste Seite!

$$\begin{aligned}
E[Z_1^4] &= \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} Y x^4 e^{-x^2/2} dx = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} Y x^3 x e^{-x^2/2} dx \\
&= \frac{1}{\sqrt{2\pi}} \left(-x^3 e^{-x^2/2} \right) \Big|_{-\infty}^{\infty} + \frac{3}{\sqrt{2\pi}} \int_{-\infty}^{\infty} Y x^2 e^{-x^2/2} dx = 3 \quad (1P)
\end{aligned}$$

erhalten wir schliesslich $E[Y^2] = 3\nu + \nu(\nu - 1) = \nu^2 + 2\nu$, und daraus

$$\text{Var}[Y] = (\nu^2 + 2\nu) - \nu^2 = 2\nu, \quad (0.5P)$$

beziehungsweise

$$\text{Var}[Y] = \nu(3 - 1) = 2\nu. \quad (0.5P)$$

b) Die Chebyshev-Ungleichung lautet $P[|Y - \nu| > c] \leq \text{Var}[Y]/c^2 = \frac{2\nu}{c^2}$. Somit folgt

$$\begin{aligned}
P \left[\left| \frac{Y}{\nu} - 1 \right| \leq \frac{3}{4} \right] &= P \left[\left| \frac{Y - \nu}{\nu} \right| \leq \frac{3}{4} \right] = 1 - P \left[|Y - \nu| > \frac{3\nu}{4} \right] \\
&\geq 1 - \frac{2\nu}{9\nu^2/16} = 1 - \frac{32}{9\nu}. \quad (1P)
\end{aligned}$$

Für $\nu = 12$ erhalten wir

$$P \left[\left| \frac{Y}{\nu} - 1 \right| \leq \frac{3}{4} \right] = \frac{19}{27} (\approx 0.7037). \quad (0.5P)$$

c) Die $Y_i = Z_i^2$ sind i.i.d. $\sim \chi_1^2$ (0.5P); also ist $E[Y_i] = 1$ und $\text{Var}[Y_i] = 2$, $i = 1, \dots, \nu$. (0.5P)

Der zentrale Grenzwertsatz für $Y = \sum_{i=1}^{\nu} Y_i$ liefert

$$Z = \frac{Y - \nu E[Y_i]}{\sqrt{\nu \text{Var}[Y_i]}} = \frac{Y - \nu}{\sqrt{2\nu}} \stackrel{\text{approx.}}{\sim} \mathcal{N}(0, 1). \quad (0.5P)$$

Eine Approximation der Wahrscheinlichkeit ergibt sich daher durch

$$\begin{aligned}
P \left[\left| \frac{Y}{\nu} - 1 \right| \leq \frac{3}{4} \right] &= P \left[\left| \frac{Y - \nu}{\nu} \right| \leq \frac{3}{4} \right] = P \left[\left| \frac{Y - \nu}{\sqrt{2\nu}} \right| \leq \frac{3}{4} \sqrt{\frac{\nu}{2}} \right] \quad (0.5P) \\
&\approx \Phi \left(\frac{3}{4} \sqrt{\frac{\nu}{2}} \right) - \Phi \left(-\frac{3}{4} \sqrt{\frac{\nu}{2}} \right). \quad (0.5P)
\end{aligned}$$

Für $\nu = 12$ erhalten wir

$$\begin{aligned}
P \left[\left| \frac{Y}{\nu} - 1 \right| \leq \frac{3}{4} \right] &\approx \Phi \left(\frac{3}{4} \sqrt{6} \right) - \Phi \left(-\frac{3}{4} \sqrt{6} \right) \\
&= 2\Phi \left(\frac{3}{4} \sqrt{6} \right) - 1 \quad (0.5P)
\end{aligned}$$

Siehe nächste Seite!

und mit Hilfe der Abschätzung $\sqrt{6} \approx \sqrt{6.25} = 2.5$ folgt $\frac{3}{4}\sqrt{6} \approx \frac{15}{8} = 1.875$,
wodurch wir den konkreten Wert

$$P \left[\left| \frac{Y}{\nu} - 1 \right| \leq \frac{3}{4} \right] \approx 2\Phi(1.875) - 1 \approx 2 \cdot 0.9696 - 1 = 0.9392 \quad (0.5P)$$

erhalten.

Siehe nächste Seite!

3. (8 Punkte)

Peter und Hans sitzen pro Woche die zufälligen Zeiten P und H über ihren Stochastikserien. Peters Zeitaufwand P kann durch eine Uniform(0,1)-verteilte Zufallsvariable beschrieben werden. Hans, der gewiefere Stochastiker, braucht gegeben Peters Zeit P die zufällige Zeit H , die uniform auf $(0,P)$ verteilt ist.

- a) (2.5 Punkte) Bestimme die gemeinsame Dichte von H und P , und skizziere den Bereich, auf dem diese Dichte positiv ist.
- b) (1.5 Punkt) Bestimme die Randdichte von H .
- c) (2 Punkte) Bestimme den Erwartungswert von H . Vergleiche dies mit dem Erwartungswert von P .
- d) (2 Punkte) Bestimme die Kovarianz zwischen H und P . Sind H und P unabhängig?

