

Umwelt- und Verhaltensmodellierung langzeitautonomer Serviceroboter

Environment and Task Modeling of
Long-Term-Autonomous Service Robots

Promotionsvortrag
Garbsen, 15. Februar 2024

Marvin Stüde, M.Sc.





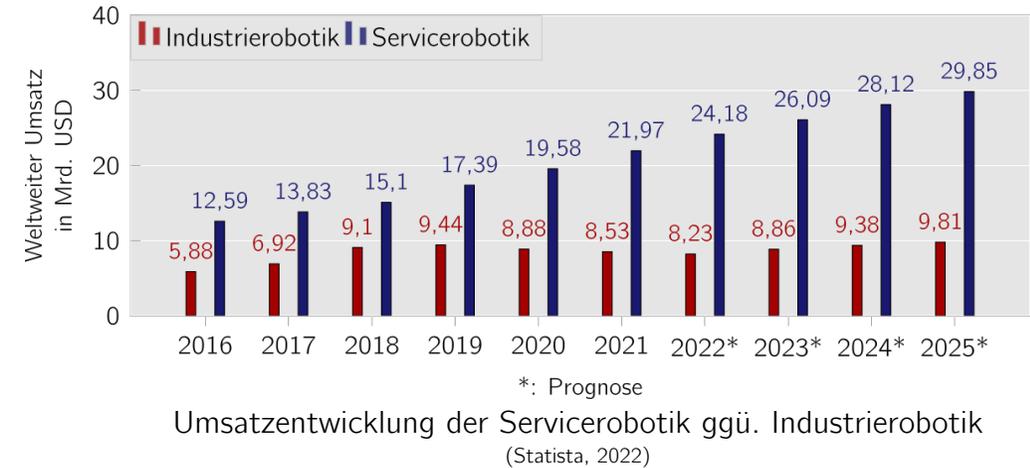
Wer besitzt ein solches Gerät

Quelle: www.allround-pc.com, 2021

Motivation

Serviceroboter

- Serviceroboter *führen Dienstleistungen für Menschen oder Anlagen [...] aus und weisen einen Autonomiegrad auf* (ISO 8373)
- Ausgenommen: Industrielle Automatisierungsanwendungen



Herausforderungen (Ingrand et al. 2017, Kunze et al. 2018)

- Vielfältige, dynamische Umgebungen
- *Offene Welt*
- Große Aufgabenvielfalt, wechselnde Aufgabenanforderungen
- Eingeschränkte Wahrnehmung



Diverse Serviceroboter in ihrer Einsatzumgebung

Langzeitautonomie?

