

## 1.3 Stochastische Unabhängigkeit und bedingte Wahrscheinlichkeiten

(Fahrmeir et al. (2003), Kap 4.4 bis 4.7)

### 1.3.1 Stochastische Unabhängigkeit

**Definition 1.22.** *Stochastische Unabhängigkeit:*

Zwei Ereignisse  $A$  und  $B$  heißen (*stochastisch*) *unabhängig* (unter  $P$ ), wenn gilt

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

andernfalls heißen sie *stochastisch abhängig*.

**Bem. 1.23.**

- „Stochastische Abhängigkeit“ bedeutet nicht „kausale Abhängigkeit“ (wie in den Überlegungen zu Korrelation und Kausalität in Statistik I diskutiert).
- Die (stochastische) Unabhängigkeit ist eine symmetrische Beziehung in dem Sinne, dass  $A$  und  $B$  genau dann unabhängig sind, wenn  $B$  und  $A$  unabhängig sind.

Genauer gilt die Äquivalenz folgender Aussagen:

$A$ und $B$	sind stochastisch unabhängig.
$A$ und $\bar{B}$	” .
$\bar{A}$ und $B$	” .
$\bar{A}$ und $\bar{B}$	” .

- Die Verwandtschaft zur empirischen Unabhängigkeit aus Statistik I.

$$f_{ij} = f_{i\bullet} \cdot f_{\bullet j} \text{ für alle } i, j$$

ergibt sich, wenn man sich durch  $A$  und  $B$  eine  $(2 \times 2)$ –Tafel erzeugt denkt, in der anstatt der Häufigkeiten die Wahrscheinlichkeiten stehen:

	$B$	$\bar{B}$	
$A$	$P(A \cap B)$	$P(A \cap \bar{B})$	$P(A)$
$\bar{A}$	$P(\bar{A} \cap B)$	$P(\bar{A} \cap \bar{B})$	$P(\bar{A})$
	$P(B)$	$P(\bar{B})$	

Unabhängigkeit:

gemeinsame Verteilung = Produkt der Randverteilungen

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

analog für  $\bar{A}, \bar{B}$ , (vgl. obige Äquivalenz)

**Bsp. 1.24. [Wahlbeispiel (Fortsetzung)]**

Sind hier die Ereignisse  $A = \{1, 3\}$  und  $C = \{3, 4\}$  stochastisch unabhängig?

Unabhängigkeit ist eine Eigenschaft, die vom Wahrscheinlichkeitsmaß abhängt. Betrachtet man wieder  $\Omega = \{1, 2, 3, 4, 5, 6\}$ , jetzt aber mit  $P(\{1\}) = \frac{1}{9}$ ,  $P(\{2\}) = \frac{1}{9}$ ,  $P(\{3\}) = \frac{1}{18}$ ,  $P(\{4\}) = \frac{5}{18}$ ,  $P(\{5\}) = \frac{2}{9}$ ,  $P(\{6\}) = \frac{2}{9}$ ,

also sind hier  $A$  und  $C$  stochastisch **un**abhängig (selbes  $\Omega$ , anderes Wahrscheinlichkeitsmaß!).

**Definition 1.25.** *Stochastische Unabhängigkeit mehrerer Ereignisse:*

Ereignisse  $A_1, A_2, \dots, A_n$  heißen (vollständig) stochastisch unabhängig, wenn für alle  $I \subseteq \{1, \dots, n\}$  gilt

$$P\left(\bigcap_{i \in I} A_i\right) = \prod_{i \in I} P(A_i).$$

**Bem. 1.26.**

Achtung: Aus der paarweisen Unabhängigkeit

$$P(A_i \cap A_j) = P(A_i)P(A_j) \quad \text{für alle } i, j$$

folgt im Allgemeinen nicht die vollständige Unabhängigkeit.

**Bsp. 1.27.** *Klassisches Beispiel (Bernsetin (1912))*

(Vgl. Wikipedia, „Stochastische Unabhängigkeit“, aufgerufen am 2.4.14)

Schachtel mit 4 Zetteln mit den Zahlenkombinationen: 112, 121, 211, 222.

Reine Zufallsauswahl eines Zettels.

