



# 64-424 Intelligente Roboter

[http://tams.informatik.uni-hamburg.de/  
lectures/2011ws/vorlesung/ir](http://tams.informatik.uni-hamburg.de/lectures/2011ws/vorlesung/ir)

Jianwei Zhang



Universität Hamburg  
Fakultät für Mathematik, Informatik und Naturwissenschaften  
Fachbereich Informatik

**Technische Aspekte Multimodaler Systeme**

Wintersemester 2011/2012



# Gliederung

1. Grundlagen der Sensorik
2. Winkel und Bewegungen
3. Kräfte und Druck
4. Abstandssensoren
5. Scandaten verarbeiten
6. **Rekursive Zustandsschätzung**

Grundlagen der Wahrscheinlichkeitsrechnung

Stochastische Fortpflanzungsgesetze und Belief

Bayes-Filter

Selbst-Lokalisierung mobiler Roboter

Literatur

7. Sichtsysteme
8. Fuzzy-Logik



# Gliederung (cont.)

## 9. Steuerungsarchitekturen





# Rekursive Zustandsschätzung

- ▶ **Idee:** Schätzung eines Systemzustands der nicht direkt gemessen werden kann, aber aus den Messungen ableitbar ist
- ▶ Probabilistische Algorithmen zur Zustandsschätzungen berechnen eine **belief distribution** über die möglichen Zustände
- ▶ Der **belief** beschreibt das Wissen eines Systems über den Zustand seiner Umgebung



# Grundlagen der Wahrscheinlichkeitsrechnung

- ▶ Sensormessungen, Stellgrößen, der Zustand eines Systems sowie der Zustand dessen Umgebung können als **Zufallsvariable** modelliert werden
- ▶ Sei  $X$  eine Zufallsvariable und  $x$  ein Wert den diese annehmen kann
- ▶ Ist der Wertebereich von  $X$  diskret schreibt man:

$$p(X = x)$$

um die Wahrscheinlichkeit anzugeben, dass  $X$  den Wert  $x$  hat



## Grundlagen der Wahrscheinlichkeitsrechnung (cont.)

- ▶ Die Summe diskreter Wahrscheinlichkeiten ist 1:

$$\sum_x p(X = x) = 1$$

- ▶ Wahrscheinlichkeiten sind immer nicht-negativ, d.h.

$$p(X = x) \geq 0$$

- ▶ Der Einfachheit halber schreiben wir  $p(x)$  anstelle von  $p(X = x)$



## Grundlagen der Wahrscheinlichkeitsrechnung (cont.)

- ▶ Kann die Zufallsvariable einen kontinuierlichen Wert annehmen, dann wird sie durch eine **Dichtefunktion** beschrieben (engl. *probability density function, PDF*)
- ▶ Eine typische Dichtefunktion ist die **Normalverteilung** mit Mittelwert  $\mu$  und Varianz  $\sigma^2$ :

$$p(x) = (2\pi\sigma^2)^{-\frac{1}{2}} \exp \left\{ -\frac{1}{2} \frac{(x - \mu)^2}{\sigma^2} \right\}$$

- ▶ Im mehrdimensionalen Fall mit Mittelwertsvektor  $\mu$  und Kovarianzmatrix  $\Sigma$ :

$$p(x) = \det(2\pi\Sigma)^{-\frac{1}{2}} \exp \left\{ -\frac{1}{2} (x - \mu)^T \Sigma^{-1} (x - \mu) \right\}$$



## Grundlagen der Wahrscheinlichkeitsrechnung (cont.)

- ▶ Die **Kovarianzmatrix**  $\Sigma$  ist *positiv semidefinit* und *symmetrisch*
- ▶ Für eine PDF gilt:

$$\int p(x) dx = 1$$

- ▶ Der Funktionswert einer PDF ist nicht wie bei diskreten Wahrscheinlichkeiten nach oben durch 1 begrenzt
- ▶ Die Wahrscheinlichkeit, dass  $X$  den Wert  $x$  und  $Y$  den Wert  $y$  hat, schreibt man

