

# Bedingte Wahrscheinlichkeit und Satz von Bayes

## Lektion B02 – BSc Wahrscheinlichkeit und Statistik

Digital Finance

- 1 Bedingte Wahrscheinlichkeit
- 2 Unabhängigkeit und Multiplikationssatz
- 3 Sensitivität und Spezifität
- 4 Satz von Bayes
- 5 Zusammenfassung

### Für diese Lektion benötigen Sie:

- Ergebnisraum  $\Omega$ , Ereignisse als Mengen
- Mengenoperationen:  $\cap$ ,  $\cup$ ,  $\bar{A}$
- Wahrscheinlichkeit  $P(A)$  und die Rechenregeln
- Komplementregel:  $P(\bar{A}) = 1 - P(A)$
- Additionsregel:  $P(A \cup B) = P(A) + P(B) - P(A \cap B)$
- Disjunkte Ereignisse und Partitionen

---

Alle Themen aus Lektion B01 – Grundlagen der Wahrscheinlichkeitsrechnung.

## Nach dieser Lektion können Sie:

- 1 Bedingte Wahrscheinlichkeiten mit der Formel  $P(A|B)$  berechnen
- 2 Abhängige und unabhängige Ereignisse unterscheiden und den Multiplikationssatz anwenden
- 3 Sensitivität und Spezifität eines Tests interpretieren
- 4 Den Satz von der totalen Wahrscheinlichkeit verstehen
- 5 Den Satz von Bayes herleiten und auf praktische Probleme anwenden
- 6 Bayes sequentiell anwenden (mehrere Tests hintereinander)

## Durchgehendes Beispiel: Medizinischer Test

Prävalenz 1%, Sensitivität 99%, Spezifität 95%

---

Diese Lernziele bilden den roten Faden der Lektion.

## Alltagssituationen:

- Regenwahrscheinlichkeit morgen: 30%
- Aber: dunkle Wolken jetzt → Wahrscheinlichkeit steigt!

## Weiteres Beispiel – Urne:

- Urne mit **3 roten** und **2 blauen** Kugeln
- Ohne Information:  $P(\text{rot}) = 3/5 = 60\%$
- **Neue Info:** Erste gezogene Kugel war rot (ohne Zurücklegen)
- Jetzt:  $P(\text{rot beim 2. Zug}) = 2/4 = 50\%$

⇒ Zusatzwissen verändert die Wahrscheinlichkeit!

---

Bedingte Wahrscheinlichkeit formalisiert, wie Wissen Unsicherheit beeinflusst.

## Definition der bedingten Wahrscheinlichkeit

**Intuition:** Gegeben, dass  $B$  eingetreten ist – wie wahrscheinlich ist  $A$ ?

**Formale Definition:**

$$P(A|B) = \frac{P(A \cap B)}{P(B)}, \quad \text{falls } P(B) > 0$$

**Lies:** „Wahrscheinlichkeit von  $A$  gegeben  $B$ “


**Beispiel:** 100 Studierende: 30 studieren Mathe, 20 davon auch Physik.

- $P(\text{Physik} | \text{Mathe}) = \frac{20}{30} = 66,7\%$
- Von den Mathe-Studierenden studieren  $2/3$  auch Physik

---


Der senkrechte Strich „|“ bedeutet „gegeben“ oder „unter der Bedingung“.

**Idee:** Wenn wir wissen, dass  $B$  eingetreten ist, wird  $B$  zum neuen „Universum“.



**Vorher:** ganzes  $\Omega$

Bedingung  $B$   
→




**Nachher:** nur noch  $B$

$$P(A|B) = \frac{P(A \cap B)}{P(B)} = \frac{\text{Anteil von } A \text{ in } B}{\text{Größe von } B}$$

Bedingen = den Ergebnisraum auf  $B$  einschränken.