Quelle: reddit.com/u/red_nibia, 2023



Quelle: Mein Staubsaugerroboter (Dobby), vor 13 Tagen

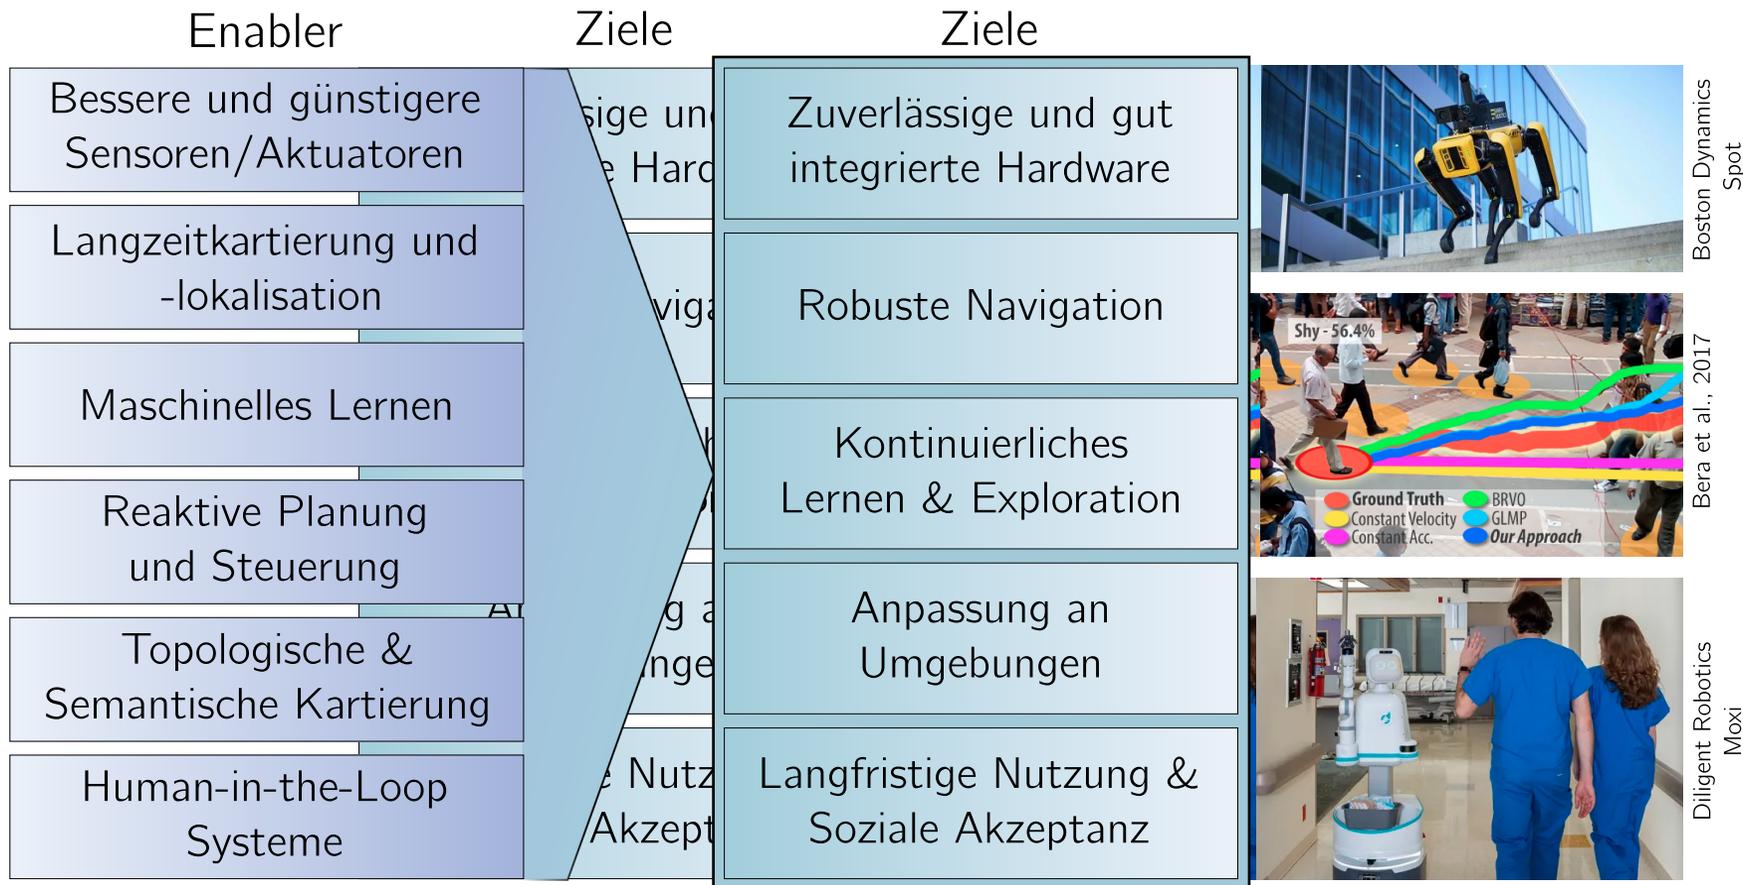


Bei wem treten solche Probleme nicht auf

Langzeitautonomie in der Servicerobotik

Langzeitautonomie (Long-Term Autonomy, LTA)

- Einsätze von Tagen, Wochen, Monaten bis Jahren
- Dynamische Umgebungen, langfristige Änderungen



Umgebungen: Dynamisch und Heterogen



Zeitliche Änderungen



Variierende menschliche Aktivität



Variierende Charakteristik



Unpassierbare Bereiche

Forschungsfrage 1

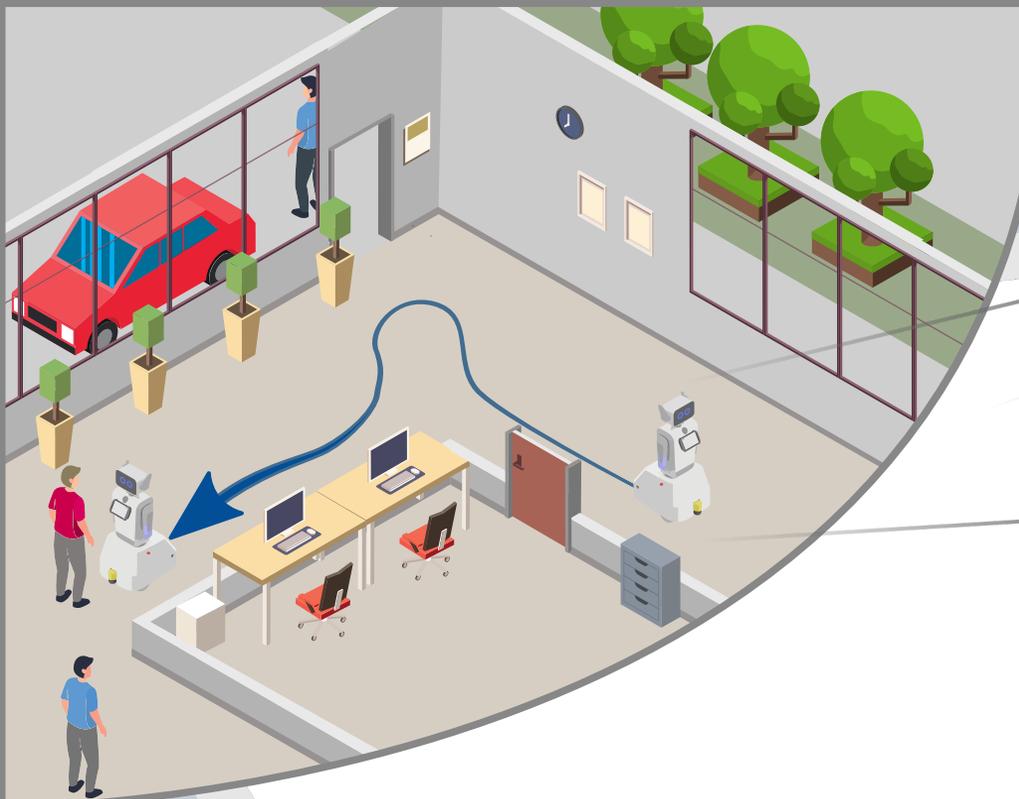
Wie kann die **Robustheit** aktueller **SLAM Methoden** in **heterogenen dynamischen Umgebungen** verbessert werden?

Forschungsfrage 2

Wie kann **menschliche Aktivität** räumlich-zeitlich basierend auf **Langzeitbeobachtungen mobiler Roboter** modelliert werden?

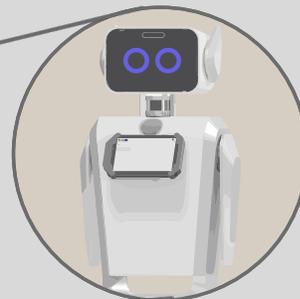
Forschungsfrage 3

Wie können **Modelle menschlicher Aktivität** in autonome **Steuerungssysteme** integriert und zur **Verbesserung der Langzeitautonomie** genutzt werden?



