

6 Navigation für autonome mobile Roboter – Grundlagen

Navigation für autonome mobile Roboter

- Problemstellung
- Bezeichnungen
- Bayes Filter
- Sensormodell
- Bewegungsmodell
- Kartenerstellung – Umgebungsmodellierung
- Selbstlokalisierung
- Kalman Filter
- SLAM – Simultaneous Localization and Mapping
- Pfadplanung

6.1 Problemstellung

Navigation

- ***bekannte Umgebung***, auch keine Veränderung der Umgebung während der Fahrt
- ***unbekannte Umgebung***

Statische und dynamische Umgebungen

- Statisch
 - Nur der Zustand des Roboters innerhalb der Umgebung ändert sich
 - Karte ist wahre Umgebung
- Dynamisch
 - Objekte ändern ihre Lage oder ihren Zustand (Verrücken von Tischen, Tür offen oder geschlossen)
 - Auftreten neuer Objekte (Personen, andere Roboter)

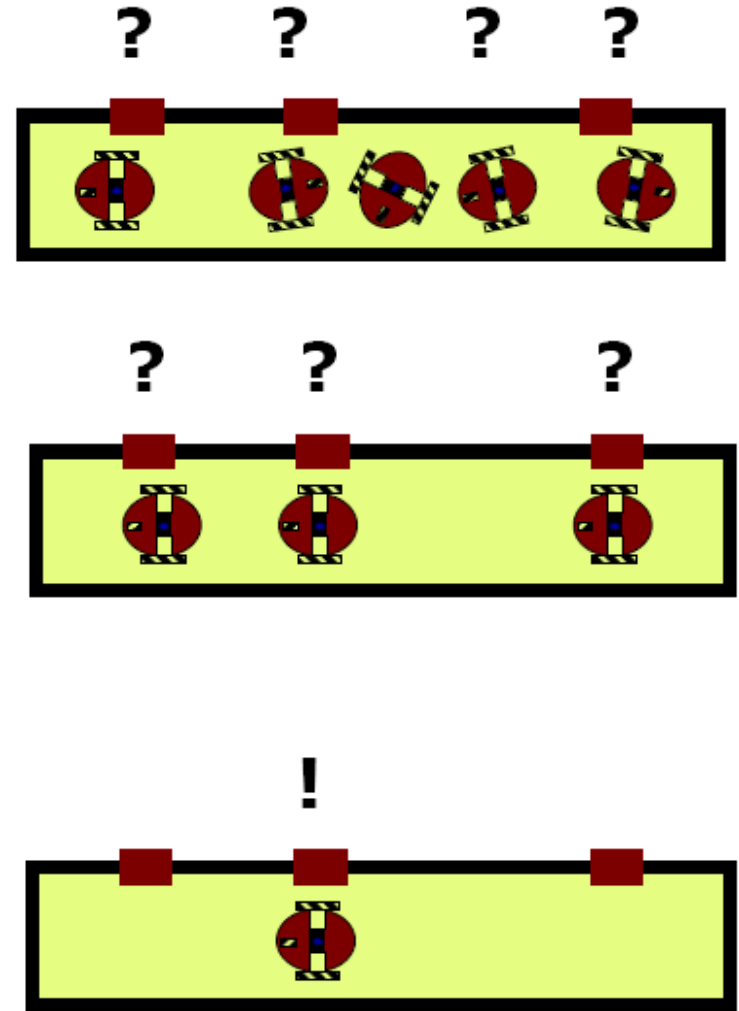
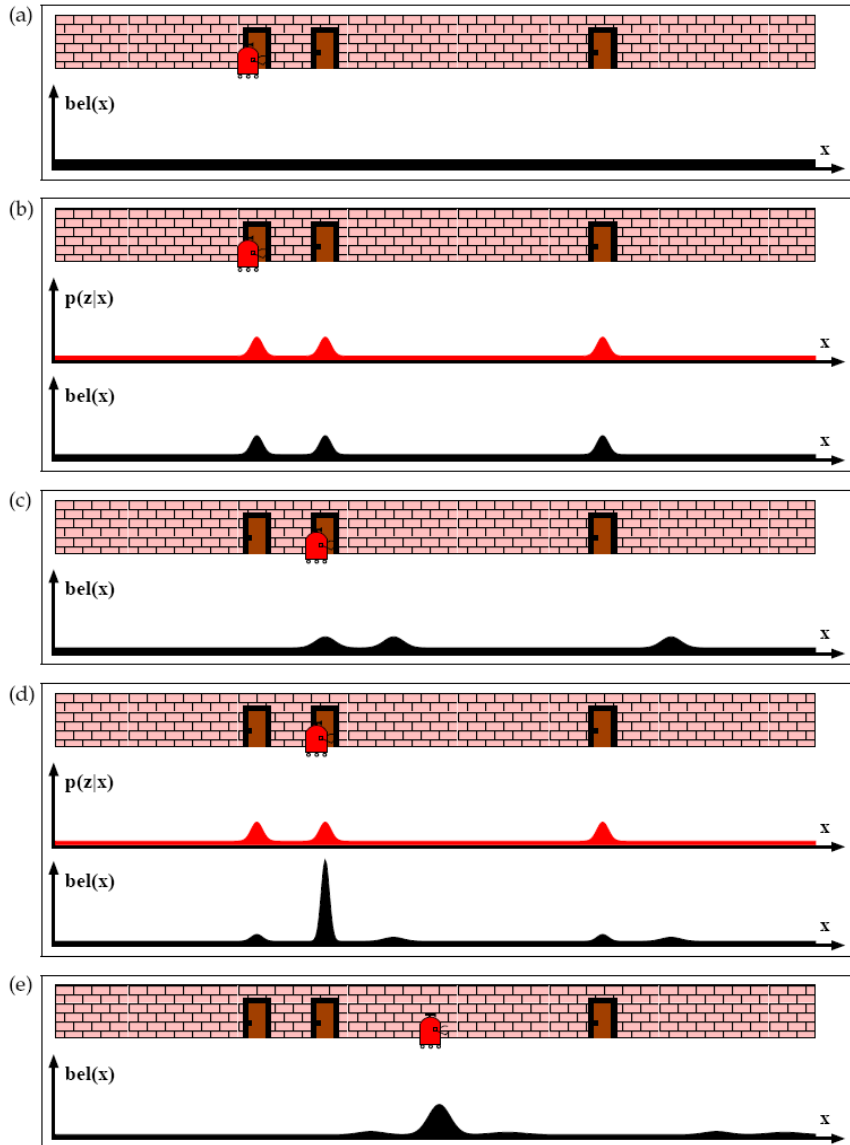
Navigationsaufgaben