## Baumdiagramm: Medizinischer Test



## Rechenbeispiel: Kartenziehen

**Standarddeck:** 52 Karten, 4 Asse, 26 rote Karten, 2 rote Asse.

**Frage:**  $P(\text{Ass} \mid \text{rote Karte}) = ?$

$$P(\text{Ass} \mid \text{rot}) = \frac{P(\text{Ass} \cap \text{rot})}{P(\text{rot})} = \frac{2/52}{26/52} = \frac{2}{26} = \frac{1}{13} \approx 7,7\%$$

**Vergleich:**  $P(\text{Ass}) = 4/52 = 1/13 \approx 7,7\%$

⇒ Die Wahrscheinlichkeit ändert sich **nicht!**

Das liegt daran, dass „Ass“ und „rote Karte“ **unabhängig** sind.

---

Wenn  $P(A|B) = P(A)$ , dann sind  $A$  und  $B$  unabhängig – mehr dazu gleich.

## Rechenbeispiel: Würfel

**Fairer Würfel:**  $\Omega = \{1, 2, 3, 4, 5, 6\}$

**Frage:** Wie wahrscheinlich ist eine Zahl  $> 4$ , wenn wir wissen, dass sie ungerade ist?

$$A = \{5, 6\} \quad (\text{größer als } 4)$$

$$B = \{1, 3, 5\} \quad (\text{ungerade})$$

$$A \cap B = \{5\}$$

$$P(A|B) = \frac{P(A \cap B)}{P(B)} = \frac{1/6}{3/6} = \frac{1}{3} \approx 33,3\%$$

**Ohne Bedingung:**  $P(A) = 2/6 = 1/3$  – dies bedeutet, dass  $A$  und  $B$  hier **unabhängig** sind – wir definieren dies in Abschnitt 2.

---

**Üben Sie:** Berechnen Sie  $P(B|A) = P(\text{ungerade} | > 4)$ .

Zwei Ereignisse  $A$  und  $B$  sind **unabhängig**, wenn:

$$P(A \cap B) = P(A) \cdot P(B)$$

**Äquivalent:**

$$P(A|B) = P(A) \quad \text{und} \quad P(B|A) = P(B)$$

**Bedeutung:** Das Eintreten von  $B$  verändert die Wahrscheinlichkeit von  $A$  **nicht**.

**Beispiele für Unabhängigkeit:**

- Zwei Münzwürfe hintereinander
- Ziehen **mit** Zurücklegen
- Würfel und Münze gleichzeitig

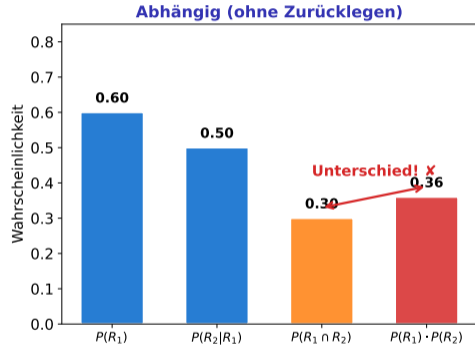
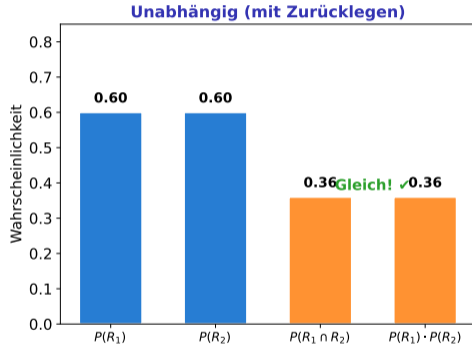
**Warnung:** Unabhängig  $\neq$  unvereinbar (disjunkt)!

Disjunkte Ereignisse sind sogar **stark abhängig**:  $A$  tritt ein  $\Rightarrow B$  kann nicht eintreten.

---

Unabhängigkeit bedeutet: Wissen über  $B$  hilft nicht bei der Vorhersage von  $A$ .

## Urne: 3 rote, 2 blaue Kugeln — Zweimal Ziehen



Mit Zurücklegen:  $P(R_1 \cap R_2) = P(R_1) \cdot P(R_2)$ . Ohne Zurücklegen: Gleichung gilt nicht.