Sei  $A_i$  „die Ziffer 1 steht an der  $i$ -ten Stelle“,  $i = 1, 2, 3$ , so gilt,

$$P(A_1) = P(A_2) = P(A_3) = \frac{1}{2},$$

$$P(A_1 \cap A_2) = P(\{112\}) = \frac{1}{4} = \frac{1}{2} \cdot \frac{1}{2} = P(A_1) \cdot P(A_2)$$

$$P(A_1 \cap A_3) = P(\{121\}) = \frac{1}{4} = \frac{1}{2} \cdot \frac{1}{2} = P(A_1) \cdot P(A_3)$$

$$P(A_2 \cap A_3) = P(\{211\}) = \frac{1}{4} = \frac{1}{2} \cdot \frac{1}{2} = P(A_2) \cdot P(A_3),$$

also herrscht paarweise Unabhängigkeit, aber

$$P(A_1 \cap A_2 \cap A_3) = P(\emptyset) = 0 \neq \frac{1}{8} = \frac{1}{2} \cdot \frac{1}{2} \cdot \frac{1}{2} = P(A_1) \cdot P(A_2) \cdot P(A_3)$$

Beobachtung von 1 an den ersten beiden Stellen schließt Ziffer 1 an der dritten Stelle aus.

## 1.3.2 Bedingte Wahrscheinlichkeiten:

- $A$  Ereignis, das mit Wahrscheinlichkeit  $P(A)$  eintritt.  
Zusatzinformation: Ereignis  $B$  ist eingetreten.
- Frage: Wie ist nun die Wahrscheinlichkeit für das Eintreten von  $A$  neu zu bewerten?  
Welche Wahrscheinlichkeit hat  $A$  „gegeben“  $B$ ?
- Notation:  $P(A | B)$ .
- Wie in Statistik I: Einschränkung der Betrachtung, hier auf alle Situationen, bei denen  $B$  eingetreten ist

### Einmaliges Würfeln

- fairer Würfel
- Ereignis  $A \hat{=} \text{Augenzahl } 6$ , d.h.  $A = \{6\}$ . Es gilt  $P(A) = \frac{1}{6}$ .

- Zusatzinformation: Augenzahl gerade

Wie ändert sich die Wahrscheinlichkeit für  $A$ , wenn  $B = \{2, 4, 6\}$  eingetreten ist?

Intuitiv:

$$P(A|B) = \frac{P(A \cap B)}{P(B)} = \frac{1/3}{1/2} = \frac{2}{3}$$

Formalisierung:

### Definition 1.28.

Gegeben seien zwei Ereignisse  $A$  und  $B$  mit  $P(B) > 0$ . Dann heißt:

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

*bedingte Wahrscheinlichkeit von  $A$  gegeben  $B$  oder bedingte Wahrscheinlichkeit von  $A$  unter der Bedingung  $B$ .*

Interpretation analog zu bedingten Häufigkeiten in Statistik I:  $P(A|B)$  ist die Wahr-



scheinlichkeit von  $A$  wenn man bereits weiß, dass  $B$  gilt.

**Bsp. 1.29.**

**Bem. 1.30.**

- Die Beziehung zu Statistik I und den bedingten relativen Häufigkeiten ergibt sich, wenn man wieder die durch  $A$  und  $B$  erzeugte  $(2 \times 2)$ –Tafel betrachtet.
- An Stichprobenmodell denken: Grundgesamtheit  $\Omega$

$$P(B) \hat{=} f_{\bullet 1}, \quad P(A \cap B) \hat{=} f_{11}$$

	1	2	
1	$f_{11}$	$f_{12}$	$f_{1\bullet}$
2	$f_{21}$	$f_{22}$	$f_{2\bullet}$
	$f_{\bullet 1}$	$f_{\bullet 2}$	

- Es ergibt sich auch eine analoge Charakterisierung der stochastischen Unabhängigkeit über bedingte Wahrscheinlichkeiten:

Sind  $P(A)$  und  $P(B) > 0$ , so sind äquivalent:

i)  $A$  und  $B$  sind stochastisch unabhängig

- Dies führt zu folgender inhaltlicher Interpretation:

Ist  $P(A|B) = P(A)$ , so ändert das Wissen um  $B$  meine Bewertung von  $A$  nicht, also sind  $A$  und  $B$  unabhängig.

