

Grundlagen der Objektmodellierung

Daniel Göhring

30.10.2006

Gliederung

- Grundlagen der Wahrscheinlichkeitsrechnung
- Begriffe zur Umweltmodellierung
- Bayesfilter
- Zusammenfassung

Grundlagen der Wahrscheinlichkeitsrechnung

- In der probabilistischen Robotik werden Objektzustände, Sensor- sowie Kontrolldaten in Form von Zufallsvariablen beschrieben
- Probabilistische Inferenz: wie kann der Wert einer Zufallsvariable aus einer anderen Zufallsvariable abgeleitet werden?

Grundlagen

- Sei X eine Zufallsvariable mit einem Wert x
- Beispiel Münzwurf:
 - $p(X=\text{Kopf}) = 0.5$, $p(X=\text{Zahl}) = 0.5$
- Diskrete Wahrscheinlichkeiten summieren sich zu 1 auf: $\sum p(X = x) = 1$

Grundlagen - PDFs

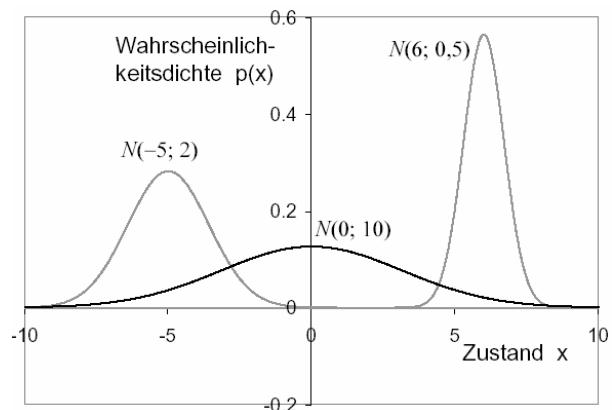
- Wahrscheinlichkeiten sind stets positiv oder gleich null
- Sehr oft werden Zustände im kontinuierlichen Raum abgeschätzt
- Variablen können dabei alle Werte innerhalb eines Kontinuums annehmen
- Alle Variablen solchen Var. besitzen eine Wahrscheinlichkeitsdichtefunktion (PDF)

Grundlagen - Normalverteilungen

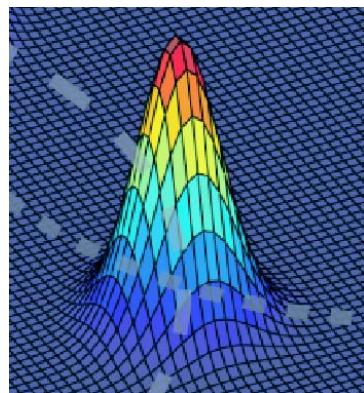
- Eine gebräuchliche Funktion zur Darstellung der Wahrscheinlichk.-Verteilung ist die Gaußfunktion, mit Mittelwert μ und Varianz σ
- Multivariate Verteilung

$$P(X) = \frac{1}{\sqrt{(2\pi)^n * \det(\Sigma)}} \exp^{-\frac{1}{2}(X-\mu)^T (\Sigma)^{-1} (X-\mu)}$$

Eindimensionale Gaußfunktionen



2D-Gaußfunktionen



Varianzen, Kovarianzen

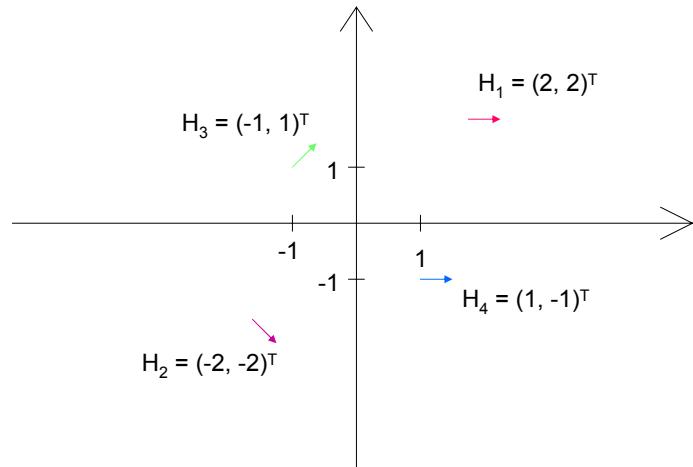
- Analog zur Varianz bei eindimensionalen Zustandsräumen können bei mehreren Dimensionen Kovarianzmatrizen S berechnet werden

