

1.3 Stochastische Unabhängigkeit und bedingte Wahrscheinlichkeiten

Ziel: komplexere Modelle aus Verkettung („Koppelung“) von Zufallsexperimenten bauen, insbesondere Ziehung von n -Personen aus n -maliger Ziehung einer Person

⇒ erster Schritt: Modellieren von zwei sich nicht gegenseitig beeinflussenden Experimenten („unabhängige Experimente“).

Vorbereitend: Unabhängigkeit von Ereignissen

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“ (vgl. die Überlegungen zu Korrelation und Kausalität in Statistik I).
- 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 (2×2) –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. [verfälschte Würfel, vgl. Bsp. 1.15]

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 $P(\{1\}) = \frac{1}{9}$, $P(\{2\}) = \frac{1}{9}$, $P(\{3\}) = \frac{1}{18}$, $P(\{4\}) = \frac{5}{18}$, $P(\{5\}) = \frac{2}{9}$, $P(\{6\}) = \frac{2}{9}$,

so sind hier A und C stochastisch **un**abhängig (selbes Ω , 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 Wahrscheinlichkeit:

- 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: Bedingen als Einschränkung der Betrachtung, hier auf alle Situationen, bei denen B eingetreten ist

Einmaliges Würfeln mit fairem Würfel

- zur ersten Annäherung betrachtet man einen fairen Würfel, sodass man mit dem Laplaceschen Wahrscheinlichkeitsbegriff arbeiten kann
- 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?

Formalisierung: Über Laplaceschen Wahrscheinlichkeitsbegriff hinaus

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 .

In der Praxis ist meist folgende Informationsinterpretation statthaft: $P(A|B)$ ist die Wahrscheinlichkeit von A wenn feststeht, 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 (2×2) –Tafel betrachtet.

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

	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 das Eintreten von 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 meist viel anschaulicher.

- Interpretation von „unter der Bedingung B “:

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

In der Tat ist

$$P_B(A) := P(A|B) = P(A \cap B|B) \quad (1.4)$$

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: Unabhängige 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

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

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

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 Ω_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 Ω , bei dem – per Konstruktion – beliebige Ereignisse aus den einzelnen Ω_i voneinander unabhängig sind.

Man beachte, dass durch die Setzung

$$P\left(\bigcap_{i=1}^n A_i\right) := P\left(\bigotimes_{i=1}^n A_i\right) = \prod_{i=1}^n P(A_i), \text{ für alle } A_1, \dots, A_n$$

, gemeinsame Unabhängigkeit erzeugt wird: Für $\emptyset \neq I \subseteq \{1, \dots, n\}$ gilt dann:

$$P\left(\bigcap_{i \in I} A_i\right) = P\left(\bigotimes_{i \in I} A_i \times \bigotimes_{i \notin I} \Omega_i\right) = \prod_{i \in I} P(A_i) \cdot \prod_{i \notin I} \underbrace{P(\Omega_i)}_1 = \prod_{i \in I} P(A_i)$$

Von besonderer Bedeutung ist der Fall *unabhängiger und identischer Wiederholungen*, bei dem dasselbe Experiment wiederholt durchgeführt wird, also sich die Ergebnisräume und die Wahrscheinlichkeitsmaße P_i nicht unterscheiden

Zufallsstichprobe vom Umfang n : (Veranschaulichung durch „Wahlbeispiel“) Das Experiment „Ziehen einer Person und Ermittlung ihrer Parteipräferenz“ wird n -mal unabhängig (Befragte dürfen sich nicht gegenseitig beeinflussen! ¹) durchgeführt.

Allgemeiner: Betrachte eine endliche Grundgesamtheit $\mathcal{G} = \{g_1, g_2, \dots, g_N\}$, sowie ein Merkmal 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 X* entnommen, d.h. eine (geordnete) Zufallsauswahl (mit Zurücklegen) von n Elementen

$$s_1, \dots, s_n \text{ mit } s_i \in \mathcal{G}, i=1, \dots, n$$

und die diesbezüglichen Ausprägungen $X(s_i)$ von X erhoben.

¹Praktisch wird dabei auch angenommen, dass die Grundgesamtheit so groß ist, dass zwischen Ziehen mit Zurücklegen und Ziehen ohne Zurücklegen kein Unterschied besteht.

