



Sensordatenverarbeitung

# BAYES-FILTER (13B)

(ab 20.1.25)



- $Z$  besteht aus mehreren Messungen  $Z_i$  hintereinander.  $Z = \begin{pmatrix} Z_1 \\ \vdots \\ Z_n \end{pmatrix}$
- Mehrere Sensoren, und / oder mehrere Zeitpunkte
- Messung sind natürlich nicht unabhängig, weil die Wahrheit sie ja gemeinsam beeinflusst.
- Aber sie sind unabhängig gegeben die Wahrheit.
  - d.h. die Messfehler sind unabhängig
  - pragmatische Annahme, stimmt nur bedingt
  - Kausalität von  $X \rightarrow Z_i$  geht unabhängig für alle  $i$
  - größter Vorteil,  $P(Z=z|X=x)$  auszurechnen

$$P(Z = z|X = x) = \prod_{i=1}^n P(Z_i = z_i|X = x)$$

$$P(X = x | Z = z) \propto \prod_{i=1}^n P(Z_i = z_i | X = x) P(X = x)$$

Die Wahrscheinlichkeit, dass die Wahrheit x ist,  
gegeben, dass wir gemessen haben,  
was wir gemessen haben,  
ist proportional zum Produkt  
der Wahrscheinlichkeiten im i-ten Sensor  
das zu messen, was wir gemessen haben,  
wenn die Wahrheit x wäre,  
mal der Wahrscheinlichkeit,  
dass die Wahrheit (a-priori) x ist.

$$\begin{aligned}\hat{x} &= \arg \max P(X = x | Z = z) \\ &= \arg \max_x \prod_{i=1}^n P(Z_i = z_i | X = x) P(X = x)\end{aligned}$$

- Sensordatenverarbeitung (Sensorfusion) als Optimierungsproblem
- Benötigt Modelle für
  - a-priori Verteilung (oft uniform)
  - Wie wahrscheinlich ist es  $Z_i = z_i$  zu messen, wenn die Wahrheit  $x$  wäre?
  - meist Formel, was gemessen werden soll + Verteilung für den Messfehler + konkrete Zahl für Genauigkeit
- Verwirklicht probabilistischen Ansatz aus VL SdV-Paradigma
  - wenn Optimierung über alle Sensoren und Messungen durchgeführt wird

# Beispiel Bayes-Schätzung

- Bei einem Glückspiel würfeln wir im Becher verdecken und sollen tippen, ob es eine 6 wird.
- Wir haben einen hochgradig illegalen Sensor unter dem Tisch mit nebenstehender Konfusionsmatrix:
- Der Sensor hat einen Wurf 4 mal gemessen und zwar
  - positiv, negativ, positiv, positiv.
- Modelliere nach der Bayes-Methode und berechne die Bayes Schätzung!

$$\hat{x} = \arg \max_x \prod_{i=1}^n P(Z_i = z_i | X = x) P(X = x)$$



	sechs	n. sechs
Sensor positiv	2/3	1/3
Sensor negativ	1/3	2/3

- $X \in \{\text{sechs, n. sechs}\}$
- $Z = (Z_1, \dots, Z_n), n = 4, Z_i \in \{\text{pos, neg}\}$
- Maximierung über  $x$

- $x=\text{sechs}: \frac{2}{3} \cdot \frac{1}{3} \cdot \frac{2}{3} \cdot \frac{2}{3} \cdot \frac{1}{6} = \frac{8}{486}$
- $x=\text{n. sechs}: \frac{1}{3} \cdot \frac{2}{3} \cdot \frac{1}{3} \cdot \frac{1}{3} \cdot \frac{5}{6} = \frac{10}{486}$
- $\rightarrow x^{\wedge}=\text{n. sechs}$

	$x = \text{sechs}$	$x = \text{n. sechs}$
$P(X=x)$	1/6	5/6

$Z=(\text{positiv, negativ, positiv, positiv})$

$$\hat{x} = \arg \max_x \prod_{i=1}^n P(Z_i = z_i | X = x) P(X = x)$$

$P(Z=z   X=x)$	$x = \text{sechs}$	$x = \text{n. sechs}$
$z=\text{pos}$	2/3	1/3
$z=\text{neg}$	1/3	2/3