$$S = 1/n \sum V_i^* V_i^{-1}$$

Beispiel

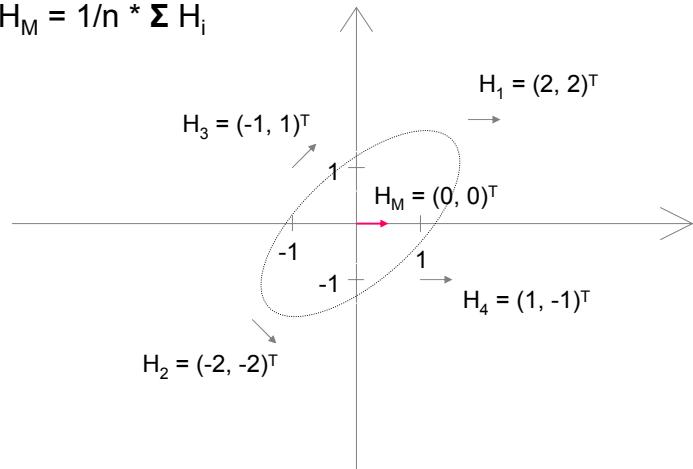
- 4 Messungen
- zwei Dimensionen: Position: x,y
- die einzelnen Messungen haben unterschiedliche Werte

Beispielverteilung



Mittelwert

$$H_M = \frac{1}{n} * \sum H_i$$



Kovarianzmatrix

$$S = 1/n * \Sigma (H_M - H_i) * (H_M - H_i)^T$$

- Auf der Hauptdiagonale befinden sich die Varianzen von x und y, auf Nebendiagonale die Kovarianzen.

$$\begin{array}{cc} 2.5 & 1.5 \end{array}$$

$$S = \left(\begin{array}{cc} & \\ & \end{array} \right)$$
$$\begin{array}{cc} 1.5 & 2.5 \end{array}$$

Werte der Kovarianzmatrix können nicht direkt in Werte der Ellipse (Rotation, Halbachsenausdehnung) umgerechnet werden. Kovarianzmatrix ist immer symmetrisch (positiv demindefinite Matrix).

Zur Vollständigkeit: Korrelationsmatrix R

- jedes Element $r_{i,j}$ aus R berechnet sich bei gegebenen Elementen $c_{i,j}$ aus S als:

$$r_{i,j} = c_{i,j} * c_{j,i} / (c_{i,i} * c_{j,j})$$

$$\begin{array}{cc} 1 & 0.36 \\ = (&) \\ 0.36 & 1 \end{array}$$

Bedingte Unabhängigkeiten

- $p(x,y)$
- $p(x|y) = p(X = x | Y = y)$
- $p(x|y) = p(x,y) / p(y)$
- $p(x|y) = p(x) * p(y) / p(y) = p(x)$
- Wenn X und Y unabhängig sind, kann man aus Y nichts über X sagen

Theorem der Totalen Wahrscheinlichkeiten

- $p(x) = \sum p(x|y)p(y)$ Diskret
- $p(x) = \int p(x|y)p(y) dy$ Kontinuierlich

Satz von Bayes

$$\bullet \ p(x|y) = \frac{p(y|x) p(x)}{p(y)}$$

$$\bullet \ p(x|y) = \frac{p(y|x) p(x)}{\int p(y|x) p(x) dx}$$

Satz von Bayes

Da $p(y)$ für alle Werte von x gleich ist, kann eine verkürzte Schreibweise eingeführt werden,

$$p(x|y) = \eta \ p(y|x) p(x)$$

η besagt, dass das Resultat noch normiert werden muss.