Nachweis zu ii)

- Die ursprüngliche Definition der Unabhängigkeit besitzt den Vorteil, dass man nicht  $P(A) = 0$ ,  $P(B) = 0$  ausschließen muss; für die Interpretation ist aber die Bezugnahme auf bedingte Wahrscheinlichkeiten viel anschaulicher.

- Interpretation von „unter der Bedingung  $B$ “:

Anstatt aller Ergebnisse in  $\Omega$  sind nur noch die Ergebnisse in  $B$  möglich. Das Betrachten bedingter Wahrscheinlichkeiten entspricht also einer Änderung des Grundraumes von  $\Omega$  zu  $B$ .

In der Tat ist

$$P_B(A) := P(A|B) = P(A \cap B|B) \quad (1.1)$$

als Funktion in  $A$  bei festem  $B$  wieder eine Wahrscheinlichkeitsbewertung, erfüllt also wieder die Axiome von Kolmogorov.

### 1.3.3 Koppelung von unabhängigen Experimenten, unabhängige Wiederholungen:

Mit dem Begriff der Unabhängigkeit (und bedingten Wahrscheinlichkeiten) kann man komplexere Situationen aus „Einzelbausteinen“ zusammensetzen:

- Bisher: Unabhängigkeit als zu überprüfende Eigenschaft

$$P(A_1 \cap A_2) = P(A_1) \cdot P(A_2) \implies \text{unabhängig.}$$

- Jetzt: Experimente „koppeln“
- Beispiel: Werfen eines Würfels ( $\Omega_1 = \{1, \dots, 6\}$ ) und eines Oktaeders ( $\Omega_2 = \{1, \dots, 8\}$ ) unabhängig voneinander.

$$A_1 \subset \Omega_1 : A_1 = \{5, 6\},$$

$$A_2 \subset \Omega_2 : A_2 = \{7, 8\},$$

$A_1 \cap A_2$  : „eine 5 oder 6 mit dem Würfel und eine 7 oder 8 mit dem Oktaeder“

Dann definiert man

$$P(A_1 \cap A_2) [:= P(A_1 \times A_2) =] = P_1(A_1) \cdot P_2(A_2);$$

also erhält man bei einem fairem Würfel und einem fairem Oktaeder mit

$$P_1(\{j\}) = \frac{1}{6}, \quad i = 1, \dots, 6, \quad \text{und} \quad P_2(\{j\}) = \frac{1}{8}, \quad i = 1, \dots, 8,$$

$$P(A_1 \cap A_2) = \frac{1}{3} \cdot \frac{1}{4} = \frac{1}{12}.$$

Diese Konstruktion führt man für alle möglichen  $A_1 \subset \Omega_1$ ,  $A_2 \subset \Omega_2$  durch.

**Unabhängige Koppelung mehrerer Experimente:** Gegeben sei eine Menge von Zufallsexperimenten, beschrieben durch die Ergebnisräume  $\Omega_i$ ,  $i = 1, \dots, n$  und die Wahrscheinlichkeitsbewertungen  $P_i$ ,  $i = 1, \dots, n$ . Fasst man die Experimente zusammen, so ergibt sich der Ergebnisraum

$$\Omega := \Omega_1 \times \Omega_2 \times \dots \times \Omega_n$$

mit den Elementen

$$\omega := (\omega_1, \omega_2, \dots, \omega_n).$$

Sind die Experimente unabhängig (Dies ist inhaltlich zu entscheiden!), so setzt man für beliebige  $A_i \subset \Omega_i$ ,  $i = 1, \dots, n$ ,

$$P(A_1 \cap A_2 \cap \dots \cap A_n) = P_1(A_1) \cdot P_2(A_2) \cdot \dots \cdot P_n(A_n).$$

Dies beschreibt ein Wahrscheinlichkeitsmaß auf  $\Omega$ , bei dem – per Konstruktion – beliebige Ereignisse aus den einzelnen  $\Omega_i$  voneinander unabhängig sind.

Von besonderer Bedeutung ist der Fall *unabhängiger und identischer Wiederholungen*, bei dem dasselbe Experiment wiederholt durchgeführt wird.