- Häufige Situation: Wahrheit ändert sich über die Zeit (Zustand)
  - Bsp. Position eines Fahrzeugs
- $X = (X_1, \dots, X_T)$ ,  $X_t$  ist Zustand zum Zeitpunkt  $t=1 \dots T$
- Messung  $Z_t$ 
  - hängt nur von Zustand  $X_t$  ab
  - Bsp. GPS, Thermometer
  - $P(Z_t = z_t | X_t = x_t, \dots) = P(Z_t = z_t | X_t = x_t)$
  - Markov-Annahme 1
- Meist zusätzlich Messung  $U_t$  bzgl. Zustandsübergang  $t-1 \rightarrow t$ 
  - hängt von Zustand  $X_t$  und vorherigem  $X_{t-1}$  ab
  - Bsp.: Raddrehsensoren, Inertialsensor
  - $P(U_t = u_t | X_t = x_t, X_{t-1} = x_{t-1}, \dots) = P(U_t = u_t | X_t = x_t, X_{t-1} = x_{t-1})$
  - Markov-Annahme 2
- $Z = (Z_1, U_1, Z_2, U_2, \dots, Z_T, U_T)$



- Äquivalent: Modell, wie sich der Zustand verändert
  - neuer Zustand hängt nur vom alten und Zustandsübergangsmessung ab
  - $P(X_t = x_t | X_{t-1} = x_{t-1}, U_t = u_t, \dots) = P(X_t = x_t | X_{t-1} = x_{t-1}, U_t = u_t,)$
  - geht auch ohne  $U_t$  ( $U_t = ()$ )
  - bsp. physikalische Gesetze
- Bayes-Filter schätzt inkrementell den aktuellen Zustand aus den vergangenen Messungen
  - $\hat{x}_t = \arg \max_x P(X_t = x | Z_{1..t} = z_{1..t}, U_{1..t} = u_{1..t})$
  - Der wahrscheinlichste *momentane* Zustand gegeben, dass wir gemessen haben, was wir *bisher* gemessen haben.
  - als mitlaufende Verarbeitung
  - jeden Zeitschritt Eingabe  $Z_t$  und  $U_t$  und Ausgabe  $\hat{x}_t$



- Indem es die Verteilung des aktuellen Zustandes einen Schritt "weiterrechnet"

$$P(X_t = x_t | Z_{1..t} = z_{1..t}, U_{1..t} = u_{1..t}) \\ \propto \sum_{x_{t-1}} P(X_t = x_t | X_{t-1} = x_{t-1}, U_t = u_t) \cdot \\ P(X_{t-1} = x_{t-1} | Z_{1..t-1} = z_{1..t-1}, U_{1..t-1} = u_{1..t-1})$$



$$P(X_t = x_t | Z_{1..t} = z_{1..t}, U_{1..t} = u_{1..t}) \\ \propto \sum_{x_{t-1}} P(X_t = x_t | X_{t-1} = x_{t-1}, U_t = u_t) \cdot \\ P(X_{t-1} = x_{t-1} | Z_{1..t-1} = z_{1..t-1}, U_{1..t-1} = u_{1..t-1})$$

Die Wahrscheinlichkeit eines momentanen Zustandes  $x_t$ , gegeben, was wir bisher gemessen haben, ist

- die Wahrscheinlichkeit für den alten Zustand gegeben die damaligen Messungen,
- mal der Wahrscheinlichkeit für den neuen Zustand gegeben den alten und die Zustandsübergangsmessung
- mal der Wahrscheinlichkeit für die neue Messung gegeben den neuen Zustand,
- und das für alle alten Zustände zusammengerechnet.



$$P(X_t = x_t | Z_{1..t} = z_{1..t}, U_{1..t} = u_{1..t}) \\ \propto \sum_{x_{t-1}} P(X_t = x_t | X_{t-1} = x_{t-1}, U_t = u_t) \cdot \\ P(X_{t-1} = x_{t-1} | Z_{1..t-1} = z_{1..t-1}, U_{1..t-1} = u_{1..t-1})$$

Die Wahrscheinlichkeit eines momentanen Zustandes  $x_t$ , gegeben, was wir bisher gemessen haben, ist