Lösung:

- a) Nach Aufgabenstellung sind $P \sim U(0, 1)$ und $H|P \sim U(0, P)$, d.h. die bedingte Dichte von H gegeben P ist durch

$$f_{H|P}(h|p) = \frac{1}{p} 1_{(0,p)}(h) \quad (0.5P)$$

gegeben. Also verschwindet $f_{H|P}$ ausserhalb des Dreiecks

$$D := \{(p, h) \mid 0 < h < p \leq 1\}.$$

Für die gemeinsame Dichte von P und H ergibt sich:

$$f_{P,H}(p, h) = f_{H|P}(h|p) f_P(p) \quad (0.5P) = \frac{1}{p} 1_{(0,p)}(h) 1_{[0,1]}(p). \quad (0.5P)$$

Der Bereich D , wo $f_{H,P}$ positiv ist, ist in Abbildung 1 skizziert. (1P)

- b) Die Randdichte von H berechnet sich für $0 < h \leq 1$ als Integral über die gemeinsame Dichte, also

$$\begin{aligned} f_H(h) &= \int_{-\infty}^{\infty} f_{P,H}(p, h) dp \quad (0.5P) \\ &= \int_0^1 \frac{1}{p} 1_{(0,p)}(h) dp = \int_h^1 \frac{1}{p} dp \quad (0.5P) \\ &= -\log h. \quad (0.5P) \end{aligned}$$

Siehe nächste Seite!

c) Mit partieller Integration folgt

$$\begin{aligned}
 E[H] &= - \int_0^1 h \log h \, dh && (0.5P) \\
 &= - \frac{h^2}{2} \log h \Big|_0^1 + \int_0^1 \frac{h^2}{2} \frac{1}{h} \, dh = 0 + \int_0^1 \frac{h}{2} \, dh && (0.5P) \\
 &= \frac{h^2}{4} \Big|_0^1 = \frac{1}{4}. && (0.5P)
 \end{aligned}$$

Andererseits ist $E[P] = 1/2$, also $E[H] = E[P]/2$. (0.5P)

Bemerkung:

$$\begin{aligned}
 - \frac{h^2}{2} \log h \Big|_0^1 &= - \frac{1}{2} \underbrace{\log 1}_{=0} + \lim_{h \rightarrow 0} \frac{h^2}{2} \log h \\
 &= \lim_{h \rightarrow 0} \frac{\log h}{2h^{-2}} \quad \left(\text{unbestimmter Ausdruck des Typs } \left\langle \frac{\infty}{\infty} \right\rangle \right) \\
 &= \lim_{h \rightarrow 0} \frac{1/h}{-4h^{-3}} = \lim_{h \rightarrow 0} -h^2/4 = 0,
 \end{aligned}$$

wobei wir die l'Hôpital'sche Regel benutzt haben.

Alternativ: Es gilt $E[H] = E[E[H|P]]$. (0.5P) Laut Aufgabenstellung ist H gegeben P $U(0, P)$ -verteilt, so dass $E[H|P] = \frac{1}{2}P$ (0.5P) ist und damit

$$E[H] = \frac{1}{2}E[P] \text{ (0.5P)} = \frac{1}{4}. \quad (0.5P)$$

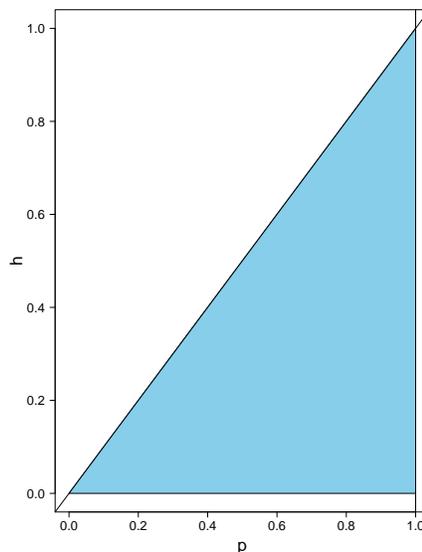


Abbildung 1: Bereich D , auf dem die gemeinsame Dichte von H und P positiv ist.

Siehe nächste Seite!

d) Man hat

$$E[PH] = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} ph f_{P,H}(p, h) dh dp = \int_0^1 dp \int_0^p h dh dp = \int_0^1 \frac{p^2}{2} dp = \frac{1}{6}, \quad (1P)$$

$$\text{Cov}(P, H) = E[PH] - E[P]E[H] = \frac{1}{6} - \frac{1}{2} \frac{1}{4} = \frac{1}{24} (\approx 0.0417). \quad (0.5P)$$

H und P sind somit nicht unabhängig. (0.5P)

Siehe nächste Seite!

4. (8 Punkte)

Unterhalb einer Kläranlage wurden 16 unabhängige Wasserproben aus einem Fluss entnommen und jeweils deren Ammoniumkonzentration X_i (angegeben in $\mu\text{gNH}_4\text{-N}/\ell$) mit einem Messgerät bestimmt. Der Mittelwert der Proben ergab $\bar{x} = 204.2$.