Versuchsstand

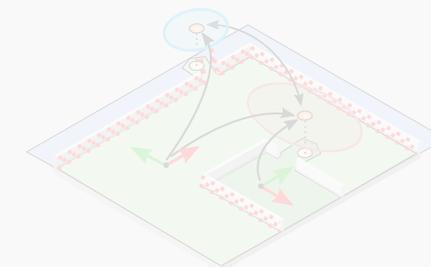
Robotersystem



Messungen

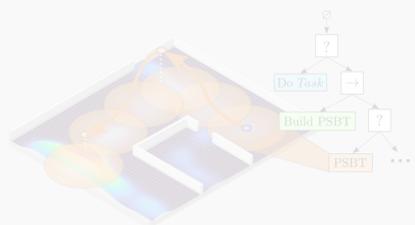
Kapitel 1

SLAM in dynamischen & heterogenen Umgebungen



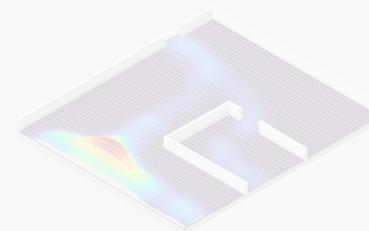
Kapitel 3

Steuerungssystem zur Langzeitautonomie



Kapitel 2

Modellierung des Personenaufkommens



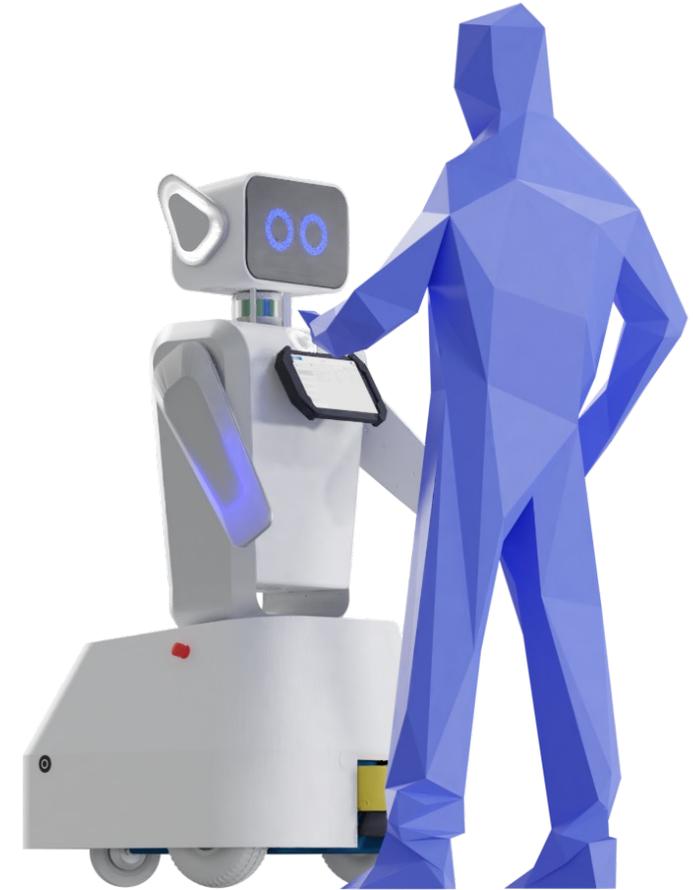
Roboterplattform für langzeitautonome Anwendungen

Heterogene Umgebungen

- Nutzung **inner-** und **außerhalb** von Gebäuden
 - Multimodale Sensorik, schützendes Design
- Große **Schleifenschlüsse** möglich, flüssige **Navigation** erforderlich
 - Robuste Odometrie
- Kontinuierlicher Betrieb über mehrere Stunden

Wissenschaftlicher Beitrag

- Open Source System für langzeitautonome Indoor-/Outdooranwendungen
- Lessons Learned in [1]



Mobiler sozialer Roboter für langzeitautonome Anwendungen

[1] Marvin Stüde, Konrad Westermann, Moritz Schappler, und Svenja Spindeldreier (2021b). "Sobi: An Interactive Social Service Robot for Long-Term Autonomy in Open Environments". In: *10th European Conference on Mobile Robotics (ECMR)*



