

Stochastik für die Naturwissenschaften

Dr. C.J. Luchsinger

5. Erwartungswert E und Varianz V

Literatur Kapitel 5

- * Storrer: (37.9)-(37.12), (38.4), (40.6)-(40.9), (41.2)
- * Stahel: Kapitel 5 und 6 (nur noch Erwartungswert und Varianz)
- * Statistik in Cartoons: Kapitel 4 (nur noch Erwartungswert und Varianz)

5.1 Erwartungswert und Varianz einer diskreten und stetigen Zufallsgrösse

Ziele dieses Teils:

- * Die StudentInnen kennen die Definition des Erwartungswerts / der Varianz von diskreten und stetigen Zufallsgrössen.
- * Sie können einfache Erwartungswerte / Varianzen selber berechnen und kennen weitere Erwartungswerte / Varianzen von bekannten Zufallsgrössen (mehr dazu in Kapitel 6).
- * Gefühl für Erwartungswerte / Varianzen (z.B. Schwerpunkt; "normalerweise" etwas wie "mittlerer Wert")

Falls wir Daten x_1, x_2, \dots, x_n haben (mehr dazu in 5.3), können wir einen sogenannten **Stichproben-Mittelwert** berechnen:

$$\bar{x} := \frac{1}{n} \sum_{i=1}^n x_i.$$

Es ist denkbar, dass einige der x_i den gleichen Wert darstellen. Wir könnten also obiges \bar{x} umschreiben, indem wir über alle vorkommenden Werte von x summieren und mit H_x angeben, wie häufig Wert x vorgekommen ist. Damit erhalten wir:

$$\bar{x} := \frac{1}{n} \sum_{i=1}^n x_i = \frac{1}{n} \sum_{\text{alle } x} x H_x = \sum_{\text{alle } x} x \frac{H_x}{n}.$$

Warum wollen wir $\bar{x} = \sum_{\text{alle } x} x \frac{H_x}{n}$ betrachten? Weil

$$\frac{H_x}{n}$$

die *relative* Häufigkeit darstellt: wie häufig kommt x in n Daten vor, geteilt durch n . Wir werden in Kapitel 7 sehen, dass diese Grösse gegen die wahre Wahrscheinlichkeit für dieses Ereignis konvergiert,

$$P[X = x],$$

wenn $n \rightarrow \infty$. Deshalb definieren wir:

Definition 5.1 [Erwartungswert (Expectation, mean) einer diskreten und stetigen Zufallsgrösse] Der Erwartungswert $E[X]$ einer Zufallsgrösse X ist definiert als

$$E[X] := \begin{cases} \sum_{x_i} x_i P[X = x_i] & \text{falls } X \text{ diskret} \\ \int_{-\infty}^{\infty} x f(x) dx & \text{falls } X \text{ stetig.} \end{cases}$$

Die Definitionen gelten, falls die Summe bzw. das Integral existiert. Dabei wird jeweils über den gesamten Wertebereich der Zufallsgrösse summiert respektive integriert.

Bemerkungen 1. Eine andere Bezeichnung für Erwartungswert ist *Mittelwert*.

2. Obschon wir im täglichen Leben oft mit Erwartungswerten argumentieren, ist es gar nicht so einfach, zu verstehen, was das genau ist. Definition 5.1 ist algebraisch (eine Summe) bzw. von der Analysis her (ein Integral) klar. Physikalisch ist der Mittelwert ein Schwerpunkt. Die Wahrscheinlichkeiten sind dann Gewichte bzw. Gewichtsverteilungen, was in Bemerkung 3 klar wird.

3. Die Zufallsgrösse muss den Erwartungswert nicht annehmen: "Reality differs from Expectations!" Dazu noch das einfache Beispiel von $\text{Be}(p) = \text{Bin}(1, p)$ - dies ist die Bernoulli-Zufallsgrösse (Binomial mit $n = 1$, nur 1 Versuch) - wo $p \in (0, 1)$ und $P[X = 0] = 1 - p$, $P[X = 1] = p$. Berechnen Sie den Erwartungswert dieser Zufallsgrösse:

Er wird offenbar von X *nie* angenommen, weil X entweder 0 oder 1 ist.