$$p(x, y) = p(X = x \text{ und } Y = y)$$



## Grundlagen der Wahrscheinlichkeitsrechnung (cont.)

- ▶ Sind die beiden Zufallsvariablen  $X$  und  $Y$  von einander unabhängig gilt:

$$p(x, y) = p(x)p(y)$$

- ▶ Wenn man weiß, das  $Y$  den Wert  $y$  hat, dann wird die Wahrscheinlichkeit für  $X$  wie folgt beschrieben

$$p(x|y) = p(X = x | Y = y)$$

- ▶ Gilt für diese **bedingte Wahrscheinlichkeit** das  $p(y) > 0$  ist, gilt:

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



## Grundlagen der Wahrscheinlichkeitsrechnung (cont.)

- ▶ Sind  $X$  und  $Y$  voneinander unabhängig, gilt:

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

- ▶ Das bedeutet, wenn  $X$  und  $Y$  unabhängig voneinander sind, sagt uns  $Y$  nichts über  $X$
- ▶ **Gesetz der totalen Wahrscheinlichkeit:**

$$p(x) = \sum_y p(x|y)p(y) \quad (\text{diskret})$$

$$p(x) = \int p(x|y)p(y)dy \quad (\text{kontinuierlich})$$

## Grundlagen der Wahrscheinlichkeitsrechnung (cont.)

- ▶ **Satz von Bayes:** (mit  $p(y) > 0$ )

$$p(x|y) = \frac{p(y|x)p(x)}{p(y)} = \frac{p(y|x)p(x)}{\sum_{x'} p(y|x')p(x')} \quad (\text{diskret})$$

$$p(x|y) = \frac{p(y|x)p(x)}{p(y)} = \frac{p(y|x)p(x)}{\int p(y|x')p(x')dx} \quad (\text{kontinuierlich})$$

- ▶ Der Satz von Bayes beschreibt das Umkehren von Schlussfolgerungen
  - ▶ die Berechnung von  $p(\text{Ereignis}|\text{Ursache})$  ist oft einfach
  - ▶ aber gesucht ist  $p(\text{Ursache}|\text{Ereignis})$



## Grundlagen der Wahrscheinlichkeitsrechnung (cont.)

- ▶ Der Satz von Bayes spielt eine hervorgehobene Rolle
- ▶ Sei  $x$  die Größe die wir aus  $y$  ableiten wollen, dann bezeichnet man  $p(x)$  als **A-Priori-Wahrscheinlichkeit** und  $y$  als **Daten** (z.B. Sensormessungen)
- ▶ Die Verteilung  $p(x)$  beschreibt das Wissen über  $X$  bevor die Messung  $y$  berücksichtigt wird
- ▶ Die Verteilung  $p(x|y)$  wird als **A-Posteriori-Wahrscheinlichkeit** von  $X$  bezeichnet
- ▶ Der Satz von Bayes erlaubt nun  $p(x|y)$  zu berechnen, wenn die Wahrscheinlichkeit für eine Messung  $y$  bei einem Zustand  $x$  bekannt ist



## Grundlagen der Wahrscheinlichkeitsrechnung (cont.)

- ▶ Im Satz von Bayes hängt  $p(y)$  nicht von  $x$  ab
- ▶ Daher ist der Faktor  $p(y)^{-1}$  für jeden Wert  $x$  in  $p(x|y)$  gleich
- ▶ Dieser Faktor wird meist als Normalisierungsfaktor im Satz von Bayes notiert:

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

- ▶ Diese abkürzende Schreibweise stellt die Normalisierung des Ergebnisses auf den Wert 1 dar
- ▶  $\eta$  bezeichnet im Folgenden immer solche Normalisierungsfaktoren, deren eigentliche Werte sich aber unterscheiden können



## Grundlagen der Wahrscheinlichkeitsrechnung (cont.)

- ▶ Alle bisherigen Regeln können durch eine weitere Zufallsvariable  $Z$  bedingt sein
- ▶ Dies bedeutet für den Satz von Bayes mit  $Z = z$ :