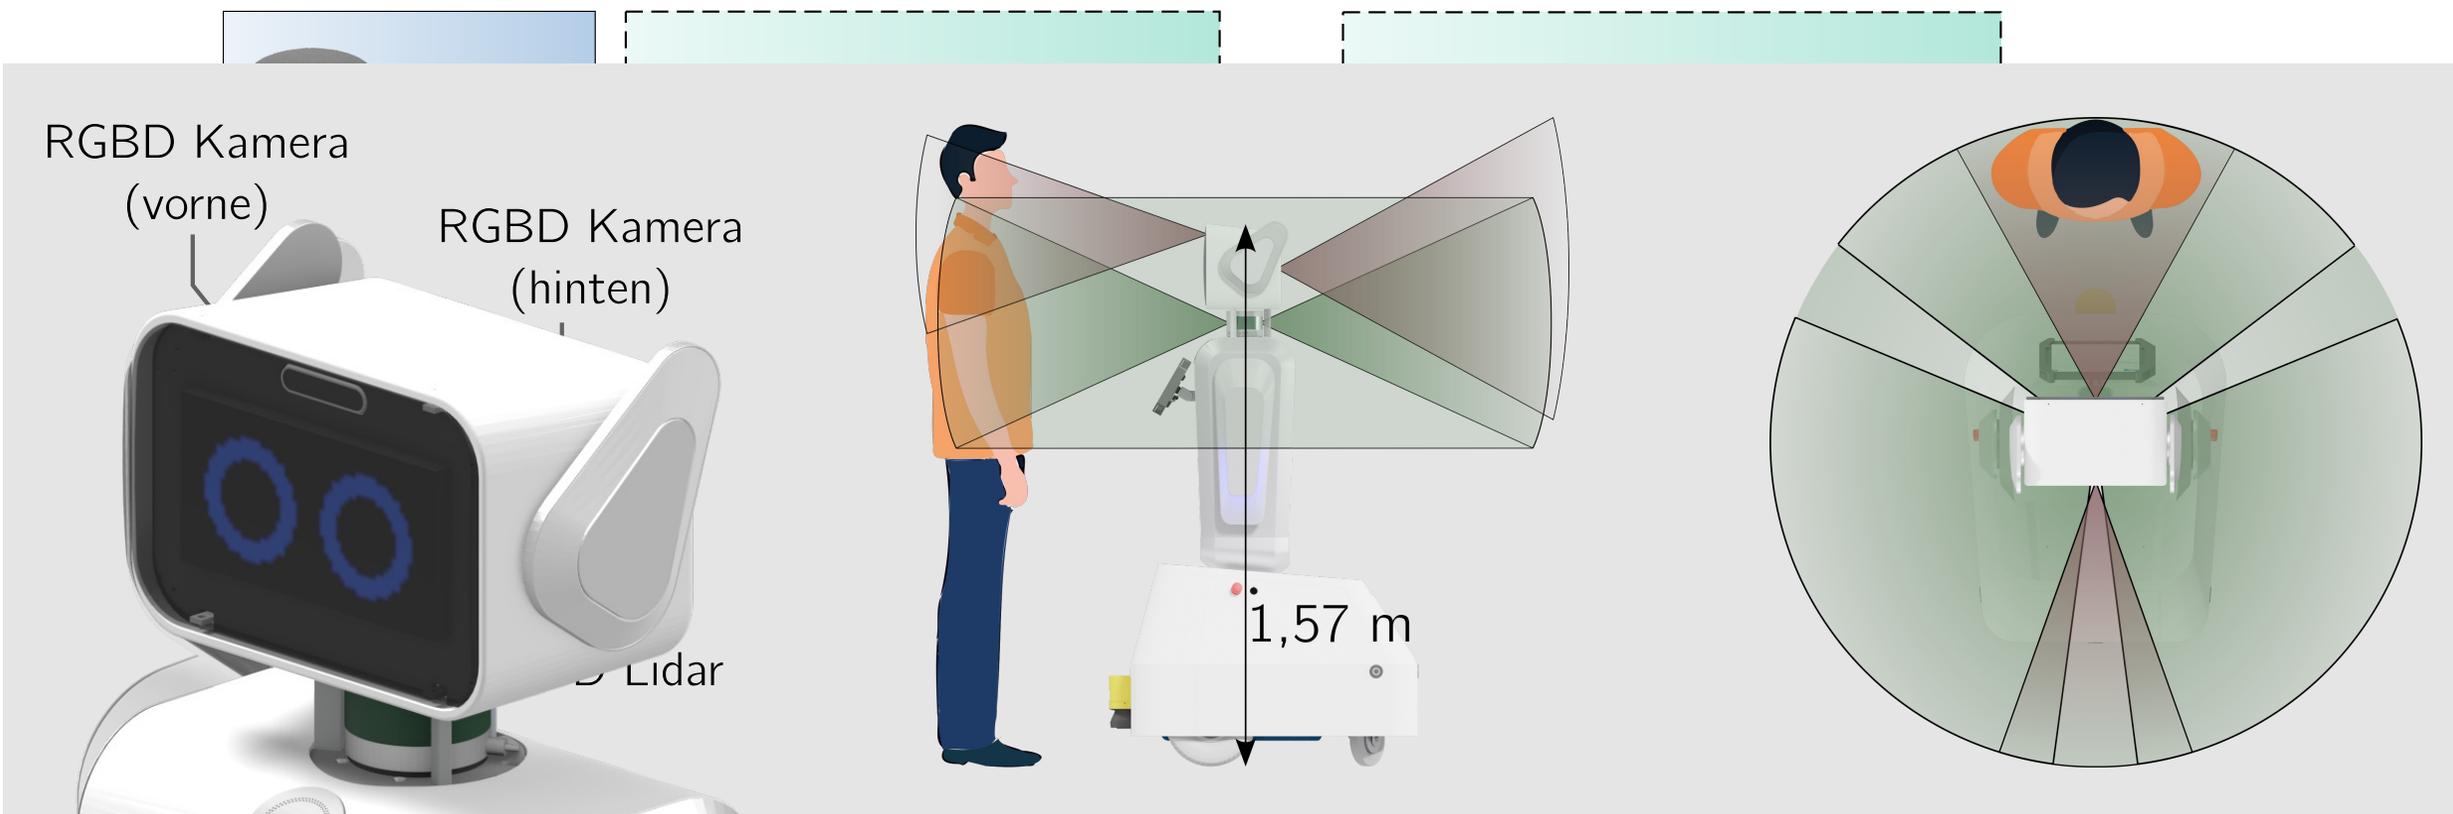
Perzeption

Sensorischer Aufbau

- RGBD Kameras und 3D-Lidar zur Perzeption
- Unterschiedliches Sichtfeld/Verdeckungen

Pipeline zur Personenperzeption

- Multimodale **Personendetektion** und **-tracking**
- Kombiniert diverse Methoden aus dem Stand der Technik



(1) Redmon et al., 2018, (2) Bogoslavskyi et al., 2016, (3) Yan et al., 2017, (4) Linder et al., 2016

Personendetektion und -tracking

Evaluation

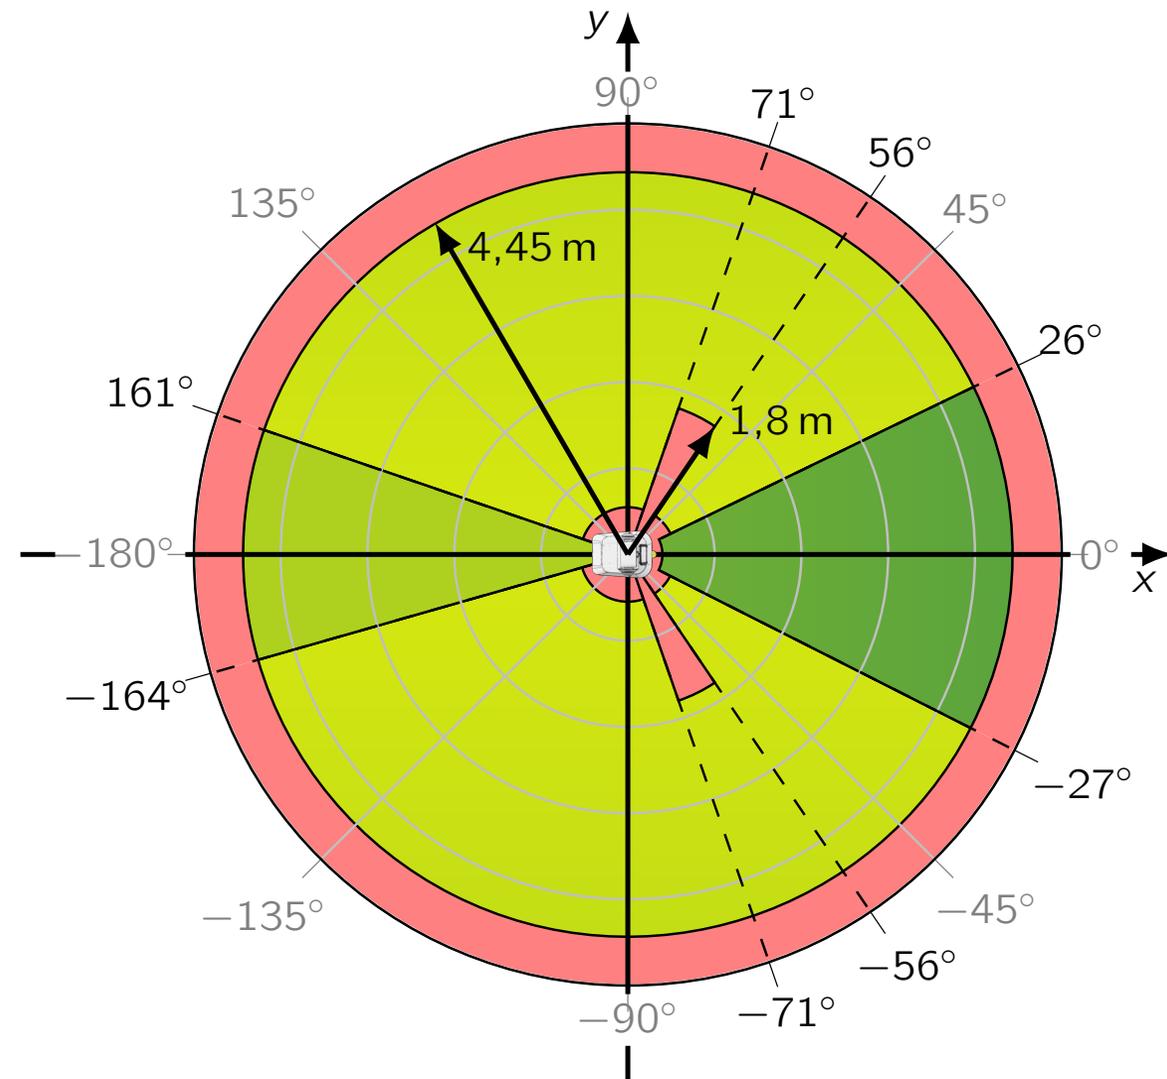
- **Wo** und **wie gut** können Personen getrackt werden?
- Ein bis zwei Personen zeitgleich
- Ground Truth über optisches Lokalisationssystem
- **Multiple Object Tracking Accuracy**