Beispiele I

1. Berechnen Sie den Erwartungswert der Anzahl Augen beim Wurf eines perfekten Würfels. Überlegen Sie sich zuerst, was es geben sollte.

2. Berechnen Sie den Erwartungswert einer $U[-2, 1]$ -Zufallsgrösse. Überlegen Sie sich zuerst, was es geben sollte.

Meist ist es bei der Berechnung von Erwartungswerten von immensem Vorteil, wenn man schon weiss, was es geben sollte. Klassisches Beispiel dazu ist die Poisson-Zufallsgrösse (sie wird in Kapitel 6 ausführlich motiviert). Wenn man weiss, dass der Erwartungswert λ ist, ist es einfacher:

3. Erwartungswert einer $\text{Po}(\lambda)$ -Zufallsgrösse, $\lambda > 0$: Eine Poisson-Zufallsgrösse hat die Verteilung:

$$P[X = k] = e^{-\lambda} \frac{\lambda^k}{k!}, \quad k \geq 0.$$

Wir sollten überprüfen, ob dies eine Verteilung ist:

Jetzt steigen wir folgendermassen ein:

$$\begin{aligned} E[X] &= \sum_{k \geq 0} k e^{-\lambda} \frac{\lambda^k}{k!} \\ &= e^{-\lambda} \sum_{k \geq 0} k \frac{\lambda^k}{k!} \\ &= e^{-\lambda} \sum_{k \geq 1} k \frac{\lambda^k}{k!} \\ &= \lambda e^{-\lambda} \sum_{k \geq 1} k \frac{\lambda^{k-1}}{k!} \\ &= \lambda e^{-\lambda} \sum_{k \geq 1} \frac{\lambda^{k-1}}{(k-1)!} \\ &= \lambda e^{-\lambda} \sum_{k \geq 0} \frac{\lambda^k}{k!} \\ &= \lambda e^{-\lambda} e^{\lambda} = \lambda \end{aligned}$$

4. Auf Übungsblatt 7 sind weitere Erwartungswerte zu berechnen. Wir fügen hier noch ein gerechnetes Beispiel an, nämlich den Erwartungswert einer $\mathcal{N}(\mu, \sigma^2)$ -Zufallsgrösse. Der Erwartungswert sollte definitionsgemäss μ sein. Die Dichte ist:

$$\frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2\sigma^2}(x-\mu)^2}.$$

Damit steigen wir folgendermassen ein (ausführlicher Storrer (41.6)):

$$\begin{aligned} E[X] &= \int_{-\infty}^{\infty} x \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2\sigma^2}(x-\mu)^2} dx \\ &= \int_{-\infty}^{\infty} \frac{(x-\mu) + \mu}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2\sigma^2}(x-\mu)^2} dx \\ &= \int_{-\infty}^{\infty} \frac{(x-\mu)}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2\sigma^2}(x-\mu)^2} dx \\ &\quad + \int_{-\infty}^{\infty} \frac{\mu}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2\sigma^2}(x-\mu)^2} dx \\ &= \int_{-\infty}^{\infty} \frac{(x-\mu)}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2\sigma^2}(x-\mu)^2} dx + \mu \\ &= 0 + \mu = \mu. \end{aligned}$$

Exponentialverteilung revisited:

Offenbar ist der Erwartungswert *ein* Mass für die **Lage** der Zufallsgrösse ("wo werden Werte etwa erwartet?"). Wir werden jetzt *ein* Mass für die **Streuung** der Zufallsgrösse um diesen Erwartungswert kennenlernen.

Definition 5.2 [Varianz und Standardabweichung einer diskreten und stetigen Zufallsgrösse] Mit $\mu_X := E[X]$ definieren wir die Varianz $V[X]$ einer Zufallsgrösse X als

$$V[X] := \begin{cases} \sum_{x_i} (x_i - \mu_X)^2 P[X = x_i] & X \text{ diskret} \\ \int_{-\infty}^{\infty} (x - \mu_X)^2 f(x) dx & X \text{ stetig.} \end{cases}$$

Dabei wird auch hier über den gesamten Wertebereich der Zufallsgrösse summiert respektive integriert. Die Standardabweichung sd (**S**tandard **D**eviation) ist die Wurzel aus der Varianz:

$$sd[X] := \sqrt{V[X]}.$$

Man beachte: der Ausdruck

$$\sum_{x_i} (x_i - \mu_X)^2 P[X = x_i]$$

besteht aus 3 (!) Teilen. Welchen und weshalb (analog mit dem Integral)?