### **Zufallsstichprobe vom Umfang $n$ : Graphische Veranschaulichung „Wahlbeispiel“**

Das Experiment „Ziehen einer Person und Ermittlung ihrer Parteipräferenz“ wird  $n$ -mal unabhängig (Befragte dürfen sich nicht gegenseitig beeinflussen!) durchgeführt.

Allgemeiner: Betrachte eine endliche Grundgesamtheit  $\tilde{\Omega}$  sowie ein Merkmal  $\tilde{X}$  mit Ausprägungen  $a_1, \dots, a_k$  und relativen Häufigkeiten  $f_1, \dots, f_k$ . Es werde eine reine *Zufallsstichprobe vom Umfang  $n$  bezüglich des Merkmals  $\tilde{X}$*  entnommen, d.h. eine (geordnete) Zufallsauswahl (mit Zurücklegen) von  $n$  Elementen

$$\omega_1, \dots, \omega_n \text{ mit } \omega_i \in \tilde{\Omega}, i = 1 \dots n,$$

und die diesbezüglichen Ausprägungen  $\tilde{X}(\omega_i)$  von  $\tilde{X}$  erhoben.



Sei für  $j = 1, \dots, k$ ,  $i = 1, \dots, n$  mit  $A_{ij}$  das Ereignis „ $\tilde{X}(\omega_i) = a_j$ “ bezeichnet („Die  $i$ -te gezogene Person hat Ausprägung  $a_j$ “), so gilt für beliebige  $j_1, j_2, \dots, j_n$

$$\begin{aligned} P(A_{1j_1} \cap A_{2j_2} \cap \dots \cap A_{nj_n}) &= P(A_{1j_1}) \cdot P(A_{2j_2}) \cdot \dots \cdot P(A_{nj_n}) \\ &= f_{j_1} \cdot f_{j_2} \cdot \dots \cdot f_{j_n} \end{aligned}$$

**Bsp. 1.31.**

Unmittelbar nach Schließung der Wahllokale 2002 habe man eine reine Zufallsauswahl vom Umfang 10 unter den Wählern vorgenommen. Wie groß ist die Wahrscheinlichkeit, mindestens 9 PDS-Anhänger in der Stichprobe zu haben?

Amtliches Endergebnis:

SPD:	38,5%
CDU/CSU:	38,5%
Grüne:	8,6%
FDP:	7,4%
PDS:	4,0%
Sonstige:	3,0%

### 1.3.4 Koppelung abhängiger Experimente:

Als nächster Schritt werden komplexere Experimente aus viel einfacheren, voneinander abhängigen Einzelexperimenten gebaut. Gerade bei komplexeren Anwendungen ist es meist bedeutend einfacher, (und auch sicherer, da sich die Chance erhöht, korrektes Expertenwissen zu erhalten) bedingte statt unbedingte Wahrscheinlichkeiten anzugeben.

Beispielsweise kann man versuchen, die Wahrscheinlichkeit eines Ereignisses dadurch zu bestimmen, dass man als Zwischenschritt „auf alle Eventualitäten bedingt“ und zunächst die entsprechenden bedingten Wahrscheinlichkeiten bestimmt. (→ Baumstruktur)

#### **Bsp. 1.32. [nach Fahrmeir et al., 2012]**

Eine Mannschaft gewinnt das Viertelfinalspiel. Wie groß ist die Chance, das Halbfinale zu gewinnen und ins Finale einzuziehen?

Gesucht:  $P(B)$  mit  $B =$  „Sieg im Halbfinale“

Technisch entscheidend:

- $A_1, A_2, A_3$  bilden eine vollständige Zerlegung.
- $(A_1 \cap B)$ ,  $(A_2 \cap B)$  und  $(A_3 \cap B)$  sind disjunkt und ergeben in der Vereinigung  $B$

Damit ergibt sich

$$\begin{aligned} P(B) &= P((A_1 \cap B) \cup (A_2 \cap B) \cup (A_3 \cap B)) \\ &= P(A_1 \cap B) + P(A_2 \cap B) + P(A_3 \cap B) \\ &= P(B|A_1) \cdot P(A_1) + P(B|A_2) \cdot P(A_2) + P(B|A_3) \cdot P(A_3) = 0.52 \end{aligned}$$

Das Ergebnis lässt sich verallgemeinern auf

- Beliebige Ereignisse  $B$
- und vollständige Zerlegungen  $(A_i)_{i=1, \dots, k}$ .