Wir wollen nun wissen, ob mit diesem Experiment eine Überschreitung des Grenzwerts von $200 \mu\text{gNH}_4\text{-N}/\ell$ nachgewiesen werden kann (auf dem 5%-Niveau).

a) (2 Punkte) Nimm an, die Standardabweichung der Messungen sei im Voraus aufgrund früherer Studien bekannt. Sie betrage $10 \mu\text{gNH}_4\text{-N}/\ell$. Finde einen geeigneten statistischen Test, um zu überprüfen, ob eine Grenzwertüberschreitung nachgewiesen werden kann. Wie lauten die Modellannahmen?

b) (3.5 Punkte)

Führe den Test aus Punkt a) durch. Gib dazu folgendes explizit an: die Null- und Alternativhypothesen H_0 und H_A , die Teststatistik, den realisierten Wert der Teststatistik, den Verwerfungsbereich und das Testergebnis.

c) (1.5 Punkte) Wie wahrscheinlich ist es, dass man mit 16 unabhängigen Wasserproben eine Grenzwertüberschreitung nachweisen kann, wenn die wahre Ammoniumkonzentration tatsächlich über dem Grenzwert und zwar bei $205 \mu\text{gNH}_4\text{-N}/\ell$ liegt?

d) (1 Punkt) Wie wahrscheinlich ist es, dass man mit 16 unabhängigen Wasserproben fälschlicherweise eine Grenzwertüberschreitung nachweist, obwohl die wahre Ammoniumkonzentration bei $200 \mu\text{gNH}_4\text{-N}/\ell$ liegt und den Grenzwert somit genau einhält?

Lösung:

a) Da die Standardabweichung der Messungen als bekannt vorausgesetzt wird, entscheiden wir uns für einen z -Test. (0.5P) Wir nehmen an, dass die Ammoniumkonzentrationen X_i unabhängig (0.5P) und identisch normalverteilt (0.5P) sind für $i = 1, \dots, 16$, mit $\sigma^2 = 100$ und μ unbekannt. (0.5P)

Siehe nächste Seite!

b) Nullhypothese H_0 : X_i i.i.d. $\sim \mathcal{N}(\mu_0, \sigma^2)$ mit $\mu_0 = 200, \sigma = 10$ (0.5P)

Alternative H_A : X_i i.i.d. $\sim \mathcal{N}(\mu, \sigma^2)$ mit $\mu > 200, \sigma = 10$ (einseitig) (0.5P)

Teststatistik: $Z = \frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}} \sim \mathcal{N}(0, 1)$ unter H_0 (0.5P)

Verwerfungsbereich: Aus der Normalverteilungstabelle:

$$\mathcal{K} = \{z \geq z_{1-\alpha}\} = [1.64, \infty).$$

(Dies entspricht dem Verwerfungsbereich $[204.1, \infty)$

auf der Skala von \bar{X} .) (1P)

Wert der Teststatistik: $z = \frac{\bar{x} - \mu_0}{\sigma/\sqrt{n}} = \frac{204.2 - 200}{\sigma/\sqrt{16}} = \frac{4.2}{2.5} = 1.68$ (0.5P)

Testentscheid: $1.68 \in \mathcal{K}$, also wird die Nullhypothese verworfen.

Die Überschreitung des Grenzwertes ist auf dem

5%-Niveau signifikant. (0.5P)

c) Aus a) folgt: Die Nullhypothese kann verworfen werden, falls der Mittelwert aller Messungen grösser als 204.1 ist,

$$\bar{X} > 204.1.$$

Um die Wahrscheinlichkeit zu berechnen, dass eine Grenzwertüberschreitung nachgewiesen werden kann (H_0 verworfen werden kann), geht man wieder zu einer standardisierten normalverteilten Zufallsvariable über. Mit $\mu_A = 205$ und $\sigma = 10$ erhält man

$$\begin{aligned} P_{\mu_A}[\bar{X} > 204.1] \quad (0.5P) &= P_{\mu_A} \left[\frac{\bar{X} - \mu_A}{\sigma/\sqrt{n}} > \frac{204.1 - \mu_A}{\sigma/\sqrt{n}} \right] \\ &= P_{\mu_A} \left[\frac{\bar{X} - \mu_A}{\sigma/\sqrt{n}} > -0.36 \right] \quad (0.5P) \\ &= P[Z > -0.36]. \end{aligned}$$

Dies entspricht also der Wahrscheinlichkeit, dass eine normalverteilte Zufallsvariable Z mit Varianz 1,

$$Z \sim \mathcal{N}(0, 1),$$

einen Wert grösser als -0.36 annimmt. Diese Wahrscheinlichkeit ist wegen der Symmetrie der Normalverteilung gleich

$$P[Z \leq 0.36] = 0.6406, \quad (0.5P)$$

Siehe nächste Seite!

wie aus der Tabelle entnommen werden kann. Die gesuchte Wahrscheinlichkeit (die Macht des Tests an der Stelle $\mu = \mu_A = 205$) ist also ungefähr 64%.

d) Dies ist genau das Niveau des Testes und war als 5% vorgegeben. (1P)