**Allgemeine Form:**

$$P(A \cap B) = P(A) \cdot P(B|A) = P(B) \cdot P(A|B)$$

**Bei Unabhängigkeit vereinfacht sich das zu:**

$$P(A \cap B) = P(A) \cdot P(B)$$

**Beispiel: Zwei faire Münzwürfe**

- $P(\text{Kopf}_1 \cap \text{Kopf}_2) = \frac{1}{2} \cdot \frac{1}{2} = \frac{1}{4}$

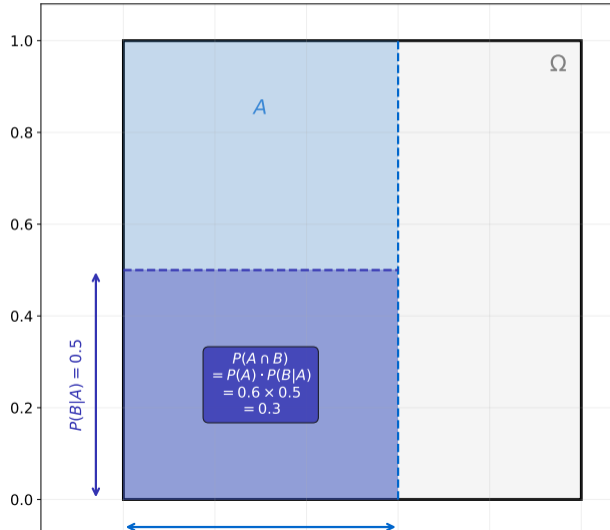
**Kettenregel (mehrere Ereignisse):**

$$P(A \cap B \cap C) = P(A) \cdot P(B|A) \cdot P(C|A \cap B)$$

---

Der Multiplikationssatz folgt direkt aus der Definition der bedingten Wahrscheinlichkeit.

## Multiplikationssatz (Flächenmodell)



**Zwei Bauteile in Reihe**, beide müssen funktionieren.

- Bauteil 1: Ausfallwahrscheinlichkeit  $P(A_1) = 0,02$
- Bauteil 2: Ausfallwahrscheinlichkeit  $P(A_2) = 0,03$
- Ausfälle sind unabhängig

**System funktioniert:**

$$P(\text{beide OK}) = P(\bar{A}_1) \cdot P(\bar{A}_2) = 0,98 \cdot 0,97 = 0,9506$$

**Mindestens ein Ausfall:**

$$P(\text{mind. ein Ausfall}) = 1 - 0,9506 = 0,0494 \approx 5\%$$

---


Bei unabhängigen Ereignissen multiplizieren wir einfach die Einzelwahrscheinlichkeiten.

## Medizinischer Test: Das Szenario

**Situation:** Eine Krankheit betrifft 1% der Bevölkerung (Prävalenz).

Es gibt einen diagnostischen Test mit:

- **Sensitivität** 99%: Der Test erkennt 99% der Kranken
- **Spezifität** 95%: Der Test erkennt 95% der Gesunden als gesund



Frage: Wenn der Test positiv ist – wie wahrscheinlich ist die Krankheit wirklich?

## Definitionen: Sensitivität und Spezifität

**Sensitivität** (Richtig-Positiv-Rate):

$$\text{Sensitivität} = P(\text{Test+} \mid \text{krank}) = \frac{\text{TP}}{\text{TP} + \text{FN}}$$

„Erkennt der Test die **Kranken**?“

**Spezifität** (Richtig-Negativ-Rate):

$$\text{Spezifität} = P(\text{Test-} \mid \text{gesund}) = \frac{\text{TN}}{\text{TN} + \text{FP}}$$

„Erkennt der Test die **Gesunden**?“

**TP** = True Positive (richtig positiv)

**FP** = False Positive (falsch positiv)

**FN** = False Negative (falsch negativ)

**TN** = True Negative (richtig negativ)

---

Hohe Sensitivität = wenig Übersehene. Hohe Spezifität = wenig falscher Alarm.