- die Wahrscheinlichkeit für den alten Zustand gegeben die damaligen Messungen,
- mal der Wahrscheinlichkeit für den neuen Zustand gegeben den alten und die Zustandsübergangsmessung
- mal der Wahrscheinlichkeit für die neue Messung gegeben den neuen Zustand,
- und das für alle alten Zustände zusammengerechnet.



$$P(X_t = x_t | Z_{1..t} = z_{1..t}, U_{1..t} = u_{1..t}) \\ \propto \sum_{x_{t-1}} P(X_t = x_t | X_{t-1} = x_{t-1}, U_t = u_t) \cdot \\ P(X_{t-1} = x_{t-1} | Z_{1..t-1} = z_{1..t-1}, U_{1..t-1} = u_{1..t-1})$$

Die Wahrscheinlichkeit eines momentanen Zustandes  $x_t$ , gegeben, was wir bisher gemessen haben, ist

- die Wahrscheinlichkeit für den alten Zustand gegeben die damaligen Messungen,
- mal der Wahrscheinlichkeit für den neuen Zustand gegeben den alten und die Zustandsübergangsmessung
- mal der Wahrscheinlichkeit für die neue Messung gegeben den neuen Zustand,
- und das für alle alten Zustände zusammengerechnet.



$$P(X_t = x_t | Z_{1..t} = z_{1..t}, U_{1..t} = u_{1..t}) \\ \propto \sum_{x_{t-1}} P(X_t = x_t | X_{t-1} = x_{t-1}, U_t = u_t) \cdot \\ P(Z_t = z_t | X_t = x_t) \cdot \\ P(X_{t-1} = x_{t-1} | Z_{1..t-1} = z_{1..t-1}, U_{1..t-1} = u_{1..t-1})$$

Die Wahrscheinlichkeit eines momentanen Zustandes  $x_t$ , gegeben, was wir bisher gemessen haben, ist

- die Wahrscheinlichkeit für den alten Zustand gegeben die damaligen Messungen,
- mal der Wahrscheinlichkeit für den neuen Zustand gegeben den alten und die Zustandsübergangsmessung
- mal der Wahrscheinlichkeit für die neue Messung gegeben den neuen Zustand,
- und das für alle alten Zustände zusammengerechnet.



$$P(X_t = x_t | Z_{1..t} = z_{1..t}, U_{1..t} = u_{1..t}) \\ \propto \sum_{x_{t-1}} P(X_t = x_t | X_{t-1} = x_{t-1}, U_t = u_t) \cdot \\ P(X_{t-1} = x_{t-1} | Z_{1..t-1} = z_{1..t-1}, U_{1..t-1} = u_{1..t-1})$$

Die Wahrscheinlichkeit eines momentanen Zustandes  $x_t$ , gegeben, was wir bisher gemessen haben, ist

- die Wahrscheinlichkeit für den alten Zustand gegeben die damaligen Messungen,
- mal der Wahrscheinlichkeit für den neuen Zustand gegeben den alten und die Zustandsübergangsmessung
- mal der Wahrscheinlichkeit für die neue Messung gegeben den neuen Zustand,
- und das für alle alten Zustände zusammengerechnet.



- Letztliche, alle Messungen miteinander malgenommen, wie beim Bayes-Schätzer, aber
  - das Schritt für Schritt gemacht
  - jeweils die alten Zustände aufsummiert

$$P(X_t = x_t | Z_{1..t} = z_{1..t}, U_{1..t} = u_{1..t}) \\ \propto \sum_{x_{t-1}} P(Z_t = z_t | X_t = x_t) \cdot \\ P(X_t = x_t | X_{t-1} = x_{t-1}, U_t = u_t) \cdot \\ P(X_{t-1} = x_{t-1} | Z_{1..t-1} = z_{1..t-1}, U_{1..t-1} = u_{1..t-1})$$



# Beispiel Bayes-Filter

- Bei einem Glückspiel würfeln wir im Becher verdecken und sollen tippen, ob es eine 6 wird.
- Wir haben einen hochgradig illegalen Sensor unter dem Tisch mit nebenstehender Konfusionsmatrix:
- Der Sensor hat einen Wurf 4 mal gemessen und zwar
  - positiv, negativ, positiv, positiv.
- Modelliere als Bayes-Filter und berechne die Schätzungen!