Satz von der bedingten Unabhängigkeit

- Analog zum Satz der Unabhängigkeit, kann der Satz der Bedingten Unabhängigkeit formuliert werden als:

$$p(x,y|z) = p(x|z) * p(y|z), \text{ äquivalent zu}$$
$$p(x|z) = p(x|z,y)$$
$$p(y|z) = p(y|z,x)$$

Begriffe zur Umweltmodellierung

- Zustand: Umwelt wird als Zustand repräsentiert
- Zustandsvariablen, die sich nicht über die Zeit ändern werden als statisch, sonst als dynamisch bezeichnet
- Bezeichnung im allgemeinen als x , Zustand zur Zeit t : x_t

- Position
 - kann durch bis zu 6 Koordinaten dargestellt werden: 3 für die Position und 3 für die Orientierung im Raum
 - Bei Bewegung in der Ebene reichen hingegen meist 3 Koordinaten aus, 2 für die Position, 1 für die Ausrichtung

- Landmarken – eine Möglichkeit der Lokalisierung ist die Einführung von Landmarken
- Stationäre, Unterscheidbare, gut erkennbare Objekte der Umwelt

- Vollständiger Zustand
 - Ein Zustand x_t wird als vollständig bezeichnet, wenn er die Zukunft maximal genau vorhersagen kann, d.h. Wissen über seine Vergangenheit auch keine zusätzliche Genauigkeit mehr einbringen würde
 - Verwendung bei Markovketten
 - Praktisch unmöglich, weil nie alle Variablen bekannt sind
 - Oft erfolgt Auswahl von Variablen – unvollständiger Zustand

- Diskrete, kontinuierliche Zustände:
 - Beispiele: Kontinuierlich: Roboterposition
 - Diskret: Sensorindikator (funktioniert/defekt)

Interaktion mit der Umwelt

- Messung:

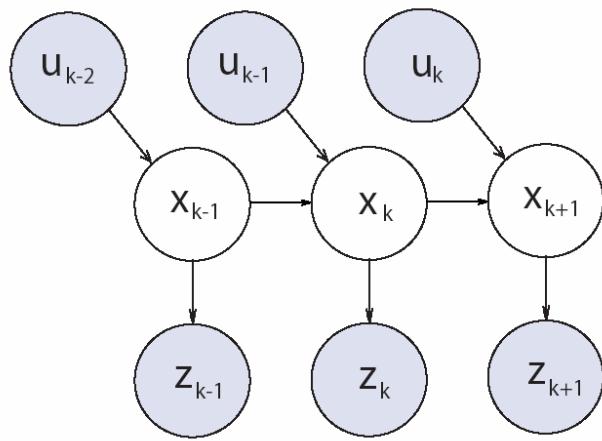
- Resultat einer Interaktion/Beobachtung der Umwelt durch Sensoren
- Sensordaten treffen i.d.R. mit einer gewissen Verzögerung ein
- Schreibweise $z_{t1:t2} = z_{t1}, \dots, z_{t2}$

- Kontrollaktionen:

- ändern den Zustand der Welt
- Auch wenn Roboter keine Aktionen intendiert, ändert sich die Welt – daher immer mitmodelliert
- $u_{t1:t2} = u_{t1}, \dots, u_{t2}$

- Odometer: Misst den Effekt einer Kontrollaktion, eigentlich Sensordaten, werden aber wie Kontrolldaten behandelt