- ***Selbstlokalisierung*** – Wo bin ich?
- ***Kartenerstellung*** – Umgebungsmodellierung
- ***Pfad(Weg)planung*** – Wie gelange ich zum Ziel?

Selbstlokalisierung

- Position und Orientierung innerhalb der Umgebung finden
- mit Hilfe von Sensoren
 - Odometrie (Radencoder, Kompass)
 - relative Position zu Objekten (Infrarot, Ultraschall, Laser, Kamera)
 - absolute Position (GPS)
- Selbstlokalisierung und Kartenerstellung bedingen sich gegenseitig (SLAM)

Markov Lokalisation



Lokale und globale Selbstlokalisierung

- Lokal
 - Ausgangsposition des Roboters ist bekannt
- Global
 - Position des Roboters ohne Kenntnis der Ausgangsposition schätzen
- Kidnaped robot
 - Ein Roboter lokalisiert sich erfolgreich selbst wenn er ohne sein Wissen zwischenzeitlich an einen unbekanntem Ort gebracht wird
 - Robuste Relokalisation obwohl der Roboter irrtümlicherweise zu wissen meint wo er sich befindet

Passive und aktive Selbstlokalisierung

- Passiv
 - Bewegung des Roboters und Orientierung der Sensoren (Kamerablickrichtung) werden nicht beeinflusst
- Aktiv
 - Roboter fährt gezielt bestimmte Orte an
 - Orientierung der Sensoren werden aktiv gewählt

Karte

- Geometrisch
 - 2D, 3D
 - Zellen (besetzt, frei)
- Topologisch
 - Knoten (Landmarken)
 - Kanten (Verbindungen)

Wegplanung

- kollisionsfreie Wege von einer Start- zu einer Zielposition finden
- Diese Wege soll der Roboter dann in der realen Welt abfahren.
- Erfüllung gewisser Optimalitätskriterien

Wegplanung - Verfahren

- geometrische Wegplanung (bekannte Umgebung)
 - Sichtbarkeitsgraph (Weglänge wird minimiert)
 - Voronoi-Diagramm (Abstand zu Hindernissen wird maximiert)
- lokale Bewegungssteuerung (Umgebung kann sich verändern)
- Reinforcement Learning (Umgebung unbekannt)
- Optimierungsverfahren

6.2 Bezeichnungen

6.2.1

Wahrscheinlichkeitsverteilungen

Erwartungswert - Mittelwert

X - Zufallsvariable

$$p(x_i) = p(X = x_i)$$

$$E[X] = \mu = \mu_X = \sum_i x_i \cdot p(x_i) \quad (X \text{ - diskret})$$

Eigenschaften:

$$E[a \cdot X + b] = a \cdot E[X] + b$$

$$E[X + Y] = E[X] + E[Y]$$

$$E[g(X)] = \sum_i g(x_i) \cdot p(x_i)$$

$$E[X^n] = \sum_i x_i^n \cdot p(x_i) \text{ - Momente von } X$$

$$E[X \cdot Y] = E[X] \cdot E[Y] \text{ - } X \text{ und } Y \text{ unabhängig}$$

Verteilungsfunktion (stetig) (distribution function continuous)

$$F : \mathbb{R} \rightarrow \mathbb{R}$$

Verteilungsfunktion bezüglich p

$$F(x) = \int_{-\infty}^x f(t) dt$$

Dichtefunktion

$$F(x) = p(]-\infty, x]) = p(X \leq x)$$

Dichtefunktion (density function)

$$f : R \rightarrow R$$

f ist integrierbar

$$f(t) \geq 0, t \in R$$

$$\int_{-\infty}^{+\infty} f(t) dt = 1$$

$$F(x) = \int_{-\infty}^x f(t) dt$$

$$f(x_0) = \left. \frac{dF(x)}{dx} \right|_{x=x_0}$$

$$F(x) = p(]-\infty, x])$$

Eigenschaften

$$F(b) - F(a) = \int_a^b f(t) dt = p(a < X \leq b)$$

$$p(X > c) = 1 - F(c) = \int_c^{\infty} f(t) dt$$

$$p(X = x_0) = 0, \quad x_0 \in R$$

$$p(x_0 \leq X \leq x_0 + \Delta x_0) = f(x_0) \cdot \Delta x_0 \quad x_0 \text{ - Stetigkeitspunkt von } f$$

Varianz

$$\text{Var}(X) = \sigma^2 = E[(X - \mu)^2] = E[X^2] - \mu^2$$

$$\sigma = \sqrt{\text{Var}(X)} \text{ - Standardabweichung}$$

Eigenschaft: $\text{Var}(a \cdot X + b) = a^2 \cdot \text{Var}(X)$

Erwartungswert und Varianz (expectation – variance)

$$\mu = E(X) = \int_{-\infty}^{+\infty} t \cdot f(t) \cdot dt$$

$$\sigma^2 = Var(X) = \int_{-\infty}^{+\infty} (t - \mu)^2 \cdot f(t) \cdot dt$$

Kovarianz

$$\text{Cov}(X, Y) = E[(X - \mu_X)(Y - \mu_Y)] = E[X \cdot Y] - \mu_X \cdot \mu_Y$$