$$MOTA = 1 - \frac{\sum_t (M_t + FP_t + MME_t)}{\sum_t GT_t}$$

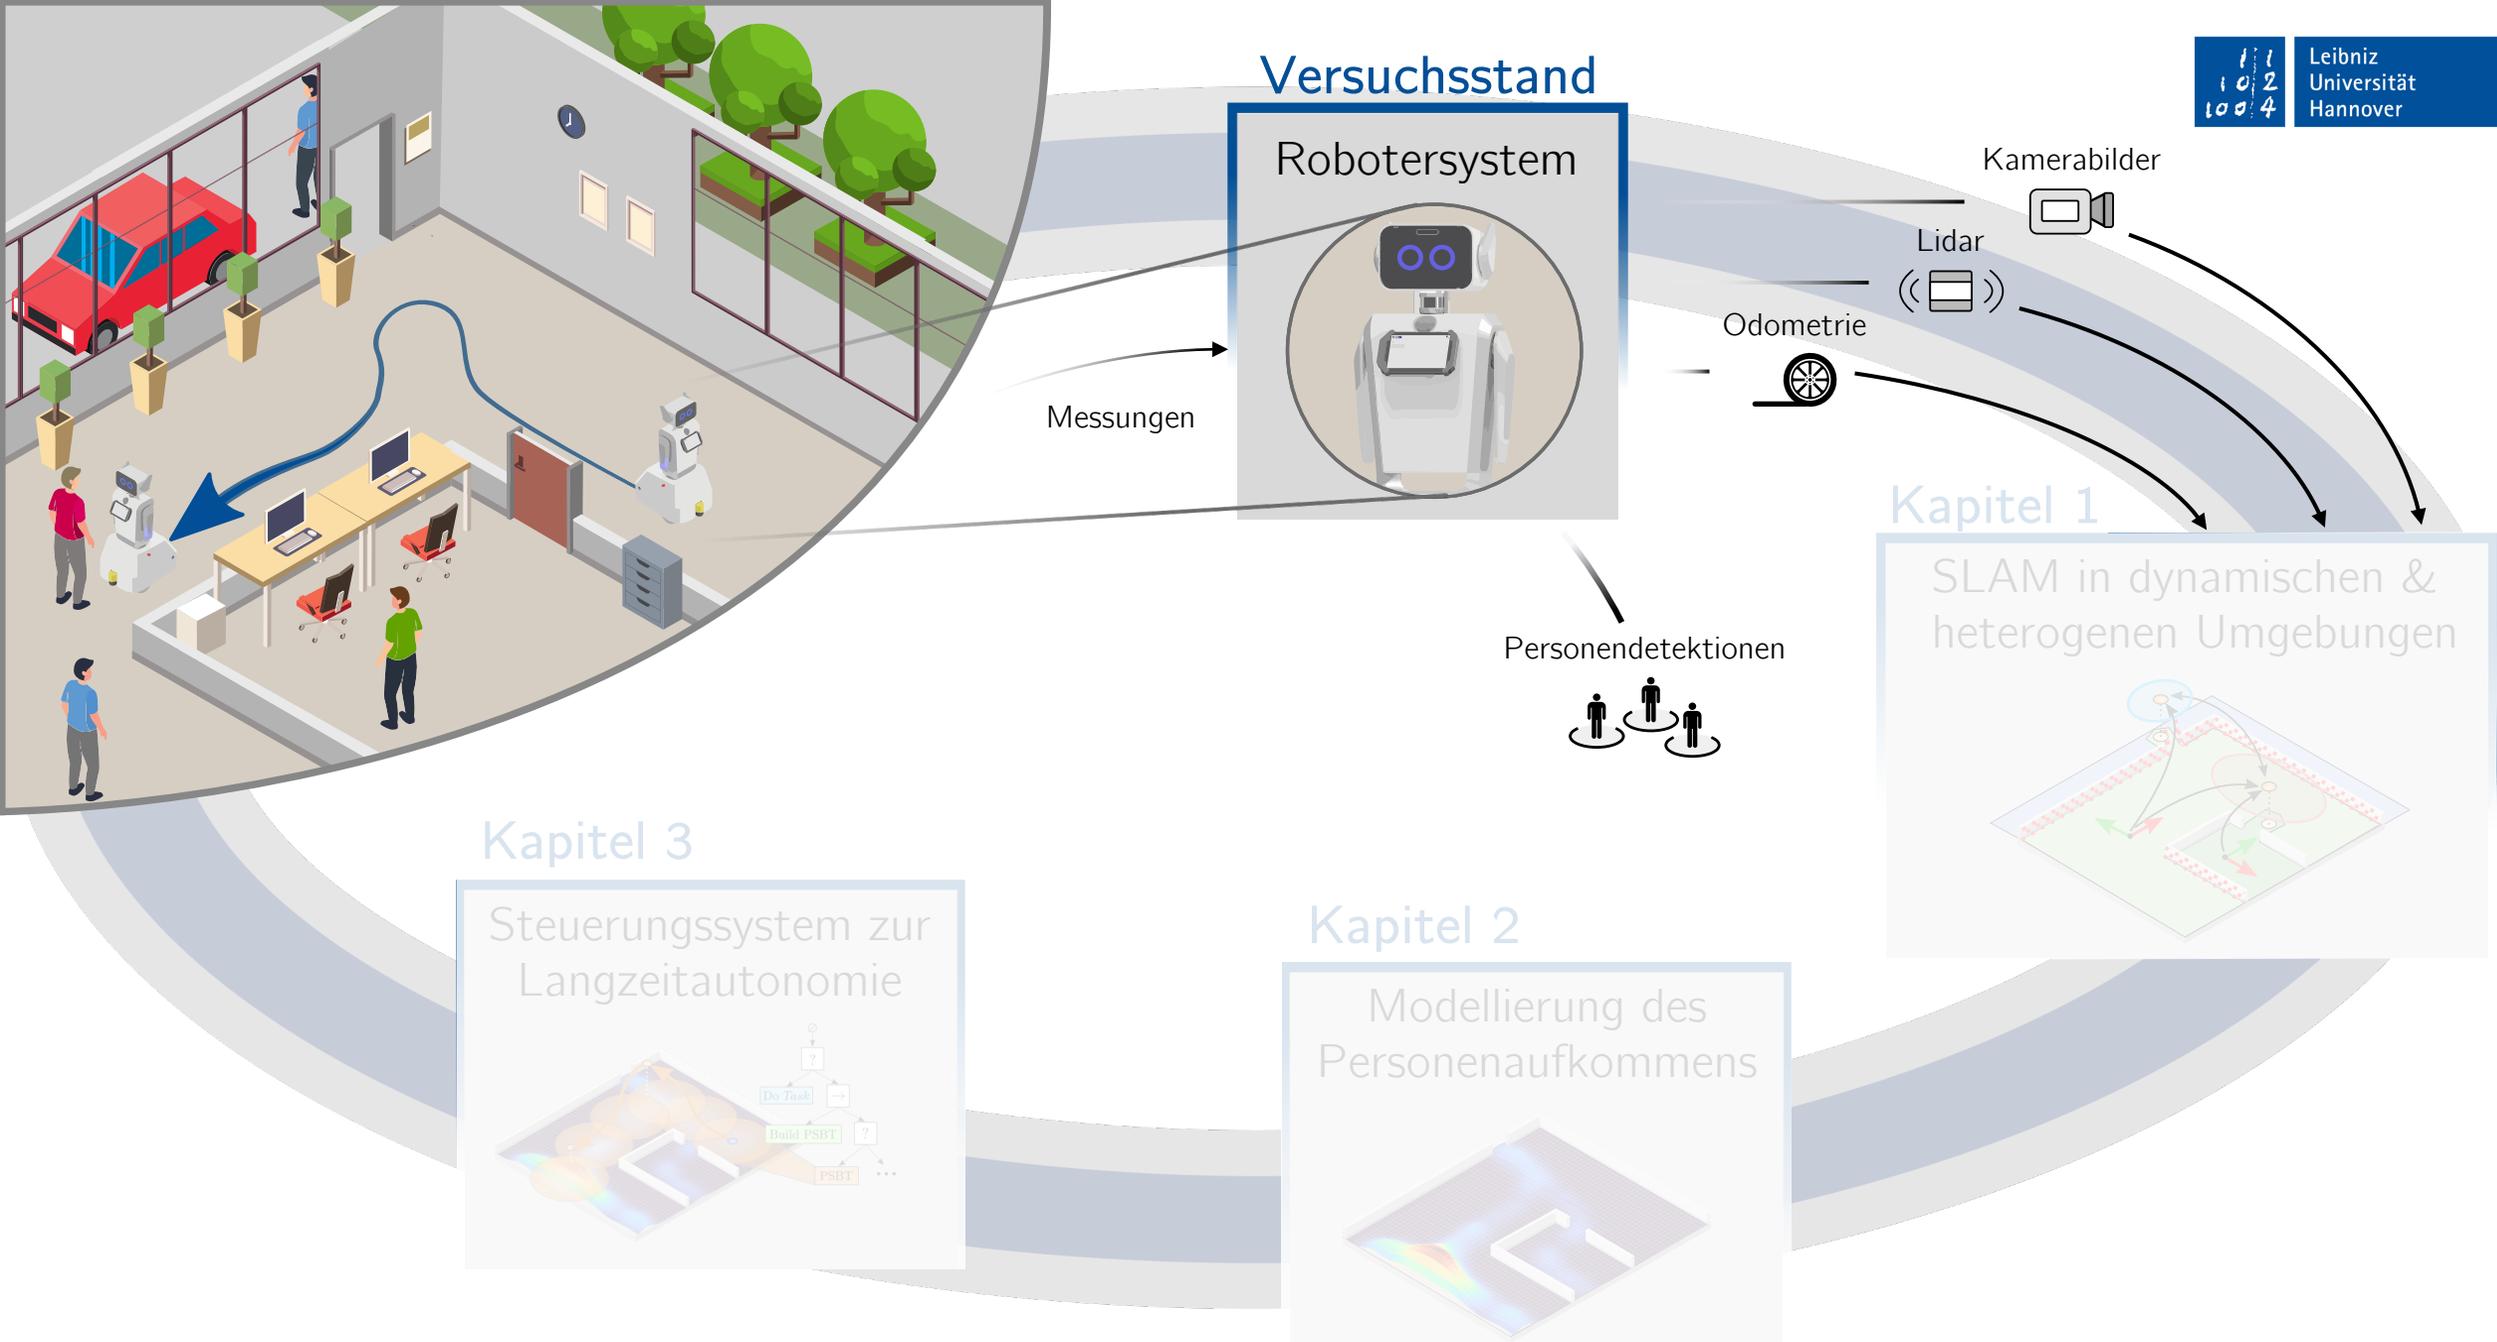
Miss (points to M_t)
 False Positive (points to FP_t)
 Mismatch (points to MME_t)
 Ground Truth (points to GT_t)