## Konfusionsmatrix: 1000 Personen

	Test +	Test -	
Tatsächlich krank	10 (TP)	0 (FN)	= 10
Tatsächlich gesund	50 (FP)	940 (TN)	= 990

**Sensitivität = TP / (TP + FN) = 10 / (10 + 0) = 100%**

## Warum hohe Sensitivität nicht ausreicht

**Unser Test:** Sensitivität 99%, Spezifität 95%

**Von 1000 Personen:**

- 10 sind krank → **10 positiv getestet** (fast alle erkannt!)
- 990 sind gesund → **50 falsch positiv** (5% von 990)

**Insgesamt positiv getestet:**  $10 + 50 = 60$  Personen

**Davon wirklich krank:** nur 10 von  $60 \approx 17\%$

### Das Basisraten-Problem:

Bei seltenen Krankheiten überwiegen die falsch-positiven Ergebnisse, weil die Grundgesamtheit der Gesunden viel größer ist!

---

Die Lösung dieses Rätsels liefert der Satz von Bayes.

**Schritt 1:** Aus der Definition der bedingten Wahrscheinlichkeit:

$$P(A|B) = \frac{P(A \cap B)}{P(B)} \quad \text{und} \quad P(B|A) = \frac{P(A \cap B)}{P(A)}$$

**Schritt 2:** Beide nach  $P(A \cap B)$  auflösen:

$$P(A \cap B) = P(A|B) \cdot P(B) = P(B|A) \cdot P(A)$$

**Schritt 3:** Gleichsetzen und nach  $P(A|B)$  auflösen:

$$P(A|B) = \frac{P(B|A) \cdot P(A)}{P(B)}$$

Das ist der **Satz von Bayes** – benannt nach Thomas Bayes (1701–1761).

---

Der Satz von Bayes ermöglicht es, Ursache-Wirkungs-Richtungen umzukehren.

## Satz der totalen Wahrscheinlichkeit

**Problem:** Oft kennen wir  $P(B)$  nicht direkt.

**Lösung:** Zerlege  $B$  in Teile über eine Partition:

$$P(B) = P(B|A) \cdot P(A) + P(B|\bar{A}) \cdot P(\bar{A})$$

Damit wird Bayes zu:

$$P(A|B) = \frac{P(B|A) \cdot P(A)}{P(B|A) \cdot P(A) + P(B|\bar{A}) \cdot P(\bar{A})}$$

**Medizintest:**

$$\begin{aligned} P(+) &= \underbrace{P(+|krank)}_{0,99} \cdot \underbrace{P(krank)}_{0,01} + \underbrace{P(+|gesund)}_{0,05} \cdot \underbrace{P(gesund)}_{0,99} \\ &= 0,0099 + 0,0495 = 0,0594 \end{aligned}$$

---

Der Satz der totalen Wahrscheinlichkeit liefert den Nenner für die Bayes-Formel.

$$P(A|B) = \frac{P(B|A) \cdot P(A)}{P(B)}$$

Term	Name	Bedeutung
$P(A)$	<b>Prior</b>	Vorwissen über $A$ ( <i>vor</i> dem Test)
$P(B A)$	<b>Likelihood</b>	Wie gut passt $B$ zu $A$ ?
$P(A B)$	<b>Posterior</b>	Neues Wissen über $A$ ( <i>nach</i> dem Test)
$P(B)$	<b>Evidenz</b>	Gesamtwahrscheinlichkeit von $B$