Eigenschaften:

$$\text{Cov}(X, Y) = \text{Cov}(Y, X)$$

$$\text{Cov}(X, X) = \text{Var}(X)$$

$\text{Cov}(X, Y) = 0$ - X und Y unabhängig

$$\text{Cov}(X + Z, Y) = \text{Cov}(X, Y) + \text{Cov}(Z, Y)$$

$$\text{Cov}\left(\sum_i X_i, Y\right) = \sum_i \text{Cov}(X_i, Y)$$

$$\text{Var}(X + Y) = \text{Var}(X) + \text{Var}(Y) + 2 \cdot \text{Cov}(X, Y)$$

$$\text{Var}\left(\sum_i X_i\right) = \sum_i \text{Var}(X_i) + \sum_i \sum_{j \neq i} \text{Cov}(X_i, X_j)$$

Korrelation

$$\text{Corr}(X, Y) = \frac{\text{Cov}(X, Y)}{\sqrt{\text{Var}(X) \cdot \text{Var}(Y)}} \in (-1, 1)$$

Kovarianzmatrix

$$\sigma_{ij} = \sigma_{ji} = \text{Cov}(X_i, X_j)$$

$$\sigma_{ii} = \sigma_i^2 = \text{Var}(X_i)$$

$$\Sigma = \begin{pmatrix} \sigma_1^2 & \sigma_{12} & \cdots & \sigma_{1n} \\ \sigma_{21} & \sigma_2^2 & \cdots & \sigma_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{n1} & \sigma_{n2} & \cdots & \sigma_n^2 \end{pmatrix}$$

Normalverteilung (Gauß) - skalar


$$N(x; \mu, \sigma^2) = f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \cdot e^{-\frac{1}{2} \cdot \frac{(x-\mu)^2}{\sigma^2}}$$

$$E[X] = \mu$$

Erwartungswert, mean

$$\text{Var}(X) = \sigma^2 = \text{Cov}(X, X)$$

Varianz, variance



σ

Standardabweichung

Normalverteilung – Gaußverteilung (normal Gauss distribution Gaussian distribution)

$$f(x) = N(x; \mu, \sigma^2) = \frac{1}{\sigma \cdot \sqrt{2\pi}} \cdot e^{-\frac{1}{2} \cdot \left(\frac{x-\mu}{\sigma}\right)^2} \quad \sigma > 0$$

$$N(x; 0, 1) = \frac{1}{\sqrt{2\pi}} \cdot e^{-\frac{1}{2}x^2}$$

$$\Phi(x) = p(X < x) = \frac{1}{\sqrt{2\pi}} \cdot \int_{-\infty}^x e^{-\frac{1}{2}t^2} dt$$

$$\Phi(-x) = 1 - \Phi(x) \quad \Phi(-x \leq X \leq x) = 2\Phi(x) - 1$$

Normalverteilung – Gaußverteilung

$$\Phi(-1 \leq X \leq 1) = \Phi(1) - \Phi(-1) = 2\Phi(1) - 1 = 0,683$$

$$\Phi(-2 \leq X \leq 2) = \Phi(2) - \Phi(-2) = 2\Phi(2) - 1 = 0,954$$

$$\Phi(-3 \leq X \leq 3) = \Phi(3) - \Phi(-3) = 2\Phi(3) - 1 = 0,997$$

Normalverteilung (Gauß) - skalar

$$N(x; \mu, \sigma^2) = f(x) = (2\pi\sigma^2)^{-\frac{1}{2}} \cdot e^{-\frac{1}{2} \frac{(x-\mu)^2}{\sigma^2}}$$



$$x = a$$

$$\mu = 0$$

$$\sigma^2 = b^2$$

$$\text{prob}(a, b) = \frac{1}{\sqrt{2\pi b^2}} \cdot e^{-\frac{1}{2} \frac{a^2}{b^2}}$$