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

solange  $p(y|z) > 0$

- ▶ Ähnliches gilt für die Regel zur Kombination unabhängiger Zufallsvariablen:

$$p(x, y|z) = p(x|z)p(y|z)$$



## Grundlagen der Wahrscheinlichkeitsrechnung (cont.)

- ▶ Obige Formel beschreibt eine **bedingte Unabhängigkeit** und ist äquivalent zu

$$p(x|z) = p(x|z, y)$$

$$p(y|z) = p(y|z, x)$$

- ▶ Sie besagt, dass  $y$  keine Information über  $x$  trägt, wenn  $z$  bekannt ist



## Grundlagen der Wahrscheinlichkeitsrechnung (cont.)

- ▶ Sie impliziert **nicht**, dass  $X$  unabhängig von  $Y$  ist:

$$p(x, y|z) = p(x|z)p(y|z) \not\Rightarrow p(x, y) = p(x)p(y)$$

und die Umkehrung gilt generell auch nicht:

$$p(x, y) = p(x)p(y) \not\Rightarrow p(x, y|z) = p(x|z)p(y|z)$$



## Grundlagen der Wahrscheinlichkeitsrechnung (cont.)

- ▶ Der **Erwartungswert** einer Zufallsvariablen ist gegeben als:

$$E[X] = \sum_x x p(x) \quad (\textit{diskret})$$

$$E[X] = \int x p(x) dx \quad (\textit{kontinuierlich})$$

- ▶ Der Erwartungswert ist eine lineare Funktion einer Zufallsvariablen, d.h. es gilt:

$$E[aX + b] = aE[X] + b$$



## Grundlagen der Wahrscheinlichkeitsrechnung (cont.)

- ▶ Die **Kovarianz** von  $X$  berechnet sich wie folgt:

$$\text{Cov}[X] = E[X - E[X]]^2 = E[X^2] - E[X]^2$$

- ▶ Die Kovarianz misst das erwartete Quadrat der Abweichung vom Mittelwert



## Grundlagen der Wahrscheinlichkeitsrechnung (cont.)

- ▶ Die **Entropie** einer Wahrscheinlichkeitsverteilung ist gegeben durch:

$$H_p(x) = E[-\log_2 p(x)]$$

bzw.

$$H_p(x) = -\sum_x p(x) \log_2 p(x) \quad (\text{diskret})$$

$$H_p(x) = -\int p(x) \log_2 p(x) dx \quad (\text{kontinuierlich})$$

- ▶ Die Entropie ist die erwartete Information, die die Werte von  $x$  tragen
- ▶ Im diskreten Fall ist  $-\log_2 p(x)$  die Anzahl der Bits, die notwendig sind, um  $x$  optimal zu kodieren, wenn  $p(x)$  die Wahrscheinlichkeit für die Beobachtung von  $x$  ist



# Stochastische Fortpflanzungsgesetze

- ▶ Der Zustand eines Systems lässt sich durch eine Wahrscheinlichkeitsverteilung

$$p(x_t | x_{0:t-1}, z_{1:t-1}, u_{1:t})$$

beschreiben, die abhängig ist von

- ▶ den bisherigen Zuständen  $x_{0:t-1}$
- ▶ allen bisherigen Messungen  $z_{1:t-1}$  und
- ▶ allen bisherigen Stellgrößen (Steuerkommandos)  $u_{1:t}$



## Stochastische Fortpflanzungsgesetze (cont.)

- ▶ Ist der Zustand  $x$  **komplett**, dann fasst die Stellgröße  $u_t$  und der Zustand  $x_{t-1}$  alle bisherigen Ereignisse zusammen:

$$p(x_t | x_{0:t-1}, z_{1:t-1}, u_{1:t}) = p(x_t | x_{t-1}, u_t)$$

- ▶ Auch für die Messungen gilt ähnliches:

$$p(z_t | x_{0:t}, z_{1:t-1}, u_{1:t}) = p(z_t | x_t)$$


- ▶ In anderen Worten: Der Zustand  $x_t$  ist ausreichend um die Messung  $z_t$  vorherzusagen