**Satz 1.33. [Satz von der totalen Wahrscheinlichkeit]**

Gegeben sei eine vollständige Zerlegung  $A_1, A_2, \dots, A_k$  von  $\Omega$  (vgl. 1.21). Dann gilt für jedes Ereignis  $B$

$$P(B) = \sum_{j=1}^k P(B|A_j) \cdot P(A_j) = \sum_{j=1}^k P(B \cap A_j).$$

Allgemeiner erlauben bedingte Wahrscheinlichkeiten die Modellierung komplexer „Experimente“, welche aus sukzessiven „Einzelexperimenten“ bestehen, bei denen die Ergebnisse jeweils von den vorherigen Experimenten abhängen dürfen (insb. dynamische stochastische Modelle).

**Koppelung abhängiger Experimente:** Gegeben seien  $n$  Experimente, beschrieben durch die Grundräume  $\Omega_i = \{a_{i1}, \dots, a_{ik_i}\}$  und die Wahrscheinlichkeitsbewertungen  $P_i, i = 1, \dots, n$ . Bezeichnet man für beliebiges  $i = 1, \dots, n$  und  $j = 1, \dots, k_i$ , mit  $A_{ij}$  jeweils das zu  $a_{ij}$  gehörige Elementarereignis (also das Ereignis „ $a_{ij}$  tritt ein“), so gilt:

$$P(A_{1j_1} \cap A_{2j_2} \cap \dots \cap A_{nj_n}) = P_1(A_{1j_1}) \cdot P_2(A_{2j_2}|A_{1j_1}) \cdot P_3(A_{3j_3}|A_{1j_1} \cap A_{2j_2}) \\ \cdot \dots \cdot P_n(A_{nj_n}|A_{1j_1} \cap A_{2j_2} \cap \dots \cap A_{n-1j_{n-1}})$$

Häufig werden die Indizes bei  $P$  weggelassen.

( $i$  als Zeit vorstellen.)

Arbeitet man mit mehreren abhängigen Experimenten, so ist folgende Folgerung aus dem Satz der totalen Wahrscheinlichkeit oft hilfreich:

**Korollar 1.34.**

Sei  $A_1, A_2, \dots, A_k$  eine vollständige Zerlegung. Dann gilt für beliebige Ereignisse  $B$  und  $C$  mit  $P(C) > 0$

$$P(B|C) = \sum_{j=1}^k P(B|(A_j \cap C)) \cdot P(A_j|C)$$

Beweisidee:  $P(B|C)$  ist für festes  $C$  als Funktion in  $B$  eine Wahrscheinlichkeit (vgl. 1.1). Wende den Satz der totalen Wahrscheinlichkeit auf diese Wahrscheinlichkeit an.

**Anwendungsbeispiele:**

- Komplexere Urnenmodelle ohne Zurücklegen, Wahrscheinlichkeit im  $n$ -ten Zug ist davon abhängig, welche Kugeln vorher gezogen wurden.
- Sicherheitsstudie zu Kernkraftwerken: Wahrscheinlichkeit für komplexe Pfade praktisch nicht angebar, aber eben bedingte Einzelwahrscheinlichkeiten.
- Markovmodelle (dynamische Modelle mit „einfacher Bedingung“)

**Markovmodelle:** Hier interpretiert man den Laufindex als Zeit. Gilt in der Koppelung abhängiger Experiment  $\Omega_1 = \Omega_2 = \dots = \Omega_n = \{a_1, \dots, a_k\}$  und sind alle bedingten Wahrscheinlichkeiten nur vom jeweils unmittelbar vorhergehenden Zeitpunkt abhängig, d.h. gilt

$$P(A_{i+1, j_{i+1}} | A_{1j_1} \cap A_{2j_2} \cap \dots \cap A_{ij_i}) = P(A_{i+1, j_{i+1}} | A_{ij_i}), \quad (1.2)$$

so spricht man von einem Markovmodell mit den *Zuständen*  $a_1, \dots, a_k$ .

