

# Stochastik für die Informatik, Vorlesung 15

## Inhalt

- ▶ Gesetz der groen Zahlen und zentraler Grenzwertsatz
- ▶ Normalapproximation der Binomialverteilung

## Lernziele


- ▶ Das Gesetz der groen Zahlen kennen
- ▶ Den zentralen Grenzwertsatz und seine wichtigsten Implikationen kennen
- ▶ Die Binomialverteilung mit Hilfe der Normalverteilung approximieren können

**Vorkenntnisse** Stoff der bisherigen Vorlesungen, insbesondere zum Thema Zufallsvariablen und Verteilungen, Integral- und Differentialrechnung


## Kapitel 7: Grenzwertsätze

Beispiel aus Kapitel 5: Ergebnis beim 100-fachen Würfeln. Fairer Würfel,  $X$  = Ergebnis eines Wurfs.

Simulation: 100x Würfeln,  $y_i$  Ergebnis des  $i$ -ten Wurfs.



# Mittelwert beim $n$ -fachen Würfeln



Für große  $n$  nähert sich der beobachtete Mittelwert  $\frac{1}{n} \sum_{i=1}^n y_i$  dem Erwartungswert an.

# Gesetz der großen Zahlen

(Satz 7.1: Gesetz der großen Zahlen). Sei  $(X_i)_{i \in \mathbb{N}}$  eine Folge von unabhängigen, identisch verteilten Zufallsvariablen auf  $(\Omega, \mathbb{P})$  mit  $\mathbb{V}(X_i) < \infty$ . Dann gilt

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n X_i = \mathbb{E}[X_1].$$

- ▶ “identisch verteilt” bedeutet dabei, dass alle  $X_i$  *dieselbe* Verteilung haben. Insbesondere gilt  $\mathbb{E}[X_1] = \dots = \mathbb{E}[X_n]$  und  $\mathbb{V}(X_1) = \dots = \mathbb{V}(X_n)$ .
- ▶ (Beweis mit Hilfe der Chebyshev-Ungleichung)
- ▶ (Bem. Art der Konvergenz)

# Gesetz der großen Zahlen: Approximation

Aus dem Gesetz der großen Zahlen wissen wir, dass für unabhängige, identisch verteilte Zufallsvariablen  $(X_i)_{i \in \mathbb{N}}$  gilt:

$$\sum_{i=1}^n X_i \approx n \cdot \mathbb{E}[X_1].$$

- ▶ Grundpfeiler der Statistik: Mittel über Messwerte als **Schätzer** für den Erwartungswert.
- ▶ Verbesserung der Approximation? eine Aussage über den Fehler?

# Zentraler Grenzwertsatz

(Satz 7.2: Zentraler Grenzwertsatz) Sei  $(X_i)$  eine Folge von unabhängigen, identisch verteilten Zufallsvariablen auf  $(\Omega, \mathbb{P})$ , mit  $\mathbb{E}[X_1] = \mu, \mathbb{V}(X_1) = \sigma^2 \in (0, \infty)$ . Dann gilt für alle  $x \in \mathbb{R}$

$$\lim_{n \rightarrow \infty} \mathbb{P}\left(\frac{1}{\sqrt{n}} \sum_{i=1}^n \frac{X_i - \mu}{\sigma} \leq x\right) = \Phi_{0,1}(x).$$

- ▶  $\Phi_{0,1}(x)$  ist die Verteilungsfunktion der Standardnormalverteilung
- ▶ (ohne Beweis)
- ▶ Dieser Satz gilt **unabhängig von der Verteilung der  $X_i$ !** Die Normalverteilung ist der **universelle Limes**.

# Zentraler Grenzwertsatz

- ▶ Der zentrale Grenzwertsatz besagt, dass die Zufallsvariable

$$Y := \frac{1}{\sqrt{n}} \sum_{i=1}^n \frac{X_i - \mu}{\sigma}$$

ungefähr (für große  $n$ ) **standardnormalverteilt** ist.