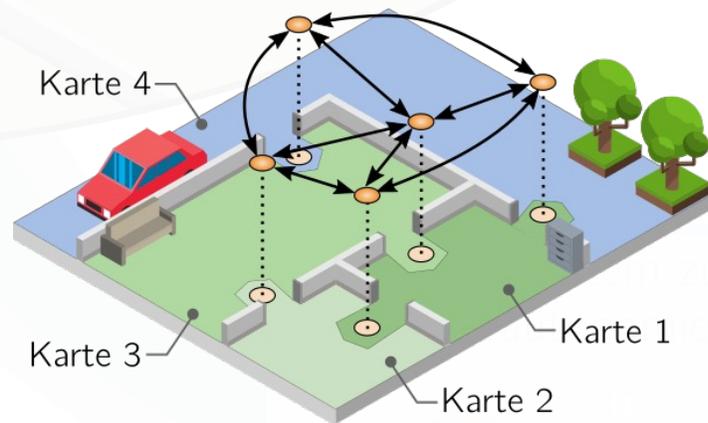
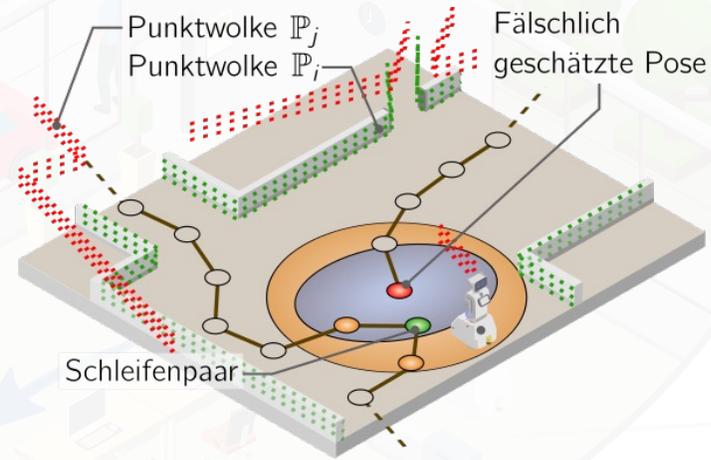
Bereich	MOTA (min.)	FP%	M%	RMSE in m
	89,7%	2,1 %	3,3%	0,2
	84,3%	4,6%	6,6%	0,25
	70,1%	17,2%	8,6%	0,21
	Keine Detektionen			