## Stochastische Fortpflanzungsgesetze (cont.)

- ▶ Die bedingte Wahrscheinlichkeit  $p(x_t | x_{t-1}, u_t)$  wird als **Zustandsübergangswahrscheinlichkeit** bezeichnet
- ▶ Sie beschreibt wie sich der Zustand der Umgebung abhängig von den Stellgrößen ändert
- ▶ Die Wahrscheinlichkeit  $p(z_t | x_t)$  wird **Wahrscheinlichkeit der Messung** genannt
- ▶ Beide Wahrscheinlichkeiten zusammen beschreiben ein **dynamisches stochastisches System**
- ▶ Eine solche Systembeschreibung ist auch bekannt als **hidden Markov model (HMM)** oder **dynamic Bayes network (DBN)**

## Stochastische Fortpflanzungsgesetze (cont.)





# Belief

- ▶ Als **belief** bezeichnet man das Wissen eines Systems über seinen Zustand
- ▶ Der *wahre Zustand* eines Systems ist nicht dasselbe
- ▶ Der *belief* ist die A-Posteriori-Wahrscheinlichkeit der Zustandsvariablen anhand der bisherigen Daten:

$$bel(x_t) = p(x_t | z_{1:t}, u_{1:t})$$

- ▶ Diese Definition setzt den *belief* als Wahrscheinlichkeit nach der Messung



## Belief (cont.)

- ▶ Der *belief* vor der Messung wird als

$$\overline{bel}(x_t) = p(x_t | z_{1:t-1}, u_{1:t})$$

definiert und meist als **Vorhersage** (engl. *prediction*) bezeichnet

- ▶ Der Schritt  $bel(x_t)$  aus der Vorhersage  $\overline{bel}(x_t)$  zu berechnen, wird als **Korrektur** (engl. *correction* oder *measurement update*) bezeichnet



# Bayes-Filter

- ▶ Der allgemeinste Algorithmus um *beliefs* zu berechnen ist der **Bayes-Filter-Algorithmus**
- ▶ Der Algorithmus ist rekursiv und berechnet  $bel(x_t)$  zum Zeitpunkt  $t$  aus folgenden Größen
  - ▶  $bel(x_{t-1})$  zum Zeitpunkt  $t - 1$
  - ▶ der Stellgröße  $u_t$
  - ▶ der Messung  $z_t$



# Bayes-Filter-Algorithmus

Bayes-Filter ( $bel(x_{t-1}), u_t, z_t$ ):

1. **for all**  $x_t$  **do**
2.      $\overline{bel}(x_t) = \int p(x_t | u_t, x_{t-1}) bel(x_{t-1}) dx_{t-1}$
3.      $bel(x_t) = \eta p(z_t | x_t) \overline{bel}(x_t)$
4. **endfor**
5. **return**  $bel(x_t)$

## Bayes-Filter-Algorithmus (cont.)

- ▶ In Zeile 2 wird die Stellgröße  $u_t$  verarbeitet
- ▶  $\overline{bel}(x_t)$  ist das Integral des Produktes zweier Wahrscheinlichkeitsverteilungen:
  - ▶ die Wahrscheinlichkeit für Zustand  $x_{t-1}$  und
  - ▶ die Wahrscheinlichkeit das mit  $u_t$  in den Zustand  $x_t$  gewechselt wird
- ▶ Das ist die **Vorhersage**
- ▶ In Zeile 3 findet die **Korrektur** statt
- ▶  $\overline{bel}(x_t)$  wird mit der Wahrscheinlichkeit multipliziert, dass die Messung  $z_t$  in diesem Zustand wahrgenommen wird



## Bayes-Filter-Algorithmus (cont.)

- ▶ Der Algorithmus muss mit einem *belief* zum Zeitpunkt  $t = 0$  initialisiert werden
- ▶ In den meisten Fällen ist der Startzustand  $x_t$  bekannt und die Wahrscheinlichkeit kann für alle anderen Zustände gleich 0 gesetzt werden
- ▶ Oder der Zustand ist vollkommen unbekannt und alle Zustände werden mit der gleichen Wahrscheinlichkeit initialisiert