- ▶ Verbesserte Approximation durch Umformung der obigen Gleichung:

$$\sum_{i=1}^n X_i \approx n \cdot \mathbb{E}[X_1] + \sqrt{n} \cdot \sigma \cdot Y,$$

wobei  $Y$  eine standardnormalverteilte Zufallsvariable ist.  $n \cdot \mathbb{E}[X_i]$  ist die Information aus dem Gesetz der großen Zahlen,  $\sqrt{n} \cdot \sigma \cdot Y$  die Information aus dem zentralen Grenzwertsatz.

## Beispiel 7.2: Binomialverteilung

Sei  $Z \sim \text{Bin}(0.4, 20)$ .


Wie in Kapitel 3 können wir schreiben:

$$Z = \sum_{i=1}^{20} X_i,$$

wobei die  $X_i$  unabhängige, identisch verteilte Bernoulli-Variablen mit Parameter  $p = 0.4$  sind, also ist

$$\mathbb{E}[X_1] = p = 0.4, \quad \text{und} \quad \mathbb{V}(X_1) = p(1 - p) = 0.4 \cdot 0.6 = 0.24.$$

# Binomialverteilung mit $p = 0.4, n = 20$



## Beispiel 7.2, Fortsetzung

Wir können nun den zentralen Grenzwertsatz auf

$$Z = \sum_{i=1}^{20} X_i$$

anwenden, und erhalten

$$Z \approx n \cdot \mathbb{E}[X_1] + \sqrt{n} \cdot \sigma \cdot Y = 20 \cdot 0.4 + \sqrt{20 \cdot 0.24} Y \approx 8 + 2.2Y,$$


wobei  $Y \sim \mathcal{N}(0, 1)$  ist. Beachte:

$$8 + \sqrt{20 \cdot 0.24} Y \sim \mathcal{N}(8, 4.8).$$

Verbesserung der Approximation:  $n$  größer wählen. Für  $n = 100$  :

$$Z \approx 40 + 4.9Y \sim \mathcal{N}(40, 24)$$

Binomialverteilung mit  $p = 0.4$ ,  $n = 100$ ,  
Normalverteilungsdichte  $\mathcal{N}(40, 24)$



# Anwendung: Normalapproximation der Binomialverteilung

Sei  $Z \sim \text{Bin}(n, p)$ . Dann ist für  $n$  hinreichend groß die Zufallsvariable

$$\frac{Z - \mathbb{E}[Z]}{\sqrt{\mathbb{V}(Z)}} = \frac{Z - np}{\sqrt{np(1-p)}}$$

annähernd normalverteilt, also gilt für  $a, b \in \{0, \dots, n\}$

$$\mathbb{P}(a \leq Z \leq b) \approx \Phi_{0,1}\left(\frac{b - np}{\sqrt{np(1-p)}}\right) - \Phi_{0,1}\left(\frac{a - np}{\sqrt{np(1-p)}}\right).$$

- ▶ Herleitung aus zentralem Grenzwertsatz:  $Z = \sum_{i=1}^n X_i$ , für  $(X_i)$  unabhängig, Bernoulli-verteilt.
- ▶ Faustregel: Die Approximation ist gut (stimmt bis auf 2-3 Nachkommastellen), falls  $np \geq 5$  und  $n(1-p) \geq 5$  erfüllt sind.

# Anwendung: Normalapproximation der Binomialverteilung

Etwas genauere Approximation:

(Satz 7.3) Sei  $Z \sim \text{Bin}(n, p)$ . Dann gilt für  $a, b \in \{0, \dots, n\}$ ,

$$\mathbb{P}(a \leq Z \leq b) \approx \Phi_{0,1}\left(\frac{b + 1/2 - np}{\sqrt{np(1-p)}}\right) - \Phi_{0,1}\left(\frac{a - 1/2 - np}{\sqrt{np(1-p)}}\right).$$

- ▶ 1/2-Korrektur aus Übergang diskret-stetig:

$$\mathbb{P}(4 \leq Z \leq 8) = \mathbb{P}(3.5 \leq Z \leq 8.5)$$

- ▶ (Beispiel 7.3)

# Zentraler Grenzwertsatz: Zusammenfassung

- ▶ Der zentrale Grenzwertsatz besagt, dass die Zufallsvariablen


$$\frac{1}{\sqrt{n}} \sum_{i=1}^n \frac{X_i - \mu}{\sigma}$$

ungefähr (für große  $n$ ) **standardnormalverteilt** ist.