Bemerkung zu Definition 5.2: Varianz bzw. Standardabweichung sind *zwei* Masse für die Streuung einer Zufallsgrösse. Es gibt aber viele weitere Masse für die Streuung. Ein Beispiel ist (diskret; stetig analog) $\sum_{x_i} |x_i - \mu_X| P[X = x_i]$. Dies ist die absolute ("|"), erwartete (" $\sum_{x_i} \dots P[X = x_i]$ ") Abweichung vom Erwartungswert (" $x_i - \mu_X$ ") (Mean absolute deviation MAD). Man verwendet aus mathematischen Gründen (einfachere Rechnungen) in der Statistik eher die Varianz anstatt die Mean absolute deviation. Wie sieht die MAD im stetigen Fall aus?

Beispiele II

5. Berechnen Sie die Varianz einer $\text{Be}(p)$ -Zufallsgrösse, wo $p \in (0, 1)$:

Praktische Interpretation:

6. Berechnen Sie die Varianz einer $U[0, 1]$ -Zufallsgrösse:

7. Was vermuten Sie: wie wird die Varianz einer $U[0, 3]$ -Zufallsgrösse sein (Auflösung nach Lemma 5.4)?

8. Wir fügen hier noch ein gerechnetes Beispiel an, nämlich die Varianz einer $\mathcal{N}(\mu, \sigma^2)$ -Zufallsgrösse. Die Varianz sollte definitionsgemäss σ^2 sein. Die Dichte ist:

$$\frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{1}{2\sigma^2}(x-\mu)^2}.$$

Damit steigen wir folgendermassen ein (partielle Integration im 4. Schritt):

$$\begin{aligned} V[X] &= \int_{-\infty}^{\infty} (x - \mu)^2 \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{1}{2\sigma^2}(x-\mu)^2} dx \\ &= \int_{-\infty}^{\infty} y^2 \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{1}{2\sigma^2}y^2} dy \\ &= \int_{-\infty}^{\infty} y \left(y \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{1}{2\sigma^2}y^2} \right) dy \\ &= -y \frac{\sigma^2}{\sqrt{2\pi\sigma}} e^{-\frac{1}{2\sigma^2}y^2} \Big|_{-\infty}^{\infty} \\ &\quad + \int_{-\infty}^{\infty} \frac{\sigma^2}{\sqrt{2\pi\sigma}} e^{-\frac{1}{2\sigma^2}y^2} dy \\ &= \sigma^2 \end{aligned}$$

Warum betrachtet man Summen von Zufallsgrößen?

Aufgabe 37-5 als Motivation für 5.2: Wir haben in dieser Aufgabe die diskrete Zufallsgröße X gegeben, dann gibt es eine sogenannte *Transformation* dieser Zufallsgröße: $Y := 2X + 1$. Wir stellen das erstmal sinnvoll in einer Tabelle dar:

Nachrechnen liefert $E[X] = 2$ und $V[X] = 4.2$.

Wenn wir uns jetzt die Frage nach $E[Y], V[Y]$ stellen, so haben wir die Hoffnung, dass wir benutzen können, dass wir schon wissen: $E[X] = 2, V[X] = 4.2$.

In der Tat kann man folgern:

$$E[Y] = E[2X + 1] =$$

und

$$V[Y] = V[2X + 1] =$$

Das wäre mühsam zu Fuss; **Gott sei Dank gibt es Rechenregeln in 5.2.**

5.2 Einige wichtige Rechenregeln

Lemma 5.3 [Linearität des Erwartungswertes]

$$E[aX + bY] = aE[X] + bE[Y]$$

Umgangssprachlich sagt man "Konstanten herausziehen" und "Summen auseinanderziehen und getrennt berechnen".