## Bayes-Filter-Algorithmus (cont.)

- ▶ Der Algorithmus kann in dieser Form nur für sehr einfache Probleme implementiert werden
- ▶ Entweder muss die Integration in Zeile 2 und die Multiplikation in Zeile 3 in geschlossener Form möglich sein
- ▶ oder ein endlicher Zustandsraum muss gegeben sein, so dass das Integral in Zeile 2 zu einer Summe wird



## Mathematische Herleitung des Bayes-Filter

- ▶ **Beweis durch Induktion:** Zeige dass  $p(x_t | z_{1:t}, u_{1:t})$  aus  $p(x_{t-1} | z_{1:t-1}, u_{1:t-1})$  hergeleitet werden kann
- ▶ **Beweis-Basis:** Korrekte Initialisierung von  $bel(x_o)$  zum Zeitpunkt  $t = 0$
- ▶ **Bedingungen:** Zustand  $x_t$  ist komplett und die Stellgrößen werden zufällig gewählt
- ▶ Nach dem Satz von Bayes gilt:

$$\begin{aligned}
 p(x_t | z_{1:t}, u_{1:t}) &= \frac{p(z_t | x_t, z_{1:t-1}, u_{1:t}) p(x_t | z_{1:t-1}, u_{1:t})}{p(z_t | z_{1:t-1}, u_{1:t})} \\
 &= \eta p(z_t | x_t, z_{1:t-1}, u_{1:t}) p(x_t | z_{1:t-1}, u_{1:t})
 \end{aligned}$$



## Mathematische Herleitung des Bayes-Filter (cont.)

- ▶ Da der Zustand komplett ist, gilt (bedingte Unabhängigkeit)

$$p(z_t | x_t, z_{1:t-1}, u_{1:t}) = p(z_t | x_t)$$

- ▶ Daraus folgt:

$$p(x_t | z_{1:t}, u_{1:t}) = \eta p(z_t | x_t) p(x_t | z_{1:t-1}, u_{1:t})$$

- ▶ und damit

$$bel(x_t) = \eta p(z_t | x_t) \overline{bel}(x_t)$$

was Zeile 3 des Bayes-Filter-Algorithmus entspricht



## Mathematische Herleitung des Bayes-Filter (cont.)

- ▶ Nach dem Gesetz der totalen Wahrscheinlichkeit gilt:

$$\begin{aligned} \overline{bel}(x_t) &= p(x_t | z_{1:t-1}, u_{1:t}) \\ &= \int p(x_t | x_{t-1}, z_{1:t-1}, u_{1:t}) p(x_{t-1} | z_{1:t-1}, u_{1:t}) dx_{t-1} \end{aligned}$$

- ▶ Wieder gilt, wenn wir  $x_{t-1}$  kennen, liefern  $z_{1:t-1}$  und  $u_{1:t-1}$  keine zusätzliche Information
- ▶ Daher gilt die Vereinfachung

$$p(x_t | x_{t-1}, z_{1:t-1}, u_{1:t}) = p(x_t | x_{t-1}, u_t)$$

- ▶  $u_t$  bleibt, da diese Stellgröße erst zum Zustandsübergang führt



## Mathematische Herleitung des Bayes-Filter (cont.)

- ▶ Bei zufällig gewählten Stellgrößen kann  $u_t$  daher auch in den Bedingungen für  $p(x_{t-1}|z_{1:t-1}, u_{1:t})$  weggelassen werden
- ▶ Es ergibt sich mit

$$\overline{bel}(x_t) = \int p(x_t|x_{t-1}, u_t) p(x_{t-1}|z_{1:t-1}, u_{1:t-1}) dx_{t-1}$$

die 2. Zeile des Bayes-Filter-Algorithmus



## Mathematische Herleitung des Bayes-Filter (cont.)

- ▶ Für konkrete Implementierungen des Bayes-Filter-Algorithmus werden drei Wahrscheinlichkeitsverteilungen benötigt:
  - ▶ der initiale *belief*  $p(x_0)$
  - ▶ die Wahrscheinlichkeit der Messungen  $p(z_t|x_t)$
  - ▶ die Zustandsübergangswahrscheinlichkeiten  $p(x_t|u_t, x_{t-1})$