Sei für $j = 1, \dots, k$, $i = 1, \dots, n$ mit A_{ij} das Ereignis „ $X(s_i) = a_j$ “ 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. Illustrieren und formalisieren Sie die Fragestellung im eben dargestellten Rahmen und bestimmen Sie 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 aufgebaut. 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, Kap. 4.6]

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“

Siegchancen sind abhängig vom jeweiligen Gegner! \implies bedingte Wahrscheinlichkeiten.

A_1	Gegner ist Mannschaft	1
A_2	”	2
A_3	”	3

Bedingte Wahrscheinlichkeiten leicht(er) anzugeben:

$$\begin{aligned}P(B|A_1) &= 0.7 \\P(B|A_2) &= 0.65 \\P(B|A_3) &= 0.2\end{aligned}$$

Technisch entscheidend:

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

Es ergibt sich also

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

Merke:

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 Ω (vgl. Bem. 1.21). Dann gilt für jedes Ereignis B

$$P(B) = \sum_{j=1}^k P(B|A_j) \cdot P(A_j) = \sum_{j=1}^k P(B \cap A_j). \quad (1.5)$$

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).

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. (1.4)). Wende den Satz der totalen Wahrscheinlichkeit auf diese Wahrscheinlichkeit an.

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. $i=1, \dots, n$ ist oft als Zeitpunkt interpretierbar.

$$P(\underbrace{A_{12} \cap A_{25} \cap A_{31}}_C \cap \underbrace{A_{42}}_B)$$

(Wahl- oder Produktentscheidung)

Im Zeitpunkt 1	Produkt 2
Im Zeitpunkt 2	Produkt 5
Im Zeitpunkt 3	Produkt 1
Im Zeitpunkt 4	Produkt 2

Von hinten nach vorne: mit Formel $P(C \cap B) = P(B \cap C) = P(B|C) \cdot P(C)$:

$$P(\underbrace{A_{42}}_B | \underbrace{A_{31} \cap A_{25} \cap A_{12}}_C) \cdot P(\underbrace{A_{31} \cap A_{25} \cap A_{12}}_C) =$$

Satz wieder anwenden auf $P(\underbrace{A_{31}}_{B_{\text{neu}}} \cap \underbrace{A_{25} \cap A_{12}}_{C_{\text{neu}}})$:

$$P(A_{42} | A_{31} \cap A_{25} \cap A_{12}) \cdot P(A_{31} | A_{25} \cap A_{12}) \cdot P(A_{25} \cap A_{12}) =$$

$$P(A_{42} | A_{31} \cap A_{25} \cap A_{12}) \cdot P(A_{31} | A_{25} \cap A_{12}) \cdot P(A_{25} | A_{12}) \cdot P(A_{12})$$

Anwendungsbeispiele:

- Komplexere Urnenmodelle ohne Zurücklegen, Wahrscheinlichkeit im n -ten Zug ist davon abhängig, welche Kugeln vorher gezogen wurden.
- Sicherheitsstudie zu komplexen Anlagen: Wahrscheinlichkeit für komplexe Pfade praktisch nicht angebar, aber eben bedingte Einzelwahrscheinlichkeiten (eventuell schon).
- Mehrstufige Auswahl (z.B. Gemeinden \rightarrow Schulen \rightarrow Klassen \rightarrow Schüler(innen))
- $i=1 \dots$ oft auch als Zeit interpretiert
- * Betrachte die Entwicklung der Beschäftigungsart einer z.B. männlichen Generationenfolge A_{ij} , i -te Generation ist in Sektor j beschäftigt
- * ähnlich soziale Mobilität: Sozialstatus über die Generationen
- * Markovmodelle (dynamische Modelle mit „einfacher Bedingung“)

Markovmodelle: Hier interpretiert man den Laufindex praktisch ausnahmslos 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

$$P(A_{i+1,j_{i+1}} | A_{1j_1} \cap A_{2j_2} \cap \dots \cap A_{ij_i}) = P(A_{i+1,j_{i+1}} | A_{ij_i}), \quad (1.6)$$

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

- Sind die sogenannten *Übergangswahrscheinlichkeiten* in (1.6) unabhängig von der Zeit, gilt also $P(A_{i+1,j} | A_{i\ell}) \equiv p_{j\ell}$ 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 der Sektorenmobilität, soziale Mobilität in Betrieben
 - Rapoport (1980): Mathematische Methoden in der Sozialwissenschaft, Physika
 - Bartholomew (1982): Stochastic Models for Social Processes, Wiley

Bsp. 1.35. [Sektorenmobilität (nach Bartholomew (1982, S. 18f.))]