Fehlerkennzahlen für verschiedene Detektionsbereiche



Ortsabhängiger Fehler des Personentrackings (Draufsicht)

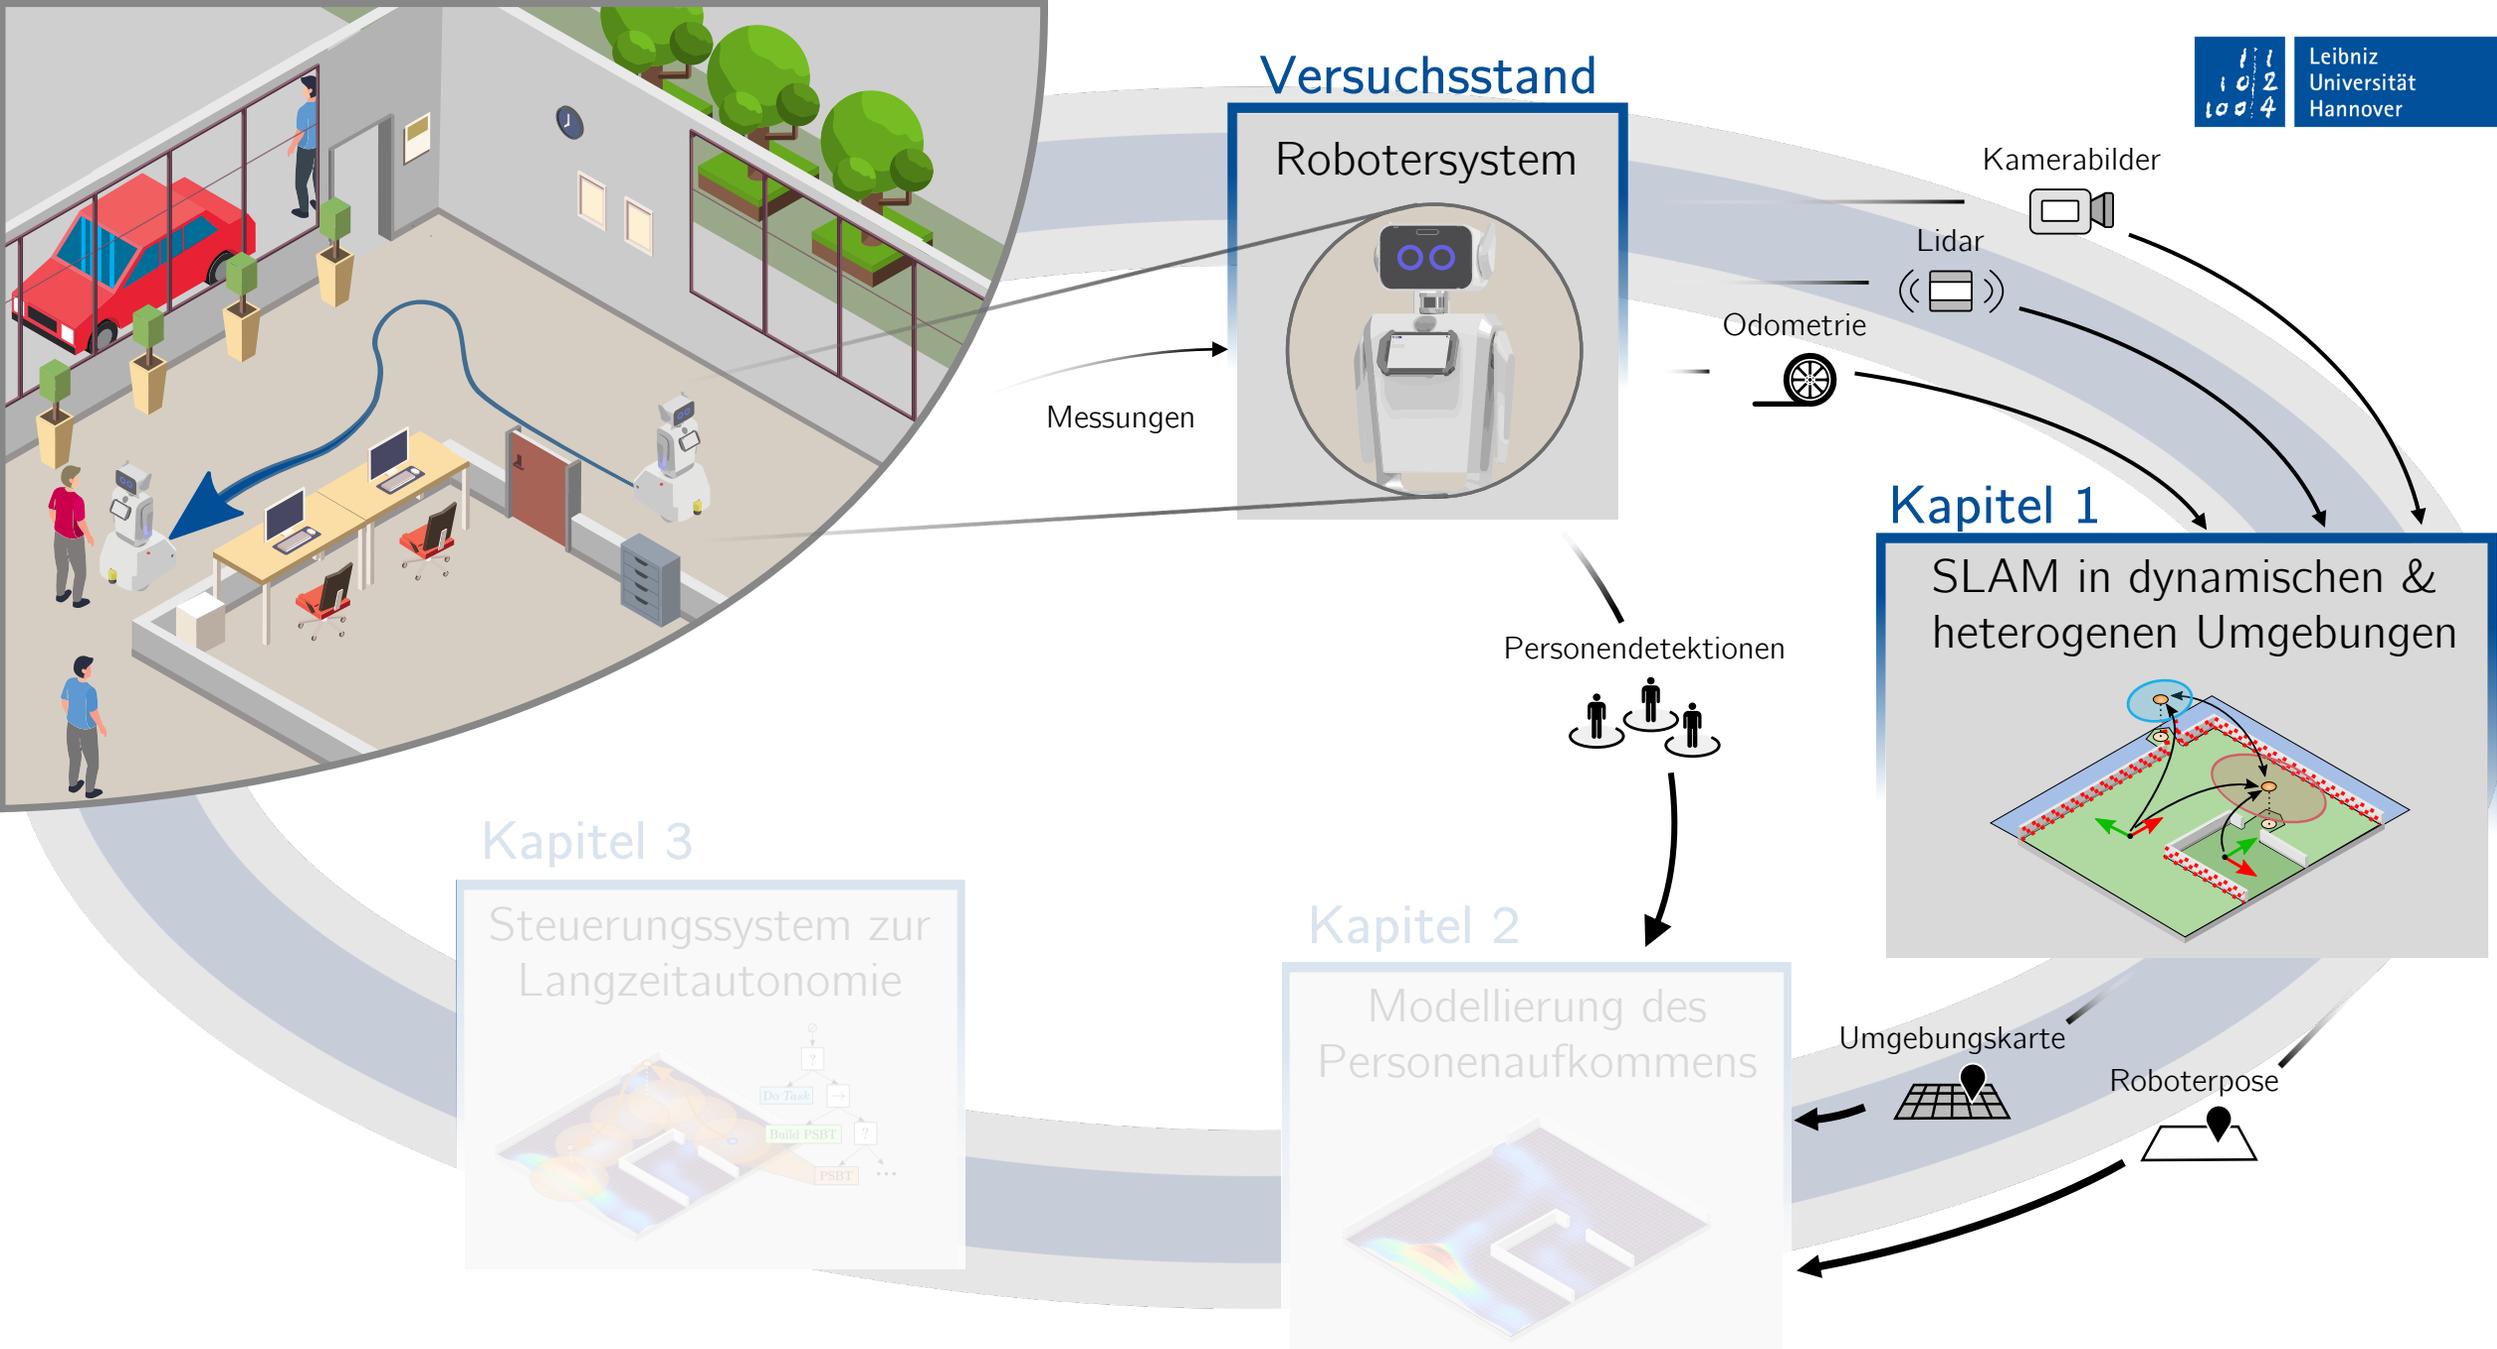




- Lidar-basierter Schleifenschluss für Graph-SLAM Verfahren (RTAB-Map) [2]
- Klassifikation + Registrierung von Punktwolken
- Kartierung großflächiger Umgebungen variierender Typs [3]
- Detektion von Umgebungsübergängen
- Verknüpfung unterschiedlicher SLAM Konfigurationen

[2] Tim-Lukas Habich, Marvin Stüde, Mathieu Labbé, und Svenja Spindeldreier (2021). "Have I been here before? Learning to Close the Loop with LiDAR Data in Graph-Based SLAM". In: *2021 IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM)*

[3] Simon F. G. Ehlers, Marvin Stüde, Kathrin Nülle, and Tobias Ortmaier (2020) "Map Management Approach for SLAM in Large-Scale Indoor and Outdoor Areas". In: *2020 IEEE International Conference on Robotics and Automation (ICRA)*



Modellierung des Personenaufkommens

Umgebungsdynamik

- Menschliche Bewegung → Umgebungsdynamik
- Modelle **menschlicher Aktivität** können die **Navigation, Aufgabenplanung** und **-durchführung** verbessern

Stand der Technik

- Wenige Modelle betrachten zeitliche (Langzeit-)effekte
- Ansätze vernachlässigen räumliche Wechselwirkungen

Nichtparametrische Modellierung (Gaußprozess)

- + Räumlich-zeitliche Wechselbeziehung als Prior
- + Berücksichtigt verrauschte Daten, Datenlücken und prädiktive Unsicherheit



LG Reinigungsroboter



Knightscope Sicherheitsroboter



Care-o-Bot Guideroboter



Starship Lieferroboter

Roboter in alltäglichen Umgebungen

Nichtparametrische Modellierung