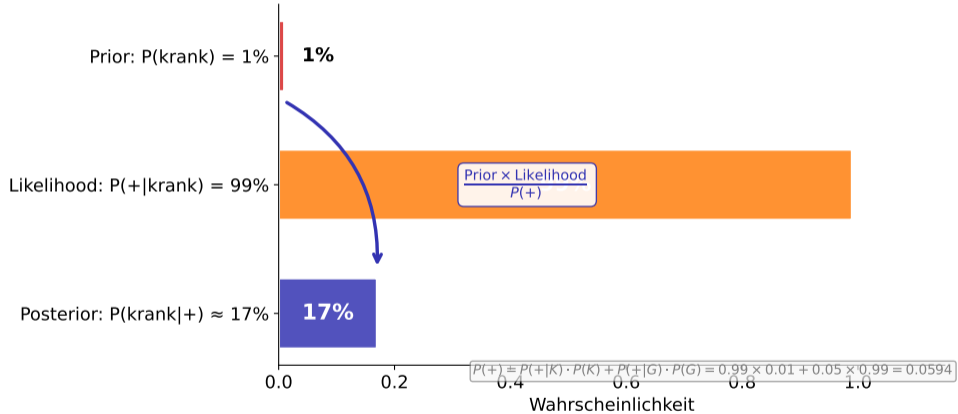
In Worten:

$$\text{Posterior} = \frac{\text{Likelihood} \times \text{Prior}}{\text{Evidenz}}$$

---

Bayes-Update: Altes Wissen + neue Daten = aktualisiertes Wissen.

## Bayes-Update: Von Prior zu Posterior



Der Prior (1%) wird durch die Evidenz zum Posterior (17%) aktualisiert.

## Gegeben:

- Prävalenz:  $P(\text{krank}) = 0,01$
- Sensitivität:  $P(+|\text{krank}) = 0,99$
- Spezifität:  $P(-|\text{gesund}) = 0,95$ , also  $P(+|\text{gesund}) = 0,05$

## Gesucht: $P(\text{krank} | +)$


$$\begin{aligned}P(\text{krank}|+) &= \frac{P(+|\text{krank}) \cdot P(\text{krank})}{P(+)} \\&= \frac{0,99 \times 0,01}{0,99 \times 0,01 + 0,05 \times 0,99} \\&= \frac{0,0099}{0,0099 + 0,0495} = \frac{0,0099}{0,0594} \\&\approx \mathbf{16,7\%}\end{aligned}$$

**Positiver Prädiktiver Wert (PPV):**  $P(\text{krank}|+) = 16,7\%$


**Negativer Prädiktiver Wert (NPV):**  $P(\text{gesund}|-) \approx 99,99\%$

Trotz 99% Sensitivität liegt die Wahrscheinlichkeit, wirklich krank zu sein, nur bei ca. 17%.

**1000 Personen: Wer ist wirklich krank?**



# Bayes-Entscheidungsbaum



$$P(\text{krank}|+) = \frac{10}{10 + 50} = \frac{10}{60} \approx 16,7\%$$

Im Entscheidungsbaum sieht man sofort: Von 60 positiven sind nur 10 wirklich krank.

## Warum ist $P(\text{krank}|+)$ so niedrig?

### Drei Faktoren bestimmen das Ergebnis:

- 1 **Niedrige Prävalenz (1%):** Es gibt viel mehr Gesunde als Kranke
- 2 **Viele Gesunde  $\times$  kleine Fehlerrate = viele FP:**  
 $990 \times 0,05 = 50$  falsch-positive Ergebnisse
- 3 **Wenige Kranke  $\times$  hohe Erkennungsrate = wenige TP:**  
 $10 \times 0,99 = 10$  richtig-positive Ergebnisse

$\Rightarrow$  Die falsch-positiven Ergebnisse **überfluten** die richtig-positiven!

### Intuitive Daumenregel:

Je seltener die Krankheit, desto eher ist ein positives Testergebnis ein **Fehlalarm**.

---

Deshalb werden Screening-Tests bei seltenen Krankheiten kritisch betrachtet.

## Was passiert bei höherer Prävalenz?

**Gleicher Test** (Sens. 99%, Spez. 95%), aber verschiedene Prävalenzen:

Prävalenz	TP	FP	$P(\text{krank} +)$	Bewertung
0,1%	1	50	2%	Fast nur Fehlalarme
1%	10	50	17%	Noch viele FP
5%	50	48	51%	Etwa 50:50
10%	99	45	69%	Mehrheit wirklich krank
50%	495	25	95%	Sehr zuverlässig

⇒ Der **gleiche Test** kann je nach Kontext völlig unterschiedlich bewertet werden!