- ▶ Der zentrale Grenzwertsatz gilt universell, also egal welche Verteilung die  $X_i$  haben (solange sie unabhängig und identisch verteilt mit endlicher Varianz sind).
- ▶ Eine Zufallsvariable, welche als Summe von unabhängigen, identisch verteilten Zufallsvariablen geschrieben werden kann, ist (nach Reskalierung) ungefähr normalverteilt
- ▶ Wann immer viele unabhängige Ergebnisse aufsummiert werden, so ist das Ergebnis nach Reskalierung ungefähr normalverteilt.
- ▶ Wichtige Grundlage für die **Statistik**


## Beispiel: Wahlergebnisse

Anzahl Wahlbüros, welche eine bestimmte Prozentzahl für die Partei gemeldet haben.  $x_i$ : Prozentzahl, welches Wahlbüro Nr.  $i$  für Partei  $X$  gemeldet hat. Geplottet sind die Häufigkeiten der gemeldeten Prozentzahlen.



# Beispiel: Wahlergebnisse

## Bundestagswahl in Deutschland 2009, Zweitstimmen



# Kapitel 8: Parameterschätzung

**Wahrscheinlichkeitstheorie:** Allgemeine Theorie angewandt auf konkrete Modelle.

Woher kommt das konkrete Modell?

**Statistik:** Durch Analyse und Interpretation von Daten aus Beobachtungen können Modelle aufgestellt, getestet und kalibriert werden

# Statistik: Grundproblem

**Gegeben:** Große Anzahl von **Messwerten (Daten)**  $x_1, \dots, x_n$  mit  $x_j \in \mathbb{R}$

**Allgemeines Ziel der Statistik:** Aufstellen eines mathematischen Modells, welches diese Daten beschreibt, und welches mit wahrscheinlichkeitstheoretischen Methoden untersucht werden kann.

**Grundaufgaben:**

- ▶ Schätzer, Bestimmung von Kenngrößen
- ▶ Konfidenzintervalle
- ▶ Hypothesentests

# Grundannahmen der Statistik:

Betreffend der gemessenen Daten  $x_1, \dots, x_n$  gehen wir von einer der beiden (sich nicht ausschließenden) Grundannahmen aus:

- ▶ Die gemessenen Daten sind einzelne **Realisierungen** von (unabhängigen, identisch verteilten) **Zufallsvariablen**  $X_1, \dots, X_n$
- ▶ Die gemessenen Daten stellen eine **Stichprobe** aus einer (noch viel größeren) **Population** dar.

Unter dieser Prämisse will man mittels der Stichprobe Aussagen über die zugrundeliegende Zufallsvariablen bzw. über die gesamte Population machen

# Beschreibende Statistik

**Beispiel 8.1: Eine Messreihe.** Messung der Zeit bis zur Betriebsbereitschaft eines elektronischen Geräts (in Sekunden)

Messung Nr.	1	2	3	4	5	6	7	8
Wert	10.9	6.8	9.5	6.9	8.2	3.4	6.2	8.6
Messung Nr.	9	10	11	12	13	14		
Wert	5.3	10.7	8.1	8.0	8.9	10.7		

- ▶ Wie können solche Daten geeignet dargestellt werden?
- ▶ Welche Informationen können aus diesen Daten abgelesen werden?
- ▶ Um welche “Art” von Daten handelt es sich hier, und inwiefern sind sie mit unseren Grundannahmen kompatibel?
- ▶ Welche weiterführenden Fragestellungen ergeben sich möglicherweise?