Eine Konstante b kann man auffassen als eine konstante Zufallsgrösse, welche mit Wahrscheinlichkeit 1 den Wert b annimmt: $P[X = b] = 1$. Der Erwartungswert ist damit b und die Varianz von b gleich 0. Prüfen Sie das mit Hilfe von Definitionen 5.1 und 5.2:

Bemerkungen zu Lemma 5.3: 1. Wir haben gesehen, dass der Erwartungswert einer $\text{Be}(p)$ -Zufallsgrösse gleich p ist. Die $\text{Bin}(n, p)$ -Zufallsgrösse ist eine Summe von n $\text{Be}(p)$ -Zufallsgrössen (sogar unabhängige Summanden!). Wegen Lemma 5.3 muss deshalb der Erwartungswert einer $\text{Bin}(n, p)$ -Zufallsgrösse gleich np sein (direkte Berechnung in Storrer p 289):

2. Was darf man machen, was nicht?

$$E[aX + b] = aE[X] + b, \quad E[\sin(X)] = \sin(E[X]), \quad E\left[\frac{1}{X}\right] = \frac{1}{E[X]}$$

Bei Transformationen g der Art $g(x) = ax + b$, wo a und b reelle Zahlen, gilt offenbar wegen Lemma 5.3 $E[g(X)] = E[aX + b] = aE[X] + b = g(E[X])$. Dies ist aber für beliebige g im Allgemeinen falsch, zB $g(x) = \sin(x)$ oder $g(x) = x^{-1}$.

3. Sei $(X_i)_{i=1}^n$ iid mit $E[X_i] = \mu$, berechne $E[\bar{X}] := E\left[\frac{1}{n} \sum_{i=1}^n X_i\right]$.

Wir stellen bei der dritten Bemerkung 3 Dinge fest:

- a) Der Erwartungswert von \bar{X} trifft selber genau μ (NB: \bar{X} ist eine Zufallsgrösse und hat damit selber einen Erwartungswert!).
- b) Wenn \bar{X} zum Schätzen von μ benutzt wird (Kapitel 8), stimmt schon mal der Erwartungswert (sog. erwartungstreue).
- c) Obiges Resultat ($E[\bar{X}] = \mu$) gilt für alle Verteilungen (mit existierendem Erwartungswert): Binomial, Poisson, etc. Wir haben die konkrete Verteilung ja nirgends benutzt.

$$\mu \quad \text{versus} \quad \bar{X} := \frac{1}{n} \sum_{i=1}^n X_i \quad \text{versus} \quad \bar{x} := \frac{1}{n} \sum_{i=1}^n x_i$$

Alle drei heissen Mittelwert:

theoretischer Mittelwert - Mittelwert der Zufallsvariablen - Stichprobenmittelwert

1. μ : das gehört zur Theorie; in den Naturwissenschaften haben wir Naturgesetze und Naturkonstanten; die sind fest! (Gegensatz: in der Ökonomie ist μ vielleicht ein "richtiger" Zinssatz.... - der ist nicht klar und fest). Zum Beispiel die Gravitationskonstante G in

$$F = G \frac{m_1 m_2}{r^2}.$$

2. $\bar{X} := \frac{1}{n} \sum_{i=1}^n X_i$: am Besten folgendermassen zu verstehen:

- * vor dem Versuch, im Büro Luchsinger bei der Aufgabenbesprechung
- * 2 Studis, gleiche Aufgabe bis hier
- * Modellierung: X_i, \bar{X} sind "Platzhalter für die Daten, die dann kommen"
- * gleiche \bar{X} und beide haben $E[\bar{X}] = \mu$, siehe (p -1) und $V[\bar{X}] = \frac{\sigma^2}{n}$, siehe (p +3)

3. $\bar{x} := \frac{1}{n} \sum_{i=1}^n x_i$:

- * nach dem (Feld)Versuch
- * 2 Studis, gleiche Aufgabenstellung oben aber jetzt andere Daten!
- * Daten x_1, \dots, x_n und y_1, \dots, y_n fest, konstant, nach Versuch, andere \bar{x}, \bar{y} .
- * wenig Sinn, aber richtig: $E[\bar{x}] = \bar{x}$ und $V[\bar{x}] = 0$ da \bar{x} konstant.