- Sind die sogenannten Übergangswahrscheinlichkeiten in (1.2) unabhängig von der Zeit, gilt also  $P(A_{i+1, j} | A_{il}) \equiv p_{jl}$  für alle  $i, j, l$ , so heißt das Markovmodell *homogen*.



## Typische Anwendungen:

- Glücksspiel: Die Wahrscheinlichkeit  $P(A_{i+1,j})$  mit  $A_{i+1,j} =$  „Spieler hat zum Zeitpunkt  $i + 1$  Kapitalbestand  $a_j$ “ hängt nur vom Kapitalbestand zum Zeitpunkt  $i$  ab, also nur von  $A_{i1}, \dots, A_{ik}$ , nicht aber von früheren Ereignissen.
- BWL: Konsumententscheidungen / Produktwahl
- Demographie: Geburts- und Todesprozesse
- Epidemiologie
- Bildet das Wetter mit  $\Omega = \{\text{Sonniger Tag, bewölkter Tag, regnerischer Tag, verschneiter Tag}\}$  eine Markovkette?
- Soziologie: z.B. Modelle sozialer Mobilität, Mobilität in Betrieben
  - Rapoport (1980): Mathematische Methoden in der Sozialwissenschaft, Physika
  - Bartholomew (1982): Stochastic Models for Social Processes, Wiley

**Bsp. 1.35. [Soziale Mobilität (nach Bartholomew (1982), S. 18f.)]**

Wie entwickelt sich der soziale Status durch die Generationen?

- Markoveigenschaft bedeutet hier:
- Homogenität bedeutet hier:

Datengrundlage: männliche Generationenfolge in Marion County, Indiana (1905 – 1912)

Väter	Söhne	$a_1$	$a_2$	$a_3$
	nicht handwerkliche Tätigkeit $\approx$ Dienstleistung	$a_1$	0.594	0.396
handwerkliche Tätigkeit $\approx$ verarb. Gewerbe	$a_2$	0.211	0.782	0.007
landwirtschaftliche Tätigkeit $\approx$ Land- u. Forstwirtschaft	$a_3$	0.252	0.641	0.108

- Die obige Matrix enthält die (geschätzten) Übergangswahrscheinlichkeiten

$$i\text{-te Zeile, } j\text{-te Spalte: } P(A_{2j}|A_{1i})$$

Wahrscheinlichkeit, dass die **zweite** Generation in Zustand **j** ist unter der Bedingung, dass die **erste** Generation im Zustand **i** ist.

Beispiel: Sohn „nicht handwerklich“ unter der Bedingung Vater „landwirtschaftlich“

$$P(A_{21}|A_{13}) = 0.252$$

- Man sieht: für feste  $A_{1l}$  ist  $P(A_{2j}|A_{1l})$  als Funktion in  $A_{2j}$  eine Wahrscheinlichkeitsverteilung, d.h. die jeweiligen Zeileneinträge summieren sich (bis auf Rundungsfehler) zu 1.
- Inhaltliche Interpretation:
  - Unter der Annahme, dass eine homogene Markov-Kette vorliegt, kann man mit den Daten weitere Entwicklungen prognostizieren.
  - Mit Hilfe der Übergangsmatrix allein kann man Fragen der Art beantworten: Wie groß ist die Wahrscheinlichkeit, dass der Enkel eines in der Landwirtschaft Tätigen eine Tätigkeit im nicht handwerklichen Sektor ausüben wird?
  - Beachte bisher ist nichts über die (unbedingte) Verteilung auf die einzelnen Sektoren

ausgesagt. Kennt man zusätzlich die Startverteilung  $P(A_{11}), P(A_{12}), P(A_{13})$ , so kann man die weitere Verteilung auf die Sektoren berechnen.

- Man kann auch (mit weiterführenden Methoden) eine Gleichgewichtsverteilung bestimmen.
- **Kritische Aspekte:**

### 1.3.5 Das Theorem von Bayes

Bei der Anwendung bedingter Wahrscheinlichkeiten ist es häufig von Interesse, „Bedingung und Ereignis“ zu vertauschen.

Also: gegeben  $P(B|A)$ , gesucht  $P(A|B)$

#### Bsp. 1.36. [Diagnoseproblem]

- Bei der Durchführung eines Tests auf eine bestimmte Krankheit ist zu unterscheiden:
  - Patient ist krank  $\longrightarrow$  Ereignis  $A$
  - Testergebnis ist positiv, d.h. der Test sagt, die Person sei krank  $\longrightarrow$  Ereignis  $B$

In der Praxis sind  $A$  und  $B$  nie identisch!

Ziel bei der Konstruktion eines Tests: möglichst geringe Fehlerwahrscheinlichkeiten

$P(B|A) = 0.98$     *Sensitivität:*    Kranker wird als krank eingestuft

$P(\bar{B}|\bar{A}) = 0.97$     *Spezifität:*    Gesunder wird als gesund erkannt

Häufiges Problem in der Praxis: Steigerung der Sensitivität geht auf Kosten der Spezifität und umgekehrt.

- Jetzt konkrete Beobachtung bei einem Patienten: Testergebnis 'krank'. Mit welcher Wahrscheinlichkeit ist die Person tatsächlich krank?

Allgemeiner nicht nur bei Dichotomie  $A$  und  $\bar{A}$ , sondern bei beliebiger vollständiger Zerlegung  $A_1, \dots, A_k$  (vgl.1.21) anwendbar:

**Theorem 1.37. [Theorem von Bayes]**

Sei  $A_1, \dots, A_k$  eine vollständige Zerlegung von  $\Omega$  (wobei  $P(A_i) > 0$ ,  $P(B|A_i) > 0$ ,  $i = 1, \dots, k$  und  $P(B) > 0$  erfüllt seien.) Dann gilt

$$P(A_j|B) = \frac{P(B|A_j) \cdot P(A_j)}{\sum_{i=1}^k P(B|A_i) \cdot P(A_i)}.$$

**Fortsetzung von Bsp. 1.36**

Gegeben seien

$$P(B|A) = 0.98 \quad (\text{Sensitivität})$$

$$P(\bar{B}|\bar{A}) = 0.97 \quad (\text{Spezifität})$$

$$P(A) = 0.001 \quad (\text{Prävalenz})$$



**Bem. 1.38. [Inhaltliche Bemerkungen zu Bsp. 1.36]**

- Problematik: Flächendeckendes Screening nicht unumstritten, da viele falsch-positive Ergebnisse. Gegenposition: Anwendung nur auf Risikopatienten.
- Bei Mammographie oder PSA-Test auf Prostatakrebs teilweise sogar noch viel geringere Spezifität.
- Wert der mathematischen Theorie: Wenn es etwas komplexer wird, verlässt einen sofort der „gesunde Menschenverstand“. Untersuchungen (u.a. von Gigerenzer) haben gezeigt, dass viele Ärzte sich dieser Problematik nicht bewusst sind.

**Bem. 1.39. [Bemerkungen zu Theorem 1.37 (Theorem von Bayes)]**

- Übliche Bezeichnungen:

$P(A_i)$ : „a priori Wahrscheinlichkeiten“ (Wahrscheinlichkeit *vor* der Beobachtung des Testergebnisses)

$P(A_i|B)$ : „a posteriori Wahrscheinlichkeiten“ (Wahrscheinlichkeit *nach* der Beobachtung des Testergebnisses)

- Im Prinzip liefert das Theorem von Bayes ein Schema für das probabilistische Lernen aus Beobachtungen („Aufdatieren von Wahrscheinlichkeiten“).

$$\left. \begin{array}{l} \text{priori} \\ + \text{ Daten} \end{array} \right\} \longrightarrow \text{posteriori}$$

Es dient als Grundlage der sog. *Bayesianischen Inferenz*, einer bestimmten Schule der statistischen Methodologie, die hier nicht behandelt wird. Dabei geht es darum, aus Daten zu lernen, indem man die subjektiven Wahrscheinlichkeiten  $P(A_i)$  für bestimmte Modellparameter mit Hilfe der Daten ( $B$ ) aufdatiert, und somit zur besseren Wahrscheinlichkeitsaussagen für die Modellparameter kommt.

- Hier Formulierung im medizinischen Kontext. Anwendung auch zur Beurteilung der Rückfallgefahr, Kreditwürdigkeitsprüfung, etc.