# Häufigkeiten

(Def. 8.1) Sei  $(x_1, \dots, x_n) \in \mathbb{R}^n$  ein Vektor (von Messwerten). Sei  $x \in \mathbb{R}$ . Die **absolute Häufigkeit** von  $x$  ist

$$H(x) := |\{i : x_i = x\}|,$$

d.h. sie gibt an, wie oft der Wert  $x$  im Vektor  $(x_1, \dots, x_n)$  vorkommt. Die **relative Häufigkeit** von  $x$  ist

$$h(x) := \frac{H(x)}{n}.$$

- ▶  $H(x) \in \mathbb{N}_0, h(x) \in [0, 1]$ .
- ▶ (Beispiel 8.1)
- ▶ (Bem. stetige und diskrete Merkmale)

(Def. 8.2) Ein **Histogramm** der Daten ist ein Plot der Funktion  $x \mapsto H(x)$  oder  $x \mapsto h(x)$ , oder, im Falle einer Einteilung in Klassen, der Funktion  $A \mapsto H(A)$  bzw.  $A \mapsto h(A)$ .

# Kenngößen von Daten

(Def. 8.4) Sei  $(x_1, \dots, x_n) \in \mathbb{R}^n$  ein Vektor (von Messwerten/Daten). Das **empirische Mittel** von  $(x_1, \dots, x_n)$  ist definiert als

$$\bar{\mu}_n(x_1, \dots, x_n) = \bar{\mu}_x := \frac{1}{n} \sum_{i=1}^n x_i$$

(Def. 8.5) Sei  $(x_1, \dots, x_n) \in \mathbb{R}^n$  ein Vektor (von Messwerten/Daten). Der **Median** von  $(x_1, \dots, x_n)$  ist definiert als der Wert in der Mitte der geordneten Liste. Falls  $n$  gerade ist, wird der Durchschnitt der beiden mittleren Werte gebildet.

(Def. 8.6) Sei  $(x_1, \dots, x_n) \in \mathbb{R}^n$  ein Vektor (von Messwerten/Daten). Die **empirische Varianz** von  $(x_1, \dots, x_n)$  ist definiert als

$$\bar{\sigma}_n^2(x_1, \dots, x_n) = \bar{\sigma}_x^2 := \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{\mu}_x)^2$$


# Kenngößen von Daten

- ▶ Empirisches Mittel: Durchschnittswert
- ▶ Empirische Varianz: Maß für die Streuung

## R-Befehle:

- ▶ `mean()` empirisches Mittel
- ▶ `var()` empirische Varianz
- ▶ `median()` Median
- ▶ `sort()` Liste aufsteigend sortieren
- ▶ `hist()` Zeichnet Histogramm.

## Beispiel 8.13: R-Datensatz



- ▶ Daten von zwei gleichzeitig gemessenen Größen: **Paare von Messwerten**  $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ .
- ▶ Grundannahme: Realisierungen zweier Zufallsvariablen  $X$  und  $Y$ .

## Beispiel 8.13: R-Datensatz

Beispieldatensatz in R: Old faithful Geysir, Yellowstone

- ▶ Aufrufen mit Befehl `faithful`
- ▶ Dauer des Ausbruchs und Wartezeit zwischen Ausbrüchen in Minuten
- ▶ 272 Datenpaare
- ▶ Beispiel: Berechnung von empirischem Mittel und empirischer Varianz von Dauer und Wartezeit:

```
> data<-faithful
> x<-faithful$eruptions
> y<-faithful$waiting
> mx<-mean(x)
> my<-mean(y)
> vx<-var(x)
> vy<-var(y)
```

- ▶ Ergebnis:  $\bar{\mu}_x = 3.487783$ ,  $\bar{\mu}_y = 70.89706$ ,  
 $\bar{\sigma}_x^2 = 1.302728$ ,  $\bar{\sigma}_y^2 = 184.8233$

# Parameterschätzung

**Grundprinzip der Parameterschätzung:** Aus den gemessenen Daten die Kenngrößen der (unbekannten) zugrundeliegenden Verteilung schätzen. Dafür müssen gewisse Annahmen getroffen werden (z.B. Unabhängigkeit).