## Markov-Annahme

- ▶ Die Annahme, dass ein Zustand komplett ist, wird **Markov-Annahme** (engl. *Markov assumption*) genannt
- ▶ Die Annahme fordert, dass vergangene und zukünftige Daten unabhängig sind, wenn man den aktuellen Zustand  $x_t$  kennt



## Markov-Annahme (cont.)

- ▶ Das folgende Beispiel soll verdeutlichen, wie hart diese Annahme ist:
  - ▶ Zur Lokalisierung mobiler Roboter werden Bayes-Filter eingesetzt
  - ▶ Dabei ist  $x_t$  die *Pose* des Roboters mit Bezug auf eine feste Karte
  - ▶ Es gibt Effekte die die Sensormessungen systematisch verfälschen und damit die Markov-Annahme zunichte machen:
    - ▶ Einfluss sich bewegender Personen auf die Sensormessungen
    - ▶ Ungenauigkeiten in den probabilistischen Modellen  $p(z_t|x_t)$  und  $p(x_t|u_t, x_{t-1})$
    - ▶ Rundungsfehler, wenn Näherungen für die Repräsentation des *beliefs* verwendet werden
    - ▶ Variablen innerhalb der Software, die mehrere Stellgrößen beeinflussen



## Markov-Annahme (cont.)

- ▶ Einige dieser Variablen könnten im Zustand berücksichtigt werden, werden aber oft fallen gelassen, um den rechnerischen Aufwand zu verringern
- ▶ In der Praxis sind Bayes-Filter erstaunlich robust gegen die Verletzung der Markov-Annahme



## Darstellung und Berechnung

- ▶ Bayes-Filter können auf unterschiedliche Weise implementiert werden
- ▶ Die Techniken basieren auf unterschiedlichen Annahmen über die Wahrscheinlichkeiten für die Messungen, die Zustandsübergänge und den *belief*
- ▶ Die Algorithmen besitzen dadurch unterschiedliche rechnerische Eigenschaften
- ▶ In den meisten Fällen müssen die *beliefs* angenähert werden
- ▶ Dies hat Auswirkungen auf die Komplexität der Algorithmen
- ▶ Keine der verschiedenen Techniken ist generell zu bevorzugen



## Effizienz

- ▶ Einige Näherungen bedingen polynomiale Laufzeiten in Abhängigkeit von der Dimension des Zustands (z.B. Kalman-Filter)
- ▶ Einige haben exponentielle Laufzeiten
- ▶ Partikel-basierte Verfahren haben eine Laufzeit, die von der gewünschten Genauigkeit abhängt



## Genauigkeit

- ▶ Einige Näherungen eignen sich besser um eine Reihe von Wahrscheinlichkeitsverteilungen anzunähern
- ▶ Beispielsweise eignen sich Normalverteilungen für uni-modale Wahrscheinlichkeitsverteilungen
- ▶ Histogramme können multimodale Verteilungen besser annähern, aber auf Kosten der Genauigkeit
- ▶ Partikel-Techniken können eine Vielzahl von Verteilungen annähern, wodurch allerdings die Anzahl der Partikel sehr groß werden kann



## Einfachheit der Implementierung

- ▶ Abhängig von der Form der Verteilungen kann die Implementierung der Verfahren aufwändig sein
- ▶ Weil Partikel-Techniken meist sehr einfach für nicht-lineare Systeme implementiert werden können, sind sie zurzeit sehr populär

## Zusammenfassung

- ▶ Die Interaktion zwischen einem Roboter und dessen Umgebung wird modelliert als gekoppeltes dynamisches System. Der Roboter setzt dazu Stellgrößen um die Umgebung zu manipulieren und nimmt die Umgebung über Sensormessungen wahr.
- ▶ Die Dynamiken werden charakterisiert durch zwei wahrscheinlichkeitstheoretische Gesetze
  - ▶ die Wahrscheinlichkeitsverteilungen für den Zustandsübergang
  - ▶ die  $p(z_t | x_t, u_t)$  die Messungen

Erstere beschreibt wie der Zustand sich mit der Zeit ändert, die Zweite, wie Messungen wahrgenommen werden.