Bayesnetzwerk/Hidden Markov Modell



- Zustandsübergangswahrscheinlichkeit

$$p(x_t|x_{t-1}, u_t)$$

- Messungswahrscheinlichkeit

$$p(z_t|x_t)$$

Beispiel

- Glaube, Tür Offen:

$$\text{bel}(X = \text{open}) = 0.5$$

$$\text{bel}(X = \text{closed}) = 0.5$$

Sensormodell:

$$p(Z = \text{sens offen} | X = \text{ist offen}) = 0.6$$

$$p(Z = \text{sens geschl.} | X = \text{ist offen}) = 0.4$$

$$p(Z = \text{sens offen} | X = \text{ist geschl.}) = 0.2$$

$$p(Z = \text{sens geschl.} | X = \text{ist geschl.}) = 0.8$$

Beispiel Fortsetzung

$$p(X = \text{ist offen} | U = \text{öffne}, X = \text{ist off.}) = 1$$

$$p(X = \text{ist geschl.} | U = \text{öffne}, X = \text{ist off.}) = 0$$

$$p(X = \text{ist offen} | U = \text{öffne}, X = \text{ist gesch.}) = 0.8$$

$$p(X = \text{ist geschl.} | U = \text{öffne}, X = \text{ist gesch.}) = 0.2$$

Oder

$$p(X = \text{ist offen} | U = \text{Do noth.}, X = \text{ist off.}) = 1$$

$$p(X = \text{ist geschl.} | U = \text{Do noth.}, X = \text{ist off.}) = 0$$

$$p(X = \text{ist offen} | U = \text{Do noth.}, X = \text{ist off.}) = 0$$

$$p(X = \text{ist geschl.} | U = \text{Do noth.}, X = \text{ist off.}) = 1$$

Beispiel Fortsetz.

- Wir können nun berechnen, mit welcher Wahrscheinlichkeit die Tür offen ist, wenn wir sie öffnen wollten und der Sensor sagt, Tür geschlossen.

Monte Carlo Lokalisierung

Iterative Bayesian Updating/Filtering:

$$\begin{array}{lcl} \text{prior} & & \text{posterior at previous time step} \\ Bel^-(s_t) & \leftarrow & \int p(s_t | s_{t-1}, u_{t-1}) Bel(s_{t-1}) ds_{t-1} \\ & & \\ Bel(s_t) & \leftarrow & np(z_t | s_t) Bel^-(s_t) \\ \text{posterior} & & \text{sensor model} \end{array}$$

Bel = belief, s = state, p = probability, u = action,
 z = observation, η = normalization factor, t = discrete time

Taxonomie von Lokalisierungsproblemen

- Lokale vs. Globale Lokalisierung
 - Frage des Roboterkoordinatensystems
- Lokal: Keine Lokalisierung/Umrechnung notwendig
- Global: Kommunikation mit anderen Robotern möglich

Taxonomie von Lokalisierungsproblemen

- Position Tracking/Lokalisierung
 - Objektverfolgung, wenn Anfangsposition bekannt,
 - Lokalisierung, wenn Anfangsposition unbekannt

Taxonomie von Lokalisierungsproblemen

- Kidnapped Robot Problem
 - Anfangsposition unbekannt,
 - Roboter muss seine Position in Umgebung ohne Vorwissen ermitteln

Taxonomie von Lokalisierungsproblemen

- Statische Umwelt, Dynamische Umwelt

Taxonomie von Lokalisierungsproblemen

- Passive Lokalisierung, Aktive Lokalisierung
 - Passiv: Warten auf bestimmte Sensordaten, die der Lokalisierung dienen könnten und dabei andere Aufgaben verfolgen
 - Aktive Lokalisierung: gezieltes Einsetzen der Sensoren zur Erfassung von Lokalisierungsdaten (active Vision)
 - Minimierung des Lokalisierungsfehlers

Taxonomie von Lokalisierungsproblemen

- Single Roboterlokalisierung
 - Weitgehend Untersucht,
 - Alle Daten kommen von derselben Plattform
- Multiroboterlokalisierung
 - In Gruppen von Robotern, in denen sich die Roboter gegenseitig erkennen können, bietet sich eine interessante Möglichkeit, die Lokalisierungsgenauigkeit zu verbessern
 - Viele interessante Algorithmen für Kommunikation, Inferenz