Lemma 5.4 [elementare Rechenregeln der Varianz]

a) $V[aX + b] = a^2V[X]$ für a, b reelle Zahlen (*"Konstante quadratisch raus"*).

b) $V[X] = E[X^2] - (E[X])^2$

Berechnen Sie jetzt $V(-X)$:

Bemerkungen zu Lemma 5.4: 1. Wir haben uns in Beispiel 7 gefragt, wie die Varianz einer $U[0, 3]$ -Zufallsgrösse ist. Mit X eine $U[0, 1]$ -Zufallsgrösse ist $Y := 3X$ eine $U[0, 3]$ -Zufallsgrösse. Deshalb muss die Varianz von Y wegen Lemma 5.4 a) 9 mal grösser sein als diejenige von X (also $9/12 = 3/4$). Bilder zu den Dichten der beiden Zufallsgrössen:

2. Wegen Lemma 5.4 a) folgt mit $a \in \mathbb{R}$:

$$sd[aX] = |a|sd[X];$$

im Gegensatz zur Varianz kann man bei der Standardabweichung einen konstanten Faktor einfach herausnehmen (Absolutbetrag!). Die Varianz ist ein quadratisches Mass für die Streuung, während die Standardabweichung direkt mit der Streuung der Daten in Relation gesetzt werden kann. Deshalb:

3. In Lemma 5.4 b) kommt der Ausdruck $E[X^2]$ vor. Wie berechnet man diesen Ausdruck?

Es gilt folgende Regel:

$$E[X^2] = \begin{cases} \sum_{x_i} x_i^2 P[X = x_i] & \text{falls } X \text{ diskret} \\ \int_{-\infty}^{\infty} x^2 f(x) dx & \text{falls } X \text{ stetig.} \end{cases}$$

Lemma 5.5 [Varianz einer Summe] Sei X_1, \dots, X_n eine Folge von unabhängigen Zufallsgrößen (die gleiche Verteilung wird nicht gefordert!). Dann gilt:

$$V\left[\sum_{i=1}^n X_i\right] = \sum_{i=1}^n V[X_i]$$

(*"Varianz der Summe ist die Summe der Varianzen"*).

Berechnen Sie jetzt $V(X - Y)$, wo X und Y unabhängig voneinander sind.

Bemerkung zu Lemma 5.5: Wir haben in Beispiel 5 gesehen, dass die Varianz einer $\text{Be}(p)$ -Zufallsgrösse gleich $p(1 - p)$ ist. Die $\text{Bin}(n, p)$ -Zufallsgrösse ist ja eine Summe von n $\text{Be}(p)$ -Zufallsgrößen (sogar unabhängig!). Wegen Lemma 5.5 muss deshalb die Varianz einer $\text{Bin}(n, p)$ -Zufallsgrösse gleich $np(1 - p)$ sein. Das kennen Sie eventuell aus der Mittelschule als *"npq"*.

Storrer Aufgabe 38-3.

Eine Rechnung mit weitreichenden Konsequenzen für die gesamte Wahrscheinlichkeitsrechnung und Statistik (die X_i 's seien iid):

$$\begin{aligned} V[\bar{X}] &:= V\left[\frac{1}{n}\sum_{i=1}^n X_i\right] \\ &= \frac{1}{n^2}V\left[\sum_{i=1}^n X_i\right] \\ &= \frac{1}{n^2}\sum_{i=1}^n V[X_i] \\ &= \frac{1}{n^2}\sum_{i=1}^n V[X_1] && \text{(wichtig)} \\ &= \frac{1}{n^2}nV[X_1] \\ &=: \frac{1}{n^2}n\sigma^2 \\ &= \frac{1}{n}\sigma^2; \end{aligned}$$

damit erhalten wir insbesondere

$$sd[\bar{X}] = \frac{1}{\sqrt{n}}\sigma. \quad \text{(noch wichtiger)}$$

Eine von vielen Konsequenzen ist:

Dieses

$$\sqrt{n}$$

wird uns *nie* mehr loslassen, denn \bar{X} , bzw \bar{x} , ist zentrales Untersuchungsobjekt in der Statistik. Es kommt in der Berechnung von Konfidenzintervallen und in fast allen Tests vor! Ein Bild zur Dynamik in dieser Rechnung:

5.3 Stichproben

Dies ist ein kleiner Vorgriff auf den Statistik-Teil. Es ist das Bindeglied zwischen Wahrscheinlichkeitstheorie und Statistik:

- * Bis jetzt haben wir immer *Wahrscheinlichkeitstheorie* gemacht (Ausnahme: Kapitel 2: Beschreibende Statistik).
- * Die *Wahrscheinlichkeitstheorie* zeichnet sich dadurch aus, dass wir immer sicher wissen, wie das Modell ist (z.B. "Sei X eine $\mathcal{N}(0, 1)$ -Zufallsgrösse.") Wir müssen uns in der *Wahrscheinlichkeitstheorie* *nie* Gedanken machen, ob dieses Modell überhaupt "stimmt".
- * In der Statistik gilt folgendes: **Wir haben nur die Daten** $d = (x_1, x_2, x_3, \dots, x_n)$!!! und wissen nicht, aus welcher Verteilung die eigentlich stammen. Diese Daten können Würfelauagen sein bei n Würfeln, Blutdruckmessungen bei verschiedenen Personen oder bei der gleichen Person zu verschiedenen Zeitpunkten, Aktienkurse etc.
- * In der Statistik mit realen Daten aus der Welt sprechen wir von *Daten oder Stichproben*; bei Statistikpaketen oder wenn wir die Theorie anhand eines Beispiels veranschaulichen wollen, sprechen wir von *Realisationen*: "Sei x_1, x_2, \dots, x_n eine Realisation vom Umfang n aus einer $\mathcal{N}(0, 1)$ -Zufallsgrösse".
- * Daten werden immer mit kleinen Buchstaben angegeben. Meist werden wir die dazugehörige Zufallsgrösse (aus der die Realisation stammt oder wir gehen zumindest mal davon aus) mit den dazugehörenden Grossbuchstaben bezeichnen: X_i und x_i .
- * Wenn nicht anders vereinbart, werden Stichproben und Realisationen vom Umfang n so behandelt, dass man jedem Datenpunkt die Wahrscheinlichkeit $1/n$ zuweist und davon ausgeht, dass die n Daten unabhängig voneinander generiert wurden. Nochmals: Dies wird (mit gutem Grund) vereinbart und ist keineswegs zwingend! Wir haben dann also:

$$(X_1(\omega), X_2(\omega), \dots, X_n(\omega)) = (x_1, x_2, \dots, x_n),$$

wenn X_i z.B. die Anzahl Augen beim i -ten Wurf ist und die Welt im Zustand ω ist und die X_i 's voneinander unabhängig sind.

Paar Bemerkungen dazu:

Theorie versus Daten und ein praktisches Zwischending:

Artikel vom Dozenten (erwartete Anzahl Rekorde): <https://schweizermonat.ch/rekorde>

Wichtig:

1. Lesen Sie jetzt das komplette Kapitel im Storrer II selber durch, genauer Kapitel 37 - 41.
2. Lösen Sie danach mindestens 5 Aufgaben hinten im Kapitel und vergleichen Sie mit den Lösungen am Schluss des Buches. Bei Bedarf lösen Sie mehr Aufgaben.
3. Gehen Sie in die Übungsstunde. Drucken Sie das Übungsblatt dazu *vorher* aus, lesen Sie *vorher* die Aufgaben durch und machen sich erste Gedanken dazu (zum Beispiel, wie man sie lösen könnte).
4. Dann lösen Sie das Übungsblatt: zuerst immer selber probieren, falls nicht geht: Tipp von Mitstudi benutzen, falls immer noch nicht geht: Lösung von Mitstudi anschauen, 1 Stunde warten, versuchen, aus dem Kopf heraus wieder zu lösen, falls immer noch nicht geht: Lösung von Mitstudi abschreiben (und verstehen - also sollte man insbesondere keine Fehler abschreiben!).
5. Lösen Sie die entsprechenden Prüfungsaufgaben im Archiv.