## Zusammenfassung (cont.)

- ▶ Der *belief* ist die A-Posteriori-Wahrscheinlichkeit des Zustands gegeben alle bisherigen Messungen und Stellgrößen. Der *Bayes-Filter* ist ein Algorithmus um den *belief* zu berechnen. Er ist rekursiv, d.h. der *belief* zum Zeitpunkt  $t$  wird aus dem *belief* zum Zeitpunkt  $t-1$  berechnet.
- ▶ Der Bayes-Filter macht eine *Markov-Annahme*, d.h. der Zustand ist eine komplette Zusammenfassung der Vergangenheit.  
Diese Annahme trifft in der Praxis meist nicht zu.



## Zusammenfassung (cont.)


- ▶ Der Bayes-Filter kann üblicherweise nicht direkt angewandt werden. Implementierungen können evaluiert werden anhand verschiedener Kriterien wie Genauigkeit, Effizienz und Einfachheit.



# Markov-Lokalisierung

- ▶ Wahrscheinlichkeitstheoretische Lokalisierungsverfahren sind Varianten des Bayes-Filters
- ▶ Die direkte Anwendung des Bayes-Filters wird **Markov-Lokalisierung** genannt
- ▶ Markov-Lokalisierungen benötigen zusätzlich eine Karte der Umgebung
- ▶ Die Karte spielt eine Rolle im Messmodell (teilweise auch im Bewegungsmodell)
- ▶ Markov-Lokalisierung wird verwendet für
  - ▶ globale Lokalisierung
  - ▶ Positions-Tracking
  - ▶ das Kidnapped-Robot-Problem

# Markov-Lokalisierung (cont.)






## Extended Kalman Filter Lokalisierung

- ▶ Ein besonderer Fall der Markov-Lokalisierung ist der **extended Kalman filter localisation** Algorithmus (oder EKF-Lokalisierung)
- ▶ Die EKF-Lokalisierung repräsentiert den *belief*  $bel(x_t)$  durch den Mittelwert  $\mu_t$  und die Kovarianzmatrix  $\Sigma_t$
- ▶ Die Karte ist dabei eine Sammlung von Merkmalen
- ▶ Der Roboter misst die Entfernung und Richtung einiger Merkmale in seiner Nähe

## Extended Kalman Filter Lokalisierung (cont.)





## Grid-Lokalisierung



- ▶ **Grid-Lokalisierung** approximiert den *belief* durch einen **Histogram-Filter** über die Grid-Dekomposition des Zustandsraumes
- ▶ Dieser diskrete Bayes-Filter verwaltet eine Menge diskreter Wahrscheinlichkeitswerte:

$$belx_t = \{p_{k,t}\}$$

wobei jedes  $p_{k,t}$  zu einer Grid-Zelle  $x_k$  gehört

- ▶ Typische Werte für die Zellengröße in der Praxis sind 15cm Kantenlänge und 5° Winkelauflösung

# Grid-Lokalisierung (cont.)







## Monte-Carlo-Lokalisierung

- ▶ **Monte-Carlo-Lokalisierung** (MCL) approximiert den *belief* durch eine Menge von Partikeln
- ▶ Sehr populär
- ▶ Mit MCL können nahezu beliebige Verteilungsfunktionen angenähert werden
- ▶ Es können multimodale und unimodale Verteilungen approximiert und übergangslos zwischen ihnen gewechselt werden
- ▶ Eine höhere Anzahl von Partikeln erhöht die Genauigkeit

# Monte-Carlo-Lokalisierung (cont.)





[TBF05] Sebastian Thrun, Wolfram Burgard, Dieter Fox,  
Ronald C. Arkin (Hrsg.):  
*Probabilistic Robotics*.  
MIT Press; Cambridge, Massachusetts, 2005  
(Intelligent Robotics and Autonomous Agents). –  
Kapitel 2