Fehler mit Normalverteilung

$$\text{prob}(a, b) = \varepsilon_b(a) = \frac{1}{\sqrt{2\pi b^2}} \cdot e^{-\frac{1}{2} \cdot \frac{a^2}{b^2}}$$

$$\hat{x} = x + N(0, \sigma^2)$$

$$\hat{x} = x + \varepsilon_\sigma$$



(Schreibweisen)

realer Wert

exakter Wert

$$x_{\text{err}} = x - \hat{x}$$

$$f(x_{\text{err}}) = \varepsilon_\sigma(x - \hat{x})$$

Fehler (normalverteilte Zufallsvariable)

Normalverteilung (Gauß) - allgemein

$$N(\mathbf{x}; \mu, \Sigma) = f(\mathbf{x}) = \det(2\pi\Sigma)^{-\frac{1}{2}} \cdot e^{-\frac{1}{2}(\mathbf{x}-\mu)^T \cdot \Sigma^{-1} \cdot (\mathbf{x}-\mu)}$$

$$\mathbf{x}^T = (x_1, x_2, \dots, x_n)$$

$$E[X] = \mu \quad \text{Erwartungswert, mean}$$

$$\mu^T = (\mu_1, \mu_2, \dots, \mu_n)$$

$$\Sigma = \begin{pmatrix} \sigma_1^2 & \sigma_{12} & \cdots & \sigma_{1n} \\ \sigma_{21} & \sigma_2^2 & \cdots & \sigma_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{n1} & \sigma_{n2} & \cdots & \sigma_n^2 \end{pmatrix}$$

Covariance matrix

symmetrisch, positivsemidefinit


(für alle \mathbf{x} gilt : $\mathbf{x}^T \Sigma \mathbf{x} \geq 0$)

Normalverteilung (Gauß) – n=2

$$N(\mathbf{x}; \mu, \Sigma) = f(\mathbf{x}) = \det(2\pi\Sigma)^{-\frac{1}{2}} \cdot e^{-\frac{1}{2}(\mathbf{x}-\mu)^T \cdot \Sigma^{-1} \cdot (\mathbf{x}-\mu)}$$

$$N(\mathbf{x}; \mu, \Sigma) = f(\mathbf{x}) = \frac{1}{2\pi \cdot \sqrt{\det(\Sigma)}} \cdot e^{-\frac{1}{2}(\mathbf{x}-\mu)^T \cdot \Sigma^{-1} \cdot (\mathbf{x}-\mu)}$$

$$\Sigma = \begin{pmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{pmatrix} \quad |\rho| < 1$$



Normalverteilung (Gauß) - Spezialfall

$$N(\mathbf{x}; \mu, \Sigma) = f(\mathbf{x}) = \det(2\pi\Sigma)^{-\frac{1}{2}} \cdot e^{-\frac{1}{2}(\mathbf{x}-\mu)^T \cdot \Sigma^{-1} \cdot (\mathbf{x}-\mu)}$$

$$\Sigma = \begin{pmatrix} \sigma_1^2 & 0 & \dots & 0 \\ 0 & \sigma_2^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma_n^2 \end{pmatrix}$$