$$P(X_t = x_t | Z_{1..t} = z_{1..t}, U_{1..t} = u_{1..t}) \\ \propto \sum_{x_{t-1}} P(X_t = x_t | X_{t-1} = x_{t-1}, U_t = u_t) \cdot \\ P(Z_t = z_t | X_t = x_t) \cdot \\ P(X_{t-1} = x_{t-1} | Z_{1..t-1} = z_{1..t-1}, U_{1..t-1} = u_{1..t-1})$$



	sechs	n. sechs
Sensor positiv	2/3	1/3
Sensor negativ	1/3	2/3



# Bayes-Beispiel

- $X \in \{\text{sechs, n. sechs}\}$
- $T = 4, Z_t \in \{\text{pos, neg}\}$
- $U_t = ()$

$P(X_t = x_t   X_{1..t-1} = x_{1..t-1})$	sechs	n. sechs
sechs	1	0
n. sechs	0	1

$Z = (\text{positiv, negativ, positiv, positiv})$

$$\begin{aligned}
 & P(X_t = x_t | Z_{1..t} = z_{1..t}, U_{1..t} = u_{1..t}) \\
 & \quad P(Z_t = z_t | X_t = x_t) \cdot \\
 & = \sum_{x_{t-1}} P(X_t = x_t | X_{t-1} = x_{t-1}, U_t = u_t) \cdot \\
 & \quad P(X_{t-1} = x_{t-1} | Z_{1..t-1} = z_{1..t-1}, U_{1..t-1} = u_{1..t-1})
 \end{aligned}$$

$P(Z_t = z_t   X_t = x_t)$	sechs	n. sechs
Sensor positiv	2/3	1/3
Sensor negativ	1/3	2/3



$P(X_0 = x_0)$	Terme		$P(X_1 = x_1)$	Terme		$P(X_t = x_t   X_{t-1} = x_{t-1})$	sechs	n. sechs
1/6	2/18	0	2/18	2/54	0	sechs	1	0
5/6	0	5/18	5/18	0	10/54	n. sechs	0	1

$P(X_2 = x_2)$	Terme		$P(X_3 = x_3)$	Terme		$P(X_4 = x_4)$
2/54	4/162	0	4/162	8/486	0	8/486
10/54	0	10/162	10/162	0	10/486	10/486

$Z = (\text{positiv}, \text{negativ}, \text{positiv}, \text{positiv})$

$$\begin{aligned}
 & P(X_t = x_t | Z_{1..t} = z_{1..t}, U_{1..t} = u_{1..t}) \\
 & \quad P(Z_t = z_t | X_t = x_t) \cdot \\
 & = \sum_{x_{t-1}} P(X_t = x_t | X_{t-1} = x_{t-1}, U_t = u_t) \cdot \\
 & \quad P(X_{t-1} = x_{t-1} | Z_{1..t-1} = z_{1..t-1}, U_{1..t-1} = u_{1..t-1})
 \end{aligned}$$

	sechs	n. sechs
Sensor positiv	2/3	1/3
Sensor negativ	1/3	2/3



$$\hat{x} = \arg \max_x \prod_{i=1}^n P(Z_i = z_i | X = x) P(X = x)$$

$$\begin{aligned}\hat{x}_t &= \arg \max_x P(X_t = x | Z_{1..t} = z_{1..t}, U_{1..t} = u_{1..t}) \\ P(X_t &= x_t | Z_{1..t} = z_{1..t}, U_{1..t} = u_{1..t}) \\ &\quad P(Z_t = z_t | X_t = x_t) \cdot \\ &= \sum_{x_{t-1}} P(X_t = x_t | X_{t-1} = x_{t-1}, U_t = u_t) \cdot \\ &\quad P(X_{t-1} = x_{t-1} | Z_{1..t-1} = z_{1..t-1}, U_{1..t-1} = u_{1..t-1})\end{aligned}$$

- Benötigt Modelle für
  - a-priori Verteilung (oft uniform)
  - Modell für  $Z_i$  bzw.  $Z_t$
  - meist Formel, was gemessen werden soll + Verteilung für den Messfehler + konkrete Zahl für Genauigkeit
  - ggf. Modell für die Zustandsübergangsmessung  $U_t$