In der Praxis: Zuerst Risikogruppe identifizieren (höhere Prävalenz), dann testen.

## Zweiter Test: Nochmals Bayes anwenden

Nach dem ersten positiven Test:  $P(\text{krank}) \approx 17\%$  (neuer Prior!)

Zweiter Test (gleiche Güte), wieder positiv:

$$\begin{aligned}P(\text{krank} | ++ ) &= \frac{P(+|\text{krank}) \cdot P(\text{krank nach 1. Test})}{P(+)} \\ &= \frac{0,99 \times 0,167}{0,99 \times 0,167 + 0,05 \times 0,833} \\ &= \frac{0,165}{0,165 + 0,042} = \frac{0,165}{0,207} \approx 80\%\end{aligned}$$

⇒ Der Prior steigt von 1% auf 17% auf 80%!

**Prinzip:** Der Posterior des ersten Tests wird zum Prior des zweiten Tests.

So funktioniert **sequentielles Bayes-Update**.

---

In der Medizin: Bei positivem Screening-Test wird oft ein Bestätigungstest durchgeführt.

**Fabrik:** Zwei Maschinen produzieren Bauteile.

- Maschine A: 60% der Produktion, 2% Ausschuss
- Maschine B: 40% der Produktion, 5% Ausschuss

**Frage:** Ein Bauteil ist defekt. Von welcher Maschine stammt es wahrscheinlich?

**Satz der totalen Wahrscheinlichkeit:**

$$P(\text{defekt}) = 0,02 \times 0,60 + 0,05 \times 0,40 = 0,012 + 0,020 = 0,032$$

**Bayes:**

$$P(A|\text{defekt}) = \frac{0,02 \times 0,60}{0,032} = \frac{0,012}{0,032} = 37,5\%$$

$$P(B|\text{defekt}) = \frac{0,05 \times 0,40}{0,032} = \frac{0,020}{0,032} = 62,5\%$$

---

Obwohl Maschine A mehr produziert, stammen defekte Teile eher von Maschine B.

### Prüfen Sie sich selbst:

- ✓ **Bedingte Wahrscheinlichkeit:** Ich kann  $P(A|B) = P(A \cap B)/P(B)$  anwenden und den reduzierten Ergebnisraum erklären.
- ✓ **Unabhängigkeit:** Ich kann prüfen, ob  $P(A \cap B) = P(A) \cdot P(B)$  gilt, und kenne den Multiplikationssatz.
- ✓ **Sensitivität & Spezifität:** Ich kann TP, FP, FN, TN zuordnen und die Kenngrößen berechnen.
- ✓ **Satz von Bayes:** Ich kann die Formel herleiten, Prior/Likelihood/Posterior benennen und auf Beispiele anwenden.

### Schlüsselerkenntnisse:

- Neue Information verändert Wahrscheinlichkeiten
- Bei seltenen Ereignissen dominieren falsch-positive Ergebnisse
- Bayes erlaubt systematisches Aktualisieren von Überzeugungen

---

Wiederholen Sie die Beispiele mit eigenen Zahlen!

Konzept	Formel
Bedingte W.	$P(A B) = \frac{P(A \cap B)}{P(B)}$
Multiplikationssatz	$P(A \cap B) = P(A) \cdot P(B A)$
Unabhängigkeit	$P(A \cap B) = P(A) \cdot P(B)$
Totale W.	$P(B) = P(B A) P(A) + P(B \bar{A}) P(\bar{A})$
Satz von Bayes	$P(A B) = \frac{P(B A) \cdot P(A)}{P(B)}$
Sensitivität	$\frac{TP}{TP + FN}$
Spezifität	$\frac{TN}{TN + FP}$