$$\mathbf{x}^T = (x_1, x_2, \dots, x_n)$$

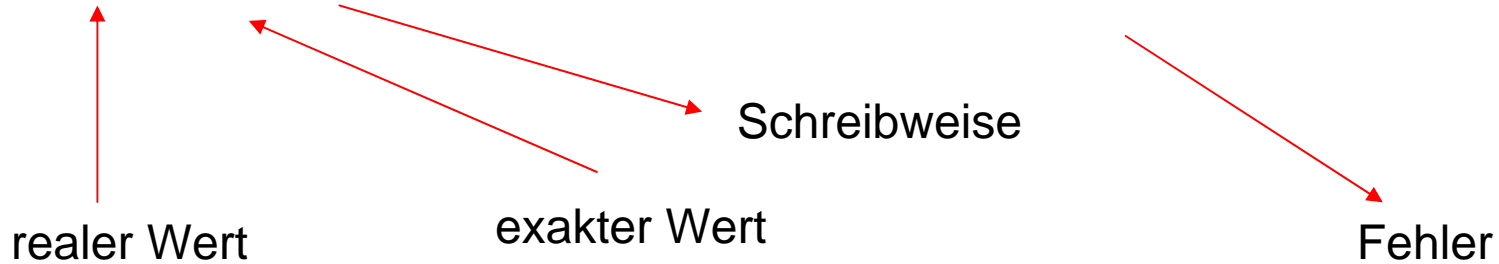
Komponenten unabhängig

$$f(\mathbf{x}) = \frac{1}{(2\pi)^{\frac{n}{2}} \cdot \prod_{i=1}^n \sigma_i} \cdot e^{-\frac{1}{2} \sum_{i=1}^n \left(\frac{x_i - \mu_i}{\sigma_i} \right)^2}$$

Fehler mit Normalverteilung

$$\hat{\mathbf{x}} = \mathbf{x} + N(\mathbf{x}; \mathbf{0}, \Sigma)$$

$$\mathbf{x}_{\text{err}} = \mathbf{x} - \hat{\mathbf{x}}$$



$$f(\mathbf{x}_{\text{err}}) = N(\mathbf{x}_{\text{err}}; \mathbf{0}, \Sigma)$$


6.2.2 Zustand, Sensordaten, Aktion

Zustand, Sensordaten, Aktion

Zustand x_t

Sensordaten z_t $z_{t_1:t_2} = z_{t_1}, z_{t_1+1}, \dots, z_{t_2}$

Aktion u_t $u_{t_1:t_2} = u_{t_1}, u_{t_1+1}, \dots, u_{t_2}$




X_t, Z_t, U_t - Zufallsvariablen mit Werten x_t, z_t, u_t, \dots

$$p(x_t) = p(X_t = x_t)$$

Zustände

Zeit (diskret)

$$t = 0, 1, 2, \dots$$



diskret oder stetig

Position des Roboters (6 Werte)
Geschwindigkeit
Gelenkparameter
Objekte der Welt



$$\mathbf{x}_t = (x, y, \theta)^T$$

X_t - Zufallsvariable mit Werten x_t

$$p(x_t) = p(X_t = x_t)$$

$$\sum_{x_t} P(X_t = x_t) = 1$$

Sensordaten

Sensordaten Z_t


$$Z_{t_1:t_2} = Z_{t_1}, Z_{t_1+1}, \dots, Z_{t_2}$$

Z_t - Zufallsvariable mit Werten z_t

$$p(z_t) = p(Z_t = z_t)$$

$$\sum_{z_t} P(Z_t = z_t) = 1$$

Aktionen




$$u_{t_1:t_2} = u_{t_1}, u_{t_1+1}, \dots, u_{t_2}$$

U_t - Zufallsvariable mit Werten u_t

$$p(u_t) = p(U_t = u_t)$$

$$\sum_{u_t} P(U_t = u_t) = 1$$

HMM – Hidden Markov Modell



Annahmen

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



Übergangswahrscheinlichkeit

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



Auftrittswahrscheinlichkeit

belief

$$\text{bel}(x_t) = p(x_t \mid z_{1:t}, u_{1:t})$$

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

$$\overline{\text{bel}}(x_1) = p(x_1 \mid u_1)$$

6.2.3 Karte - Umweltbeschreibung

Karte

$$m = \{m_1, \dots, m_N\}$$

$$1 \leq j \leq N$$

Menge von Objekten (Landmarken) in der Umwelt
zusammen mit ihren Eigenschaften

feature-based

j - Index eines Merkmals

m_j Eigenschaften und Ortskoordinate des Merkmals

location-based

j – korrespondiert mit Ortkoordinaten x,y

$$m_j \rightarrow m_{x,y}$$

Eigenschaft des Punktes (x,y)

Landmarken - Feature-based

Torpfosten

Fensterbrett

Baumstamm

Gebäudeecken


$$m_j = (m_{j,x}, m_{j,y}, s_j)^T$$

Ort

Signature

Vektor von numerischen Werten (Höhe, Farbe)

Occupancy grid map - location-based



Vorteil: günstig für die Wegplanung