Wie entwickelt sich die Art der Erwerbstätigkeit über 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	0.009
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.
- Für Nebenfachstudierende:
 - * Diese Rechnungen lassen sich sehr einfach durch Matrixmultiplikation bewerkstelligen. Für die Verteilung nach n Schritten gilt:
Startverteilung \cdot (Übergangsmatrix) ^{n}
 - * Man kann auch eine Gleichgewichtsverteilung bestimmen. Unter Regularitätsbedingungen kann der asymptotische Gleichgewichtszustand über den zum größten Eigenwert gehörenden Eigenvektor bestimmt werden

- **Kritische Aspekte:**

- + interessantes und sehr leistungsfähiges Modellierungsinstrument
aber nicht in Ehrfurcht vor Methode erstarren, sondern Annahme kritisch hinterfragen
- Markoveigenschaft nicht unproblematisch: zusätzliche Rolle der Großväter!
- Zeitliche Homogenität absolut problematisch (in der Tat gute 30 Jahre später hat sich die Wahrscheinlichkeit, in der Landwirtschaft zu bleiben, nochmals mehr als halbiert)

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 K
 - * Testergebnis ist positiv, d.h. der Test sagt, die Person sei krank \longrightarrow Ereignis T^+

In der Praxis sind K und T^+ nie für alle Personen identisch!

Ziel bei der Konstruktion eines Tests: möglichst geringe Fehlerwahrscheinlichkeiten

$P(T^+ K)$	<i>Sensitivität:</i>	Wsk, dass Kranker als krank eingestuft wird
$P(\bar{T}^+ \bar{K})$	<i>Spezifität:</i>	Wsk, dass Gesunder als gesund eingestuft wird
$P(K)$	<i>Prävalenz:</i>	Wsk, dass eine zufällig ausgewählte Person krank ist

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 K und \bar{K} , sondern bei beliebiger vollständiger Zerlegung K_1, \dots, K_k (vgl. Bem. 1.21) anwendbar:

Satz 1.37. [Theorem von Bayes]

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

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

Für beliebige Ereignisse A und B mit

$P(A) > 0$, $P(\bar{A}) > 0$, $P(B|A) > 0$, $P(B|\bar{A}) > 0$, $P(B) > 0$, $P(\bar{B}) > 0$ gilt also:

$$P(A|B) = \frac{P(B|A) \cdot P(A)}{P(B|A) \cdot P(A) + P(B|\bar{A}) \cdot P(\bar{A})} \quad (1.7)$$

Bsp. 1.38. [Fortsetzung von Bsp. 1.36]

Gegeben seien

$$P(T^+|K) = 0.98 \quad (\text{Sensitivität})$$

$$P(\bar{T}^+|\bar{K}) = 0.97 \quad (\text{Spezifität})$$

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

Bem. 1.39. [Inhaltliche Bemerkungen zu Bsp. 1.36 und Bsp. 1.38]

- Die in solchen natürlicherweise (!) entstehende Zahl von falsch positiven Testergebnissen bewirkt ein substantielles Dilemma, das sehr kontrovers diskutiert wird. Problematik: Flächendeckendes Screening nicht unumstritten, da viele falsch-positive Ergebnisse. Also (?): Anwendung nur auf Risikopatienten.
- z.B. bei Mammographie oder PSA-Test auf Prostatakrebs teilweise sogar noch viel geringere Spezifität → Effekte noch drastischer.
- Wert der mathematischen Theorie: Wenn es etwas komplexer wird, verlässt einen sofort der „gesunde Menschenverstand“. Untersuchungen (u.a. von Gigerenzer ¹) haben gezeigt, dass viele Ärzte sich der hier ermittelten Problematik nicht bewusst sind.

¹Gerd Gigerenzer: Das Einmaleins der Skepsis. Über den richtigen Umgang mit Zahlen und Risiken

Bem. 1.40. [Bemerkungen zu Satz 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)

Einschub:

Im Beispiel:

- 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.

Eine elementare Erläuterung findet sich etwa bei Henk Tijms¹, der den Verdacht einer manipulierten Ziehung der Halbfinalpartien in der Champions League 2013 bayesianisch als didaktisches Beispiel untersucht.

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

¹Henk Tijms: Teaching Note-Was the Champions League Draw Rigged? <http://personal.vu.nl/h.c.tijms/TeachingNoteBayes.pdf>, aufgerufen am 25.04.2015