Es gibt viele **verschiedene Methoden** für die Parameterschätzung. Wir lernen klassische Schätzer für wichtige Kenngrößen kennen, sowie die Methode der “Maximum Likelihood”-Schätzung.

# Schätzfunktion

(Def. 8.7) Seien  $X_1, \dots, X_n$  Zufallsvariablen auf einem Wahrscheinlichkeitsraum  $(\Omega, \mathbb{P})$ . Eine **Schätzfunktion** zur Stichprobengröße  $n$  ist eine Funktion

$$\theta_n : \mathbb{R}^n \rightarrow \mathbb{R}, (X_1, \dots, X_n) \mapsto \theta_n(X_1, \dots, X_n).$$

- ▶ Für praktische Zwecke sollte eine Schätzfunktion einen Zusammenhang mit einem Parameter oder einer Kenngröße der Verteilung der  $X_1, \dots, X_n$  haben
- ▶ Ist dieser Parameter unbekannt, so erhält man, nach Messung der Daten  $x_1, \dots, x_n$  als Realisierungen von  $X_1, \dots, X_n$  einen **Schätzer** oder **Schätzwert** für den Parameter.
- ▶ Damit die Schätzfunktion und der Schätzer nützlich sind, sollten sie gewisse günstige Eigenschaften haben.
- ▶ (Bem. Statistisches Modell)

# Klassische Schätzer

Beispiel 8.3: Empirisches Mittel. Seien  $(x_1, \dots, x_n) \in \mathbb{R}^n$  Messwerte. Das empirische Mittel (vgl. Def. 8.4) ist definiert als

$$\bar{\mu}_x = \bar{\mu}_n(x_1, \dots, x_n) = \frac{1}{n} \sum_{i=1}^n x_i$$

- ▶ Sind die  $x_i$  Realisierungen von unabhängigen, identisch verteilten Zufallsvariablen  $X_1, \dots, X_n$ , so gilt mit dem Gesetz der großen Zahlen

$$\bar{\mu}_n(X_1, \dots, X_n) = \frac{1}{n} \sum_{i=1}^n X_i \rightarrow \mathbb{E}[X_i] = \mu$$

- ▶  $\bar{\mu}_x$  ist ein **Schätzwert** für den Erwartungswert der zugrundeliegenden Zufallsvariablen.

# Klassische Schätzer

Beispiel 8.4: Empirische Varianz. Seien  $(x_1, \dots, x_n) \in \mathbb{R}^n$  Messwerte. Die empirische Varianz (vgl. Def. 8.6) ist definiert als

$$\bar{\sigma}_x^2 = \bar{\sigma}_n^2(x_1, \dots, x_n) = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{\mu}_n(x_1, \dots, x_n))^2$$

- ▶  $\bar{\sigma}_x^2$  ist ein **Schätzwert** für die Varianz der zugrundeliegenden Zufallsvariablen.

# Eigenschaften von Schätzern

(Def. 8.7) Sei  $(x_1, \dots, x_n) \in \mathbb{R}^n$  ein Vektor von Daten, welche als Realisierungen von identisch verteilten Zufallsvariablen  $X_1, \dots, X_n$  mit Parameter  $\theta$  auf einem Wahrscheinlichkeitsraum  $(\Omega, \mathbb{P})$ . Sei  $\theta_n$  eine Schätzfunktion zur Stichprobengröße  $n$ .

- ▶  $\theta_n$  ist ein **erwartungstreuer Schätzer** für  $\theta$ , falls

$$\mathbb{E}[\theta_n(X_1, \dots, X_n)] = \theta$$

ist (engl: **unbiased**).

- ▶  $\theta_n$  ist ein **konsistenter Schätzer** für  $\theta$ , falls

$$\lim_{n \rightarrow \infty} \theta_n(X_1, \dots, X_n) = \theta$$

gilt.

- ▶  $\theta_n$  ist ein **effizienter Schätzer** für  $\theta$ , falls

$$\lim_{n \rightarrow \infty} \mathbb{V}(\theta_n(X_1, \dots, X_n)) = 0$$

gilt.

- ▶ (Beispiele)