



# Grundlagen der Künstlichen Intelligenz

## Wintersemester 25/26

### Vorlesung 12

Variablen-basierte Modelle, Bayes'sche Netze,  
Hidden-Markov-Modelle

26. Januar 2026

T.T.-Prof. Dr. Peer Nowack  
Prof. Dr. Pascal Friederich

# Wir werden immer mal wieder Umfragen machen...

Sie können sich bereits einloggen. Nutzen Sie das KIT Wi-Fi bei schlechtem Empfang.



1

Go to [wooclap.com](https://wooclap.com)

2

Enter the event code in the top banner

Event code

**HIPFAX**


# Zustandsbasierte vs. variablenbasierte Modelle

- In zustandsbasierten Modellen sind Lösungen Aktionen (**actions**): schrittweise Anweisungen, die in einer Reihenfolge nacheinander ausgeführt werden.
- In vielen Anwendungen gibt es jedoch **keine Aktionen** und **die Reihenfolge ist nicht wichtig**.

5	3			7					
6			1	9	5				
	9	8					6		
8				6				3	
4			8		3			1	
7				2				6	
	6					2	8		
			4	1	9			5	
				8				7	9

Sudoku

5	3	4	6	7	8	9	1	2
6	7	2	1	9	5	3	4	8
1	9	8	3	4	2	5	6	7
8	5	9	7	6	1	4	2	3
4	2	6	8	5	3	7	9	1
7	1	3	9	2	4	8	5	6
9	6	1	5	3	7	2	8	4
2	8	7	4	1	9	6	3	5
3	4	5	2	8	6	1	7	9



Zustandsschätzung

- Könnte man als Suchproblem formulieren (in dem die Reihenfolge wichtig ist), aber das wäre ineffizient, weil die Reihenfolge eben keine Rolle spielt...wollen für diesen Fall alternative Algorithmen kennenlernen!

# Variablenbasierte Modelle

Probleme mit (harten) Randbedingungen:  
(nicht in dieser Vorlesung)

- z. B. Sudoku, Stundenplan
- Modell: Constraint Satisfaction Problems


5	3		7						
6			1	9	5				
	9	8					6		
8			6					3	
4		8		3				1	
7			2					6	
	6				2	8			
			4	1	9			5	
			8			7	9		

→

5	3	4	6	7	8	9	1	2	
6	7	2	1	9	5	3	4	8	
1	9	8	3	4	2	5	6	7	
8	5	9	7	6	1	4	2	3	
4	2	6	8	5	3	7	9	1	
7	1	3	9	2	4	8	5	6	
9	6	1	5	3	7	2	8	4	
2	8	7	4	1	9	6	3	5	
3	4	5	2	8	6	1	7	9	

Probleme mit probabilistischen (weichen) Abhängigkeiten:

- Z.B. Sensordaten → Position von Autos
- Modell: Bayes'sche Netze



Modellierung  
Schlussfolgerung Lernen



# KI-Landkarte

## Künstliche Intelligenz

### Modellierung und Schlussfolgerung

Variablen **VL12** Inferenz

Logik **VL11** Wissensrepräsentation

Zustände **VL13** MDPs  
Suche

Reflex **VL11**

### Anwendungen

Robotik **VL14**

Computer Vision **VL9**

Natürliche Sprache **VL10**

### Lernen

Optimierung und Generalisierung **VL6**

Vorhersage **VL4** **VL5** Neuronale Netze

Modellierung **VL3** Unsupervised **VL7**  
Supervised **VL8**

### Historie und Philosophie

**VL1** Geschichte

Personen

KI und Gesellschaft

Kritische Aspekte

### Mathematik

**VL2**

Lineare Algebra

Statistik

Logik

Numerik

Analysis

# Lernziele der heutigen Vorlesung

Nach dieser Vorlesung werden Sie in der Lage sein:

- Grundideen der **probabilistischen Inferenz** zu erklären.
- **Bayes'sche Netze** in ihrer mathematischen Idee und als grafische Modelle zu formulieren und einfache Berechnungen anzustellen, sowie den **Explaining-Away Effekt** zu bewerten.
- **Probabilistische Programme** zu entwerfen und einige Anwendungsbeispiele zusammenzufassen.
- Das Konzept von **Markov Modellen** zu erklären, sowie darauf aufbauend zentrale Ideen der **Hidden Markov Modelle** in Beziehung zu setzen, um den **Forward-Backward Algorithmus** zu formulieren, inklusive **Filterung** und **Glättung**.

*Kapitel 12, 13, 14 in Norvig & Russell, 4. Edition*

# Agenda

## **Bayessche Netze** (Bayesian networks)

- Definition
- Explaining Away
- Inferenz


## **Probabilistische Programme**

### **Hidden Markov Modelle**

- Zustandsabschätzung und Filtern (state estimation and filtering)
- Vorwärts Algorithmus (forward algorithm): Filtern
- Vorwärts Rückwärts Algorithmus (forward backward algorithm): Glättung (smoothing)

# Warum brauchen wir Bayes'sche Netze?

- Grundlegendes Framework für **probabilistisches Schlussfolgern/probabilistic reasoning**.
- Umgang mit **heterogenen** Informationslücken.
- Einbeziehung von **Vorwissen** (z. B. physikalische Gesetze)
- Kann die Variablen aller Zwischenschritte **interpretieren**



# Recap: probabilistische Inferenz

**Inferenz:** Schlussfolgerungen aus vorhandenen Informationen ziehen; Evidenz dazu nutzen etwas zu erklären das wir nicht direkt sehen oder sicher wissen können.

Beispiele:

- Nasser Bürgersteig → es hat wahrscheinlich geregnet
- Handybatterie fällt schnell ab → eine App könnte verantwortlich sein

Normalerweise: von Unsicherheiten behaftet → **probabilistisch**

- Es hat wahrscheinlich geregnet.
- Es könnte die eine oder die andere App sein.

# Recap: probabilistische Inferenz

**Zufallsvariablen:**  $S$  (Sonnenschein),  $R$  (Regen),  $T$  (Verkehr),  $A$  (Herbst)

**Gemeinsame Verteilung (probabilistische Datenbasis):**  $p(S, R, T, A)$

Probabilistische Inferenz ist die Beantwortung von Fragen anhand dieser Daten:

- **Kondition/Bedingung** für die Evidenz (Verkehr, Herbst):  $T = 1, A = 1$
- Interessiert an **Query** (Regen?):  $R$
- Einige Variablen ( $S$ ) sind nicht von Interesse – **marginalisieren**

$$p(R|T = 1, A = 1) = \sum_S p(\underbrace{R}_{\text{query}}, \underbrace{S}_{\text{marginalize out}} \mid \underbrace{T = 1, A = 1}_{\text{condition}})$$

- Die Menge der **Konditionierungs-Variablen**, der **Query-Variablen** und der **marginalisierten Variablen**, bilden eine **Partitionierung** aller Variablen.

# Recap: Satz von Bayes

**Der Satz von Bayes** ist eine der wichtigsten Gleichungen in der Wahrscheinlichkeitsrechnung und im maschinellen Lernen

$$\underset{\text{Posterior}}{p(z|y)} = \frac{\overset{\text{Likelihood}}{p(y|z)} \overset{\text{Prior}}{p(z)}}{\underset{\text{Evidence}}{p(y)}} = \frac{p(y|z)p(z)}{\sum_{z'} p(y|z')p(z')}$$



- "Umkehrung" der bedingten Wahrscheinlichkeiten
- Oft ist eine Bedingung kompliziert, die andere aber einfach zu erhalten

# Recap: Satz von Bayes

Der Satz von Bayes mit „Hintergrundinformationen  $x$ “



$$p(z|y, x) \underset{\text{Posterior}}{=} \frac{\overset{\text{Likelihood}}{p(y|z, x)} \overset{\text{Prior}}{p(z|x)}}{\underset{\text{Evidence}}{p(y|x)}} = \frac{p(y|z, x)p(z|x)}{\sum_{z'} p(y|z', x)p(z'|x)}$$

- Alle Verteilungen sind jetzt auch von  $x$  abhängig

# Bayes'sche Netze (BN): Definition


- Gegeben Zufallsvariablen  $X = (X_1, \dots, X_n)$
- Ein BN ist ein Directed Acyclic Graph (DAG), der eine gemeinsame Verteilung über  $X$  als **Produkt lokaler bedingter Verteilungen** spezifiziert (eine pro Knoten):

$$p(x_1, \dots, x_n) = \prod_{i=1}^n p(x_i | x_{\text{parents}(i)})$$

$$p(A, B, E) = p(B) p(E) p(A|B, E)$$

Häufig als **grafisches Modell** dargestellt:

- Beispiel: 3 Zufallsvariablen (B, A, E)
- **Eltern** werden durch gerichtete Kanten angezeigt
- **Beobachtete Variablen** werden oft in grau dargestellt



Grafische Modelle können zum Ablesen von Unabhängigkeitsannahmen und Faktorisierungen verwendet werden, die die Berechnungen vereinfachen.

# Ein kleines Rätsel...



## Problemstellung: Erdbeben ( $E$ ), Einbrüche ( $B$ ) und Alarme ( $A$ )

- **Erdbeben** und **Einbrüche** sind unabhängige Ereignisse (Wahrscheinlichkeit  $\epsilon$ ).
- In beiden Fällen wird ein **Alarm** ausgelöst.
- Angenommen, wir erhalten einen **Alarm**.
- Erhöht oder verringert sich die Wahrscheinlichkeit eines Einbruchs, wenn man hört, dass es ein Erdbeben gibt, oder bleibt sie gleich?

**Gemeinsame Verteilung:**  $p(E, B, A) = p(E)p(B)p(A|B, E)$

**Fragen:**

$$p(B = 1|A = 1) \quad ? \quad p(B = 1|A = 1, E = 1)$$



# Bayes'sches Netz

- Alarm wird ausgelöst, wenn entweder ein Erdbeben oder Einbruch, oder beides eintritt

$$p(E = e) = \epsilon^e (1 - \epsilon)^{1-e}$$


$$p(B = b) = \epsilon^b (1 - \epsilon)^{1-b}$$

$$p(A = a | e, b) = [a = (b \vee e)]$$

- Gemeinsame Verteilung

$$p(E, B, A) = p(E)p(B)p(A|B, E)$$

Wahrscheinlichkeit Einbruch



Wahrscheinlichkeit Erdbeben

$b$	$p(b)$
1	$\epsilon$
0	$1 - \epsilon$

$e$	$p(e)$
1	$\epsilon$
0	$1 - \epsilon$

Joint distribution

$b$	$e$	$a$	$\mathbb{P}(B = b, E = e, A = a)$
0	0	0	$(1 - \epsilon)^2$
0	0	1	0
0	1	0	0
0	1	1	$(1 - \epsilon)\epsilon$
1	0	0	0
1	0	1	$\epsilon(1 - \epsilon)$
1	1	0	0
1	1	1	$\epsilon^2$

$b$	$e$	$a$	$p(a   b, e)$
0	0	0	1
0	0	1	0
0	1	0	0
0	1	1	1
1	0	0	0
1	0	1	1
1	1	0	0
1	1	1	1

Bedingte  $p$  für Alarm

## Joint distribution

$b$	$e$	$a$	$\mathbb{P}(B = b, E = e, A = a)$
0	0	0	$(1 - \epsilon)^2$
0	0	1	0
0	1	0	0
0	1	1	$(1 - \epsilon)\epsilon$
1	0	0	0
1	0	1	$\epsilon(1 - \epsilon)$
1	1	0	0
1	1	1	$\epsilon^2$

## Query:

$$P(B = 1) = \epsilon(1 - \epsilon) + \epsilon^2 = \epsilon$$

$$P(B = 1|A = 1) = \frac{P(B = 1, A = 1)}{p(A = 1)} = \frac{\epsilon(1 - \epsilon) + \epsilon^2}{\epsilon(1 - \epsilon) + \epsilon^2 + (1 - \epsilon)\epsilon} = \frac{1}{2 - \epsilon}$$

$$P(B = 1|A = 1, E = 1) = \frac{P(B = 1, A = 1, E = 1)}{p(A = 1, E = 1)} = \frac{\epsilon^2}{\epsilon^2 + (1 - \epsilon)\epsilon} = \epsilon$$

You cannot vote anymore



Warum ist die Wahrscheinlichkeit von  $P(B = 1|A = 1)$  in den meisten Fällen größer als  $P(B = 1|A = 1, E = 1)$ ? (alle richtigen Antworten gemäß unserer Problemdefinition (!) auswählen)



1

Erdbeben senken die Wahrscheinlichkeit von Einbrüchen.

6%

5

2

Einbrüche werden weniger wahrscheinlich wenn Erdbeben stattfinden.

7%

6

3

Die Wahrscheinlichkeit für einen Einbruch können.

Click on the projected screen to start the question

65%

54 ✓

4

Die Wahrscheinlichkeit für einen Einbruch nach Beobachtung des Erdbebens ist wieder die Grundwahrscheinlichkeit bevor wir einen Alarm gehört hatten.

82%

68 ✓



wooclap



75%



89% correct

83 / 180



$$P(B = 1|A = 1) = \frac{1}{2 - \epsilon}$$

$$P(B = 1|A = 1, E = 1) = \epsilon$$

Erdbeben ( $E$ ), Einbrüche ( $B$ ) und Alarme ( $A$ )



## Joint distribution

$b$	$e$	$a$	$\mathbb{P}(B = b, E = e, A = a)$
0	0	0	$(1 - \epsilon)^2$
0	0	1	0
0	1	0	0
0	1	1	$(1 - \epsilon)\epsilon$
1	0	0	0
1	0	1	$\epsilon(1 - \epsilon)$
1	1	0	0
1	1	1	$\epsilon^2$

## Query:

$$P(B = 1) = \epsilon(1 - \epsilon) + \epsilon^2 = \epsilon$$


$$P(B = 1|A = 1) = \frac{P(B = 1, A = 1)}{p(A = 1)} = \frac{\epsilon(1 - \epsilon) + \epsilon^2}{\epsilon(1 - \epsilon) + \epsilon^2 + (1 - \epsilon)\epsilon} = \frac{1}{2 - \epsilon}$$

$$P(B = 1|A = 1, E = 1) = \frac{P(B = 1, A = 1, E = 1)}{p(A = 1, E = 1)} = \frac{\epsilon^2}{\epsilon^2 + (1 - \epsilon)\epsilon} = \epsilon$$

**Eilmeldung: Erdbeben verringern Einbrüche!\***

\*Diese Aussage geht von einer Kausalität aus, die **nicht** gegeben ist.

# Der Explaining-Away-Effekt



## Hauptprinzip:


Angenommen zwei Ursachen beeinflussen eine Wirkung  $A$  positiv. Konditioniert man zusätzlich zur Wirkung  $A$  auf eine der Ursachen, verringert dies die Wahrscheinlichkeit der anderen Ursache; hier:

$$p(B = 1 | A = 1, E = 1) < p(B = 1 | A = 1)$$

Dies geschieht auch, wenn beide Ursachen unabhängig voneinander sind!

# Ein anderes Beispiel: Erkältung oder Allergie?

Sie husten und haben juckende Augen. Haben Sie eine Erkältung?



C	$p(c)(C)$
0	0.9
1	0.1

A	$p(a)(A)$
0	0.8
1	0.2

C	A	H	$p(h c,a)(C,A,H)$
0	0	0	0.9
0	1	1	0.9
1	0	1	0.9
1	1	1	0.9
0	0	1	0.1
0	1	0	0.1
1	0	0	0.1
1	1	0	0.1

A	I	$p(i a)(A,I)$
0	0	0.9
1	1	0.9
0	1	0.1
1	0	0.1

## Zufallsvariablen

Erkältung  $C$ , Allergien  $A$ , Husten  $H$ ,  
juckende Augen  $I$

## Gemeinsame Verteilung

$$p(c, a, h, i) = p(c)p(a)p(h|c, a)p(i|a)$$

**Abfragen:**  $p(C = 1|H = 1) = 0.28 > P(C = 1|H = 1, I = 1) = 0.13$

Die Beobachtung "juckende Augen" unterstützt die Allergiehypothese, welche die Anzeichen für eine Erkältung ausräumt.

# Probabilistische Inferenz (formale Definition)

## Eingabe:

Bayes'sches Netzwerk:  $p(X_1, \dots, X_n)$

Evidenz:  $E = e$  wobei  $E \subseteq X$  ist Teilmenge von  $X$

Query:  $Q \subseteq X$

## Ausgabe:

Berechnung der Wahrscheinlichkeiten für Query  $Q$  bei Evidenz  $E = e$

$$p(Q = q | E = e) \text{ for all values } q$$


## Beispiel:

wenn Husten und juckende Augen, hat man dann eine Erkältung?

$$p(C | H = 1, I = 1)$$

## Inferenz ist ein Kernproblem der KI:

- Es gibt viele Algorithmen, die die Inferenz effizienter machen
- Faktorgraphen, **Message Passing**, Expectation Propagation usw...



# Fragen?



# Agenda

## Bayessche Netze (Bayesian networks)


- Definition
- Explaining Away
- Inferenz

## Probabilistische Programme

### Hidden Markov Modelle

- Zustandsabschätzung und Filtern (state estimation and filtering)
- Vorwärts Algorithmus (forward algorithm): Filtern
- Vorwärts Rückwärts Algorithmus (forward backward algorithm): Glättung (smoothing)

# Probabilistische Programme



## Probabilistic program: alarm

$$B \sim \text{Bernoulli}(\epsilon)$$
$$E \sim \text{Bernoulli}(\epsilon)$$
$$A = B \vee E$$

## Gemeinsame Verteilung:

$$p(E, B, A) = p(E)p(B)p(A|B, E)$$

```
def Bernoulli(epsilon):  
    return random.random() < epsilon
```

## Der Schlüsselgedanke:

- Ein randomisiertes Programm, das die Zufallsvariablen setzt
- Auch "generatives Modell" oder "generativer Prozess" genannt

# Beispiel: Objektverfolgung



## Probabilistic program: object tracking

$$X_0 = (0, 0)$$


For each time step  $i = 1, \dots, n$ :

if Bernoulli( $\alpha$ ):





$$X_i = X_{i-1} + (1, 0) \text{ [go right]}$$

else:

$$X_i = X_{i-1} + (0, 1) \text{ [go down]}$$







Trajectories for  $\alpha = 0.5$



- Wir können beliebig viele Zufallsvariablen (d.h. Zeitschritte) mit Hilfe von for-Schleifen erzeugen
- **Markov-Modell:** Jedes  $X_i$  hängt nur von  $X_{i-1}$  ab

# Beispiel für eine Schlussfolgerung

**Frage:** Was sind mögliche Wege angesichts des Evidenz?  $X_{10} = (8, 2)$



# Anwendung: Sprachmodelle (z.B. Spracherkennung, maschinelle Übersetzung)


- Einfaches Modell: Wahrscheinlichkeit des neuen Worts hängt nur vom vorherigen Wort ab
- Besser: hängt von den letzten  $k$  Wörtern ab (**Markov-Modelle höherer Ordnung**)



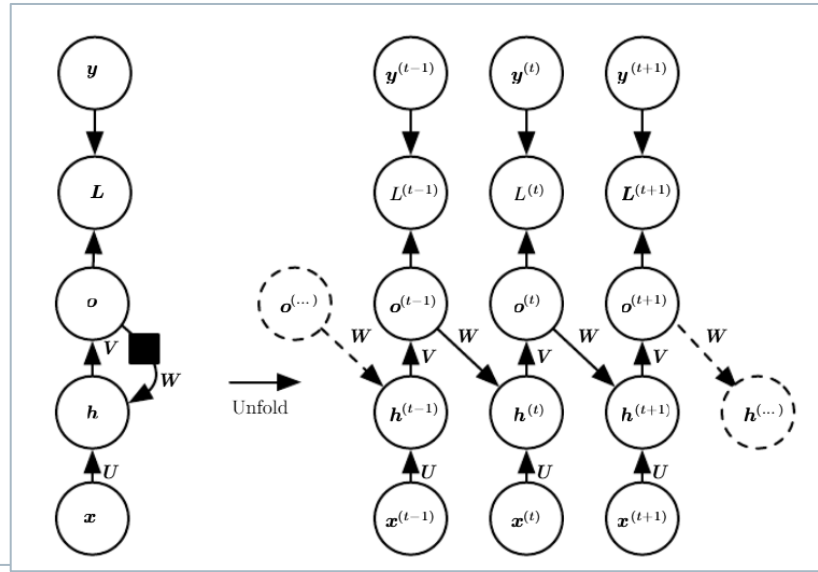
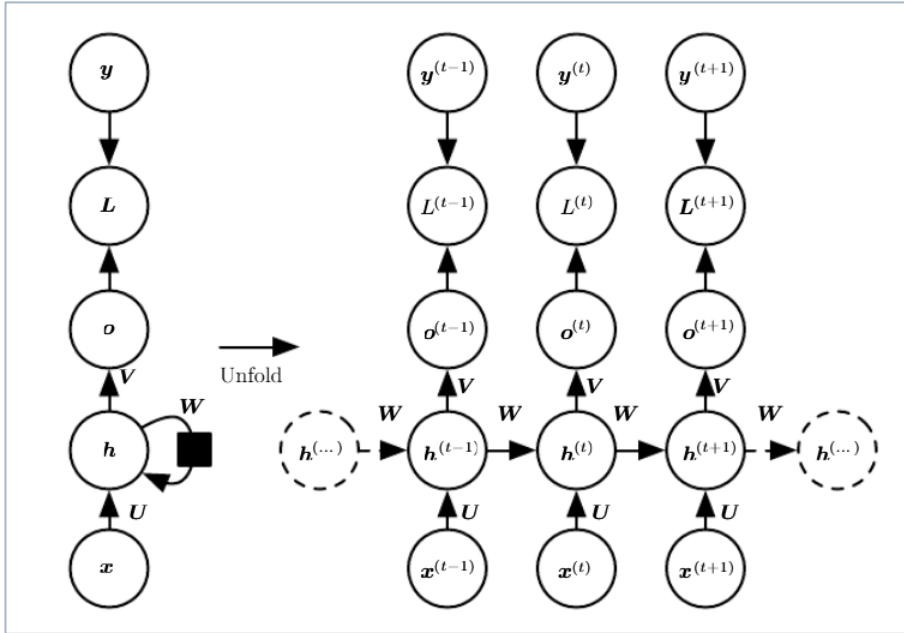
## Probabilistic program: Markov model

For each position  $i = 1, 2, \dots, n$ :

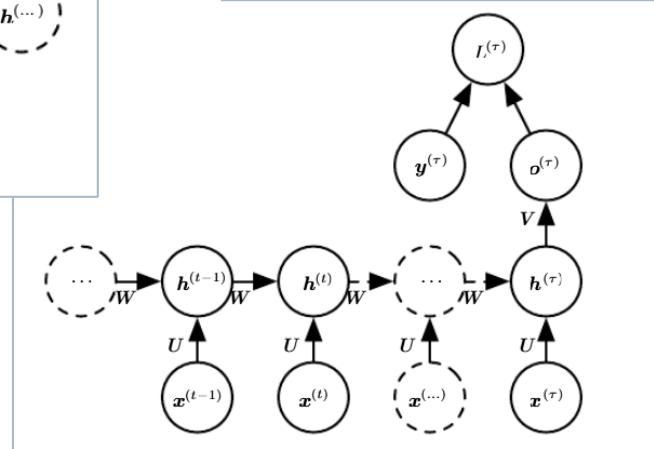
Generate word  $X_i \sim p(X_i \mid X_{i-1})$



# RNN-Architekturbeispiele



Markov models?



# Anwendung: Objektverfolgung aus unsicheren Beobachtungen




## Probabilistic program: hidden Markov model (HMM)

For each time step  $t = 1, \dots, T$ :

Generate object location  $H_t \sim p(H_t | H_{t-1})$

Generate sensor reading  $E_t \sim p(E_t | H_t)$



- Wo befindet sich das Objekt aufgrund der Reihe von Sensormesswerten?
- Das allgemeine Problem wird als Zustandsschätzung bezeichnet

# Agenda

## Bayessche Netze (Bayesian networks)

- Definition
- Explaining Away
- Inferenz

## Probabilistische Programme

### Hidden Markov Modelle

- Zustandsabschätzung und Filtern (state estimation and filtering)
- Vorwärts Algorithmus (forward algorithm): Filtern
- Vorwärts Rückwärts Algorithmus (forward backward algorithm): Glättung (smoothing)

# Feedback Lehrevaluation

# Positive Kommentare durch die LLM-Brille

## Zusammenfassung (max. 5 Stichpunkte):

- Sehr hohe **Interaktivität** durch Umfragen, Quizze (z. B. Wooclap) und aktive Einbindung der Studierenden, die zum Mitdenken anregen.
- **Didaktisch starke Aufbereitung**: komplexe Inhalte werden verständlich erklärt, mit vielen anschaulichen Beispielen, Diagrammen und klaren Einführungen.
- **Angenehmer, motivierter Vortragsstil** des Dozenten: sympathisch, kompetent, offen, strukturiert und gut nachvollziehbar.
- **Praxis- und Anwendungsbezug** sowie hohe Aktualität der Themen, mit qualitativ hochwertiger Einordnung jenseits von bloßem „Hype“.
- **Gute Lernunterstützung** durch sinnvolle Übungsblätter, Notebooks, deutsche Folien sowie kleine Anreize (z. B. Schokolade, humorvolle Elemente).

# Einige Verbesserungsvorschläge (spezifisch)

- Folien: oft zu viele Formeln und zu voll; Mathematik recht anspruchsvoll (gerade live); nicht immer alleine ausreichend für Nachbearbeitung und Übungen.
- Auch aktuelle Vorlesungsaufzeichnungen bitte (mehrfach genannt...).
- (Noch) klarere Definitionen für einige Begriffe.
- Einige abstrakte Konzepte hätten noch weiter aufgedröselt werden können.
- Tempo am Ende oft erhöht (in den letzten 15-30 Minuten)...Schwerer zu folgen.
- Mathematische Notation mit LA/Numerik abstimmen.
- Wechsel zwischen Deutsch und Englisch, Notationen nicht immer konsistent.
- Mehr Quellenverweise für Hintergrund, gerade bei der Mathematik.
- Vorlesungsfolien früher hochladen.
- Zu viele englische Fachbegriffe die aus dem Nichts kommen.

Go to **wooclap.com** and use the code **HIPFAX**



Inhalte der Vorlesungen: "What could go? (-)" and "What should stay?" (+)  
Vor Ihrer Antwort mit Plus oder Minus andeuten in welche Kategorie Ihre Antwort gehört. Vielen Dank!



75%



# Agenda

## Bayessche Netze (Bayesian networks)

- Definition
- Explaining Away
- Inferenz

## Probabilistische Programme


### Hidden Markov Modelle

- Zustandsabschätzung und Filtern (state estimation and filtering)
- Vorwärts Algorithmus (forward algorithm): Filtern
- Vorwärts Rückwärts Algorithmus (forward backward algorithm): Glättung (smoothing)

# Hidden Markov Modelle (HMM)

Betrachten **Markov-Kette** über die nicht beobachtbaren Zustände  $z_t$  und beobachten die Ausgaben  $y_t$  zu jedem Zeitschritt  $t$

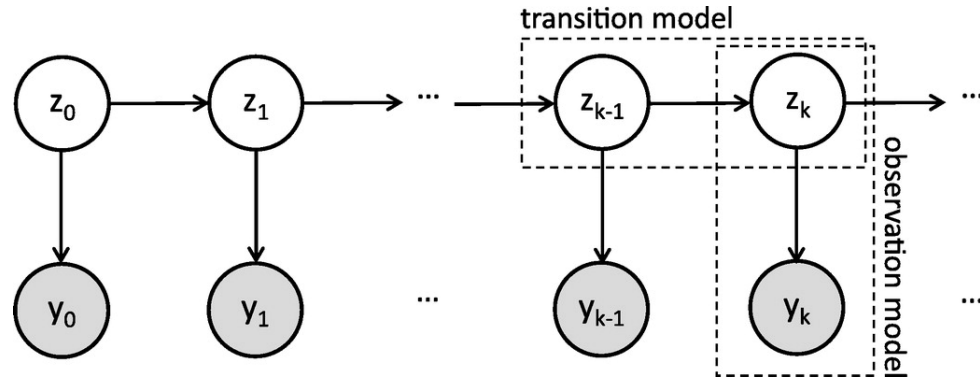
- Anfangsverteilung:  $p(z_0)$
- Übergangsmodell:  $p(z_{t+1}|z_t)$
- Beobachtungsmodell:  $p(y_t|z_t)$



In Anwendungen mit kontinuierlichen Zuständen bezeichnen wir dieses Modell oft als Zustandsraummodell

- Gleiches Konstrukt wie ein HMM
- Wir haben wieder die Markov-Annahme für das Übergangsmodell  
Beispiel: Kalman-Filter.
- Hier: bleiben für Anschaulichkeit bei diskreten Zuständen.

# Hidden Markov Modelle (HMM)



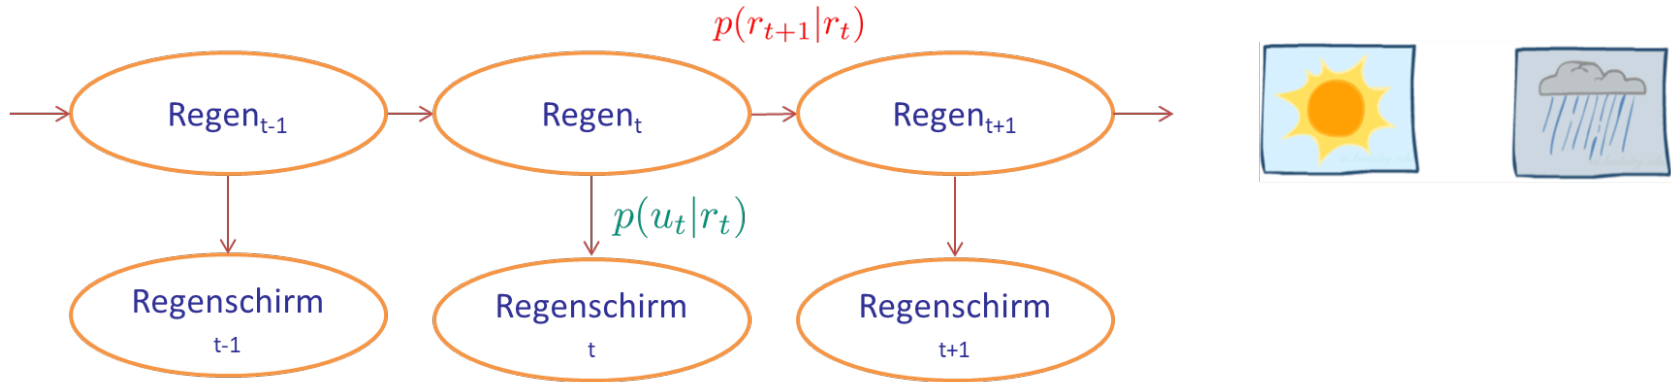
## Gemeinsame Verteilung

$$p(z_{0:t}, y_{0:t}) = p(z_0)p(y_0|z_0) \prod_{i=1}^t p(z_i|z_{i-1})p(y_i|z_i)$$

HMMs haben **zwei wichtige Unabhängigkeitseigenschaften** (ausnutzen!):

- Angesichts der Gegenwart ist die Zukunft unabhängig von der Vergangenheit
- Aktuelle Beobachtung unabhängig von allem anderen gegebenen aktuellen Zustand

# Beispiel: Wetter-HMM



- **HMM besteht aus:**

- Anfangsverteilung:  $p(r_0)$
- Transitionsmodell:  $p(r_{t+1}|r_t)$
- Beobachtungsmodell:  $p(u_t|r_t)$

$r_0$	$P(r_0)$
+	0.6
-	0.4

$r_t$	$r_{t+1}$	$P(r_{t+1}   r_t)$
+	+	0.7
+	-	0.3
-	+	0.3
-	-	0.7

$r_t$	$u_t$	$P(u_t   r_t)$
+	+	0.9
+	-	0.1
-	+	0.2
-	-	0.8

# Beispiel: Wetter-HMM

- Für diskrete Zufallsvariablen lassen sich die bedingten Verteilungen als Matrizen schreiben

$r_t$	$r_{t+1}$	$P(r_{t+1}   r_t)$
+	+	0.7
+	-	0.3
-	+	0.3
-	-	0.7



$r_{t+1} \backslash r_t$	+	-
+	0.7	0.3
-	0.3	0.7

- Spaltenindex: bedingende Variable ( $r_t$ ), Zeilenindex: bedingte Variable ( $r_{t+1}$ )
- **HMM besteht aus:**
  - Anfangsverteilung: **Vektor**  $p(r_0)$
  - Übergangsmodell : **Matrix**  $p(r_{t+1}|r_t)$
  - Beobachtungsmodell : **Matrix**  $p(u_t|r_t)$

# Hidden Markov Modelle Anwendungen

- HMMs für die Spracherkennung:
  - Beobachtungen sind akustische Signale (mit kontinuierlichem Wert)
  - Zustände sind bestimmte Positionen in bestimmten Wörtern (also Zehntausende)
- Maschinelle Übersetzung HMMs:
  - Beobachtungen sind Wörter (Zehntausende)
  - Staaten sind Übersetzungsoptionen
- Roboter-Verfolgung:
  - Beobachtungen sind Positionsmessungen (kontinuierlich)
  - Zustände sind Positionen auf einer Landkarte (kontinuierlich)

# Sonar Pacman

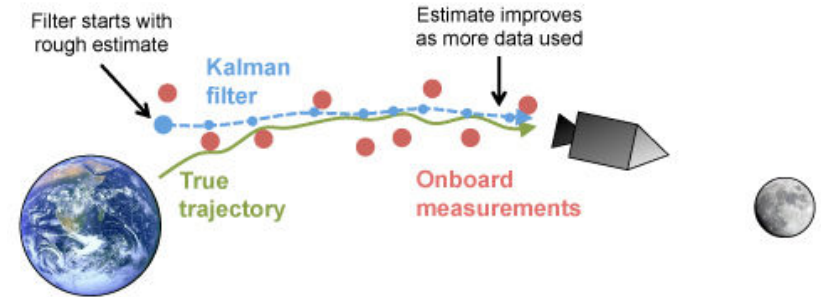


# Tracking mit HMMs

Normalerweise können wir nur **verrauschte Messungen** erhalten

Schätzung des "Zustands" anhand von Sensordaten:

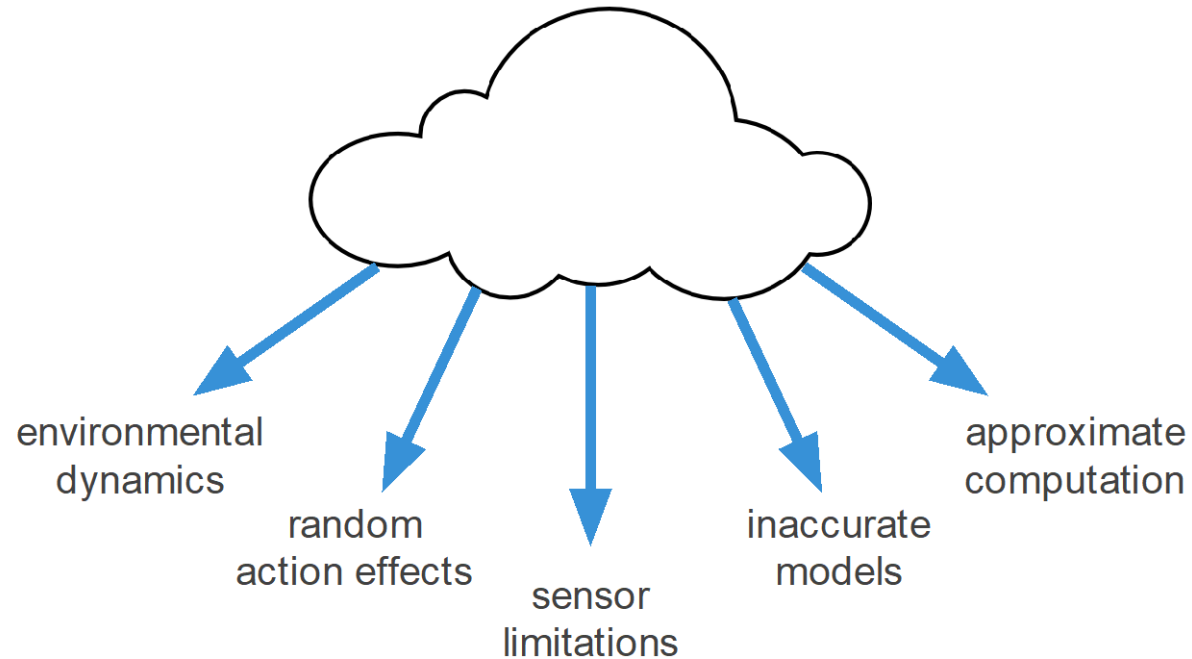
- Position und Ausrichtung des Roboters
- Karte der Umwelt
- Ortung von Personen, anderen Robotern, Objekten usw.



Indoor-Lokalisierung für mobile Roboter (gegebene Karte)

- Zusammenführung von Informationen aus verschiedenen Sensoren (LIDAR, Raddrehgeber)
- Probabilistische Filterung


# Warum ein probabilistischer Ansatz?



Explizite Darstellung der **Unsicherheit** mit Hilfe der Wahrscheinlichkeitsrechnung

# Einfaches Beispiel für eine Zustandsschätzung

- Angenommen, ein Roboter erhält die Messung  $y$  einer Tür
- Was ist  $p(\text{open}|y)$ ?



# Einfaches Beispiel für eine Zustandsschätzung

## Bayes'sches Netzwerk: Likelihood + Prior

$$p(y|\text{open}) = 0.6, \quad p(y|\neg\text{open}) = 0.3$$



$$p(\text{open}) = 0.5, \quad p(\neg\text{open}) = 0.5$$

## Satz von Bayes anwenden:

$$p(\text{open}|y) = \frac{p(y|\text{open})p(\text{open})}{p(y|\text{open})p(\text{open}) + p(y|\neg\text{open})p(\neg\text{open})}$$


$$p(\text{open}|y) = \frac{0.6 \cdot 0.5}{0.6 \cdot 0.5 + 0.3 \cdot 0.5} = \frac{2}{3} = 0.67$$

- $y$  erhöht die Wahrscheinlichkeit, dass die Tür offen ist.
- Auch “Konditionierung auf Beobachtung” genannt




# Einfaches Beispiel für eine Zustandsschätzung

- Angenommen, unser Roboter erhält weitere Beobachtung  $y_2$
- Wie lautet  $p(open|y_1, y_2)$ ?



# Sequentielle Bayes'sche Aktualisierung



Angenommen, wir haben mehrere Beobachtungen  $y_1$  bis  $y_n$ , dann:

$$p(z|y_{1:n}) = p(z|y_n, y_{1:n-1}) = \frac{p(y_n|z, y_{1:n-1})p(z|y_{1:n-1})}{p(y_n|y_{1:n-1})}$$

- Da wir wissen, dass die Beobachtungen  $y$  unabhängig gegebenen  $z$  sind

$$p(y_n|z, y_{1:n-1}) = p(y_n|z)$$

- können wir den **Satz von Bayes rekursiv** anwenden (**für jede neue Beobachtung!**)


$$\begin{array}{ccc} & \text{Likelihood} & \text{Alter Posterior = Prior} \\ p(z|y_{1:n}) = & \frac{p(y_n|z)p(z|y_{1:n-1})}{p(y_n|y_{1:n-1})} & \\ \text{Neuer Posterior} & & \text{Evidence} \end{array}$$

# Zurück zur zweiten Beobachtung

**Likelihood + Prior** (andere Beobachtung als anderer Likelihood)

$$p(y_2|\text{open}) = 0.5, \quad p(y_2|\neg\text{open}) = 0.6$$

$$p(\text{open}|y_1) = \frac{2}{3}, \quad p(\neg\text{open}|y_1) = \frac{1}{3}$$



**Satz von Bayes anwenden:**


$$p(\text{open}|y_1, y_2) = \frac{p(y_2|\text{open})p(\text{open}|y_1)}{p(y_2|\text{open})p(\text{open}|y_1) + p(y_2|\neg\text{open})p(\neg\text{open}|y_1)}$$

$$p(\text{open}|y_1, y_2) = \frac{0.5 \cdot 2/3}{0.5 \cdot 2/3 + 0.6 \cdot 1/3} = \frac{5}{8} = 0.625$$

- $y_2$  verringert die Wahrscheinlichkeit, dass die Tür offen ist.



# Eine wichtige Anwendung dieser rekursiven Ideen: Filtern

- Berechnung der **Zustands-Verteilung**  $b_t(z_t) = p(z_t|y_{0:t})$  (der “Belief State”) gegeben aller vergangenen Beobachtungen
- Wir beginnen mit einer Anfangsverteilung  $b_0(z_0)$  (keine Beobachtungen)
- Wenn ein Zeitschritt vergeht oder wir neue Beobachtungen machen, aktualisieren wir den Belief  $b_t(z_t)$
- Für kontinuierliche Systeme: **Kalman-Filter**
  - wurde in den 60er Jahren erfunden und erstmals als Methode zur Flugbahnabschätzung für das Apollo-Programm eingesetzt



# Beispiel: Roboter-Lokalisierung

Beispiel von  
Michael Pfeiffer



## Sensor-Modell:

- Kann messen, in welchen Richtungen eine Wand liegt (4 binäre Werte)
- Max 1 Fehler (Wand falsch detektiert) mit geringer Wahrscheinlichkeit


## Bewegungsmodell:

Bewegung + Rauschen (Roboter kann auch stehen bleiben).


# Beispiel: Roboter-Lokalisierung – kennen die Karte - wo ist der Roboter?

**Erste Messung:** von  $t=0$  nach  $t=1$

Zwei Wände  
stimmen nicht  
mit Messung  
überein



An allen dunkelgrauen Positionen  
hätten wir konsistente Messungen  
erwartet; alle gleich wahrscheinlich



Hellgrau: da ein Messfehler möglich ist, sind diese  
Felder unwahrscheinlicher, aber nicht unmöglich...

Prob

0

1

**Dunkelgrau:** Zustand konsistent mit Beobachtung


**Hellgrau:** Zustand weniger wahrscheinlich, da hierfür ein Fehler erforderlich wäre

**Weiß:** Zustand aufgrund Beobachtung nicht möglich


# Beispiel: Roboter-Lokalisierung

Die neue Messung wäre noch konsistent, falls der Roboter fehlerhaft stehen geblieben ist

Wäre möglich, weil wir vom Feld links gekommen sein könnten und eventuell jetzt eine fehlerhafte Messung machen




Noch möglich, weil ein Fehler auch in der ersten Messung aufgetreten sein könnte und jetzt korrekt gemessen wurde



t=2

# Beispiel: Roboter-Lokalisierung



Probe


0

1


t=3




# Beispiel: Roboter-Lokalisierung



t=4



# Beispiel: Roboter-Lokalisierung




Probe

0



1

t=5




# Beispiel: Geisterjäger HMM

- **Anfangszustand:**  $p(z_0) =$  gleichverteilt
- **Bewegungsmodell für jeden Geist:**  $p(z'|z) =$  bewegt sich normalerweise im Uhrzeigersinn, manchmal aber in eine zufällige Richtung oder bleibt an Ort und Stelle
- **Zustandsübergangsmodell:**  $p(y_{ij}|z) =$  kann ein bestimmtes Feld (ij) daraufhin untersuchen, ob es einen Geist gibt, rot bedeutet nah, grün bedeutet weit weg.



1/9	1/9	1/9
1/9	1/9	1/9
1/9	1/9	1/9

$$p(z)_0$$

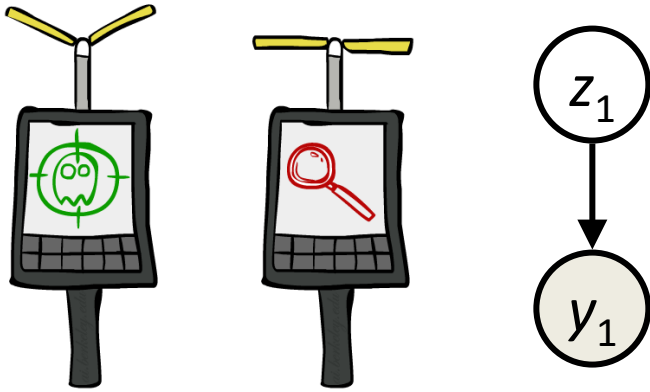


1/6	1/6	1/2
0	1/6	0
0	0	0

$$p(z'|z = \langle 1, 2 \rangle)$$


# Schlussfolgerung: Basis-Fälle

## Aktualisierung durch Beobachtung




$$p(z_1|y_1) \propto p(y_1|z_1)p(z_1)$$

## Vorhersage für nächsten Zeitschritt



$$p(z_2) = \sum_{z_1} p(z_2|z_1)p(z_1)$$

# Vorhersage: Übergang in den nächsten Zeitschritt



- Angenommen, wir haben eine aktuellen Belief  $p(z_t | \text{bisherige Erkenntnisse})$

$$b_t(z_t) = p(z_t | y_{0:t})$$

- Nachdem Zeitschritt verstrichen, berechne “**Prior Belief**” für t+1

$y_{t+1}$  noch nicht enthalten

$$b_{t+1}^-(z_{t+1}) = p(z_{t+1} | y_{0:t}) = \sum_{z_t} p(z_{t+1} | z_t) p(z_t | y_{0:t}) = \sum_{z_t} p(z_{t+1} | z_t) b(z_t)$$

- Grundidee: Beliefs werden durch die Übergangswahrscheinlichkeit in den nächsten Zeitschritt „geschoben“
  - $b_{t+1}^-(z_{t+1})$  ist der prior Belief für den Zeitschritt t+1, d. h. sie enthält keine Beobachtung

# Beispiel: Vorhersage in die Zukunft

- Mit der Zeit "akkumuliert" sich die Unsicherheit

Bewegungsmodell:  
Geister gehen normalerweise  
im Uhrzeigersinn

t=1

<0.01	<0.01	<0.01	<0.01	<0.01	<0.01
<0.01	<0.01	<0.01	<0.01	<0.01	<0.01
<0.01	<0.01	1.00	<0.01	<0.01	<0.01
<0.01	<0.01	<0.01	<0.01	<0.01	<0.01

t=2

<0.01	<0.01	<0.01	<0.01	<0.01	<0.01
<0.01	<0.01	0.06	<0.01	<0.01	<0.01
<0.01	0.76	0.06	0.06	<0.01	<0.01
<0.01	<0.01	0.06	<0.01	<0.01	<0.01

t=5

0.05	0.01	0.05	<0.01	<0.01	<0.01
0.02	0.14	0.11	0.35	<0.01	<0.01
0.07	0.03	0.05	<0.01	0.03	<0.01
0.03	0.03	<0.01	<0.01	<0.01	<0.01





# Wir brauchen also neue Messungen, um die Unsicherheiten einzuschränken!

- Angenommen, wir haben einen aktuellen **prior Belief**  $p(z_t | y_{<t})$ :

$$b_t^-(z_t) = p(z_t | y_{0:t-1})$$

- Sobald eine neue Beobachtung vorliegt, kann der **posterior Belief** berechnet werden (Satz von Bayes)

$$\begin{aligned} b_t(z_t) &= p(z_t | y_{0:t}) = \frac{p(z_t, y_t | y_{0:t-1})}{p(y_t | y_{0:t-1})} \\ &= \frac{p(y_t | z_t) p(z_t | y_{0:t-1})}{p(y_t | y_{0:t-1})} \propto p(y_t | z_t) b_t^-(z_t) \end{aligned}$$



- **Grundidee:** prior Beliefs werden nach der Wahrscheinlichkeit der neuen Beobachtung "neu gewichtet".
- Im Gegensatz zur Vorhersage müssen wir renormieren

# Belief-Update durch Beobachtung (t=5)

Wenn wir Beobachtungen erhalten, werden Beliefs neu gewichtet, die Unsicherheit "nimmt ab".

0.05	0.01	0.05	<0.01	<0.01	<0.01
0.02	0.14	0.11	0.35	<0.01	<0.01
0.07	0.03	0.05	<0.01	0.03	<0.01
0.03	0.03	<0.01	<0.01	<0.01	<0.01

Vor der Beobachtung


<0.01	<0.01	<0.01	<0.01	0.02	<0.01
<0.01	<0.01	<0.01	0.83	0.02	<0.01
<0.01	<0.01	0.11	<0.01	<0.01	<0.01
<0.01	<0.01	<0.01	<0.01	<0.01	<0.01

Nach der Beobachtung

Annahme:  
beobachten  
hier – ist der  
Geist in der  
Nähe oder  
nicht?



$$b_t(z_t) \propto p(y_t | z_t) b_t^-(z_t)$$




# Der Bayes-Filter (auch bekannt als der Vorwärts Algorithmus)

**Berechnen des Belief-States**  $b_t(z_t) = p(z_t|y_{0:t})$

1. Aktualisierung durch Vorhersage:

$$\underbrace{b_{t+1}^-(z_{t+1})}_{\text{Prior Belief for } t+1} = \sum_{z_t} p(z_{t+1}|z_t) \underbrace{b_t(z_t)}_{\text{Posterior belief for } t}$$



- Übergangmodell anwenden, vergangenen Zustand ausintegrieren/ marginalisieren

2. Aktualisierung durch Beobachtung:

$$\underbrace{b_{t+1}(z_t)}_{\text{Posterior Belief}} = p(z_{t+1}|y_{0:t+1}) \propto p(y_{t+1}|z_{t+1}) \underbrace{b_{t+1}^-(z_{t+1})}_{\text{Prior Belief for } t+1}$$

- Bayes-Theorem zur Berechnung des Posterior Beliefs
- In der Praxis müssen wir **den Normalisator Z** erst am Ende für den letzten Zeitschritt **berechnen**. Daher arbeiten wir in der Regel mit nicht normalisierten Beliefs (auch **Messages** genannt).

# Message weiterleiten

- Es reicht aus, den **unnormalisierten Belief** für Zwischenschritte zu berechnen
- Die Aktualisierung der Vorhersage und die Aktualisierung der Beobachtung können **in einer Gleichung kombiniert werden**
- Unnormierter Belief wird auch als **Message** bezeichnet

Für das Filtern berechnen wir die **Forward-Message**

$$\underbrace{\alpha_{t+1}(z_{t+1})}_{\text{Forward message for } t+1} \propto p(z_{t+1}|y_{0:t+1}) \propto p(y_{t+1}|z_{t+1}) \sum_{z_t} p(z_{t+1}|z_t) \underbrace{\alpha_t(z_t)}_{\text{Forward message for } t}$$

# Fragen?



# Forward Algorithmus

**Init:** Initialisierung  $\forall z : \alpha_0(z) = p(y_0|z)p(z_0)$

**Für k = 1 bis t**

Berechnung der Forwardmessage  $\alpha_k(z)$  für Zeitschritt k

$$\forall z_k : \alpha_k(z_k) = p(y_k|z_k) \sum_{z_{k-1}} p(z_k|z_{k-1})\alpha_{k-1}(z_{k-1})$$

**Normalisiere am Ende, um den Belief zu erhalten:**

$$\forall z : b_t(z) = \alpha_t(z) / \sum_z \alpha_t(z)$$

## Dynamische Programmierung

(siehe MDPs)

- Verwendung von Zwischenergebnissen (Belief) zur Berechnung der Endergebnisse
- Verwendet Messages als unnormalisierten Belief
- Beispiel für **Message Passing** in Bayes'schen Netzen

## Rechenkomplexität:


- Quadratisch in der Anzahl der hidden States
- Für jeden nächsten State muss über alle aktuellen verborgenen Zustände summiert werden

## Vermeide numerische Underflows

(zu kleine Zahlen)

- Reskalierung (Normalisierung) nach einigen Zeitschritten

# Sonar Pacman mit Beliefs




# Glättung (Smoothing)

**Was ist, wenn wir auch Beobachtungen aus der Zukunft  $T > t$  haben?**

- Wirkt sich das auf unseren Belief für den Zeitschritt  $t$  aus? Ja!
- Das Einbeziehen von Erkenntnissen aus der Zukunft wird als Glättung (Smoothing) bezeichnet.

**Wir wollen berechnen:**  $p(z_t | y_{0:T})$  with  $t < T$

**Faktorisieretes Belief-Update:**

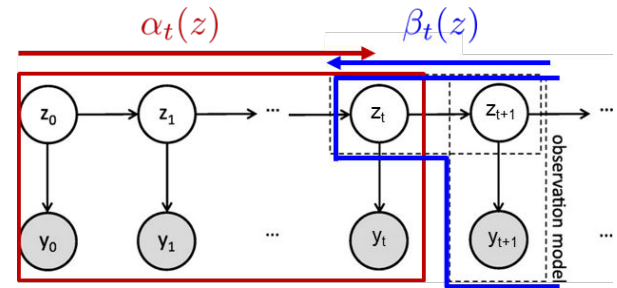


$$p(z_t | y_{0:T}) \propto \underbrace{p(z_t | y_{0:t})}_{\text{forward message } \alpha_t(z)} \cdot \underbrace{p(y_{t+1:T} | z_t)}_{\text{backward message } \beta_t(z)}$$

- Backward-Message  $\beta_t(z)$  "sammelt" Informationen aus der Zukunft

# Backward Message

- Anfangs-Message  $\beta_T(z_T) = 1$
- Beobachtungs-Update



$$\beta_t^+(z_t) = p(y_{t:T}|z_t) = p(y_t|z_t)p(y_{t+1:T}|z_t) = p(y_t|z_t)\beta_t(z_t)$$

$\beta_t^+(z_t)$ : "+" in zeigt an, dass auch Beobachtungen aus dem Zeitschritt  $t$  enthalten sind

- Umgedrehtes Vorhersage-Update: (zukünftiger Zeitschritt wird ausintegriert)

$$\beta_t(z_t) = p(y_{t+1:T}|z_t) = \sum_{z_{t+1}} p(y_{t+1:T}, z_{t+1}|z_t) = \sum_{z_{t+1}} p(y_{t+1:T}|z_{t+1})p(z_{t+1}|z_t) = \sum_{z_{t+1}} \beta_{t+1}^+(z_{t+1})p(z_{t+1}|z_t)$$

- Beide Updates können in einem Schritt berechnet werden:

$$\underbrace{\beta_t(z_t)}_{\text{Backward message for } t} = \sum_{z_{t+1}} p(z_{t+1}|z_t)p(y_t|z_t) \underbrace{\beta_{t+1}(z_{t+1})}_{\text{Backward message for } t+1}$$

# Forward-Backward-Algorithmus

Um  $p(z_t|y_{0:T})$  mit  $t < T$  zu berechnen, müssen wir:

- Berechnung der Forwardmessage

$$\alpha_t(z_t) \propto p(z_t|y_{0:t})$$

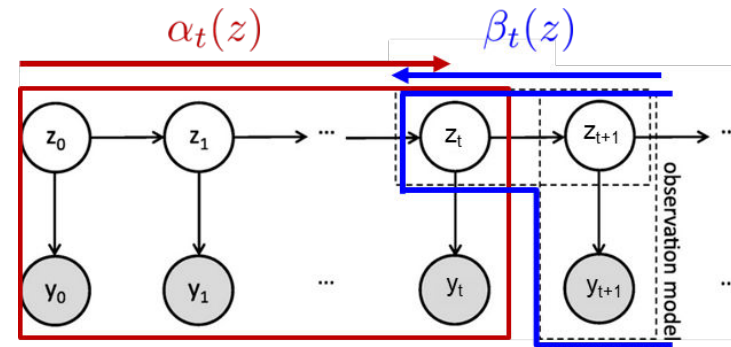
- Berechnung der Backwardmessage

$$\beta_t(z_t) = p(y_{t+1:T}|z_t)$$

- Berechnung des **geglätteten Beliefs** als normalisiertes Produkt

$$b_t(z_t) = p(z_t|y_{0:T}) \propto p(z_t|y_{0:t})p(y_{t+1:T}|z_t) \propto \alpha_t(z_t)\beta_t(z_t)$$


$$\Rightarrow b_t(z_t) = \frac{\alpha_t(z_t)\beta_t(z_t)}{\sum_{z_t} \alpha_t(z_t)\beta_t(z_t)}$$



# Smoothing vs. Filtering

## Visualisierung für ein kontinuierliches System

Dieselben Gleichungen, nur mit Gaußverteilungen (Kalman-Filter/Smother)



- „Glätteres“ Ergebnis als Filter, näher dran am echten Zustand
- Smoother hat weniger Unsicherheit (da auch zukünftige Informationen verwendet werden)

# Was wir uns heute nicht angesehen haben...

- **HMM-Dekodierung**

- Welches ist die wahrscheinlichste Abfolge  $z_{0:t}$  von Zuständen bei gegebenen Beobachtungen  $y_{0:t}$ ?
- Berechnet mit dem Viterbi-Algorithmus, ebenfalls ein dynamisches Programm

- **Lernen mit HMM**

- Einfach, wenn  $z_t$  auch beobachtet wird: Einfaches Zählen (alle Übergänge und Beobachtungsemissionen)
- Normalerweise ist  $z_t$  unbeobachtet.
- Kann mit dem Baum-Welch-Algorithmus gelernt werden
  - **Expectation-Maximization**
  - **Expectation-Schritt**: Berechnung der Anzahl der erwarteten Zustandsbesuche und Übergänge mit Hilfe des Forward-Backward-Algorithmus
  - **Maximization-Schritt**: Schätzung der HMM-Parameter auf der Grundlage der erwarteten Übergänge

- **Kalman-Filterung:**

- Bayes-Filter für lineare Systeme mit Gaußschem Rauschen

# HMM Zusammenfassung

**Hidden-Markov-Modelle und der Bayes-Filter bilden die Grundlage für viele andere Methoden:**

- Kalman-Filter
- Partikelfilter
- Partial-Observable Markov-Decision Processes (POMDPs)

**Berechnung eines Beliefs (einer Verteilung) über den Zustand zum Zeitschritt  $t$**

- **Vorhersage:** Belief um einen Zeitschritt nach vorne verschieben (Marginalisierung)
- **Beobachtung:** Neue Informationen einbeziehen (Bayes-Regel)
- **Glättung:** Auch Informationen aus der Zukunft einbeziehen

**Forward-Backward-Algorithmus:**

- Effizienter Weg zur Berechnung des Beliefs unter Verwendung der Markov-Faktorisierungsannahmen
- Berechnet Forward und Backward-Messages, um den Belief an dem Zeitschritt  $t$  zu berechnen

# Fragen zum Selbsttest

## Was Sie jetzt wissen sollten:

- Grundregeln der Wahrscheinlichkeitsrechnung
- Wie man die Bayes-Regel verwendet und wie man sie rekursiv verwendet
- Wie der Belief State definiert ist
- Welche Aktualisierungen sind erforderlich, um den Belief State in einem Bayes-Filter zu erhalten?
- Die Aktualisierungsgleichungen für den Bayes-Filter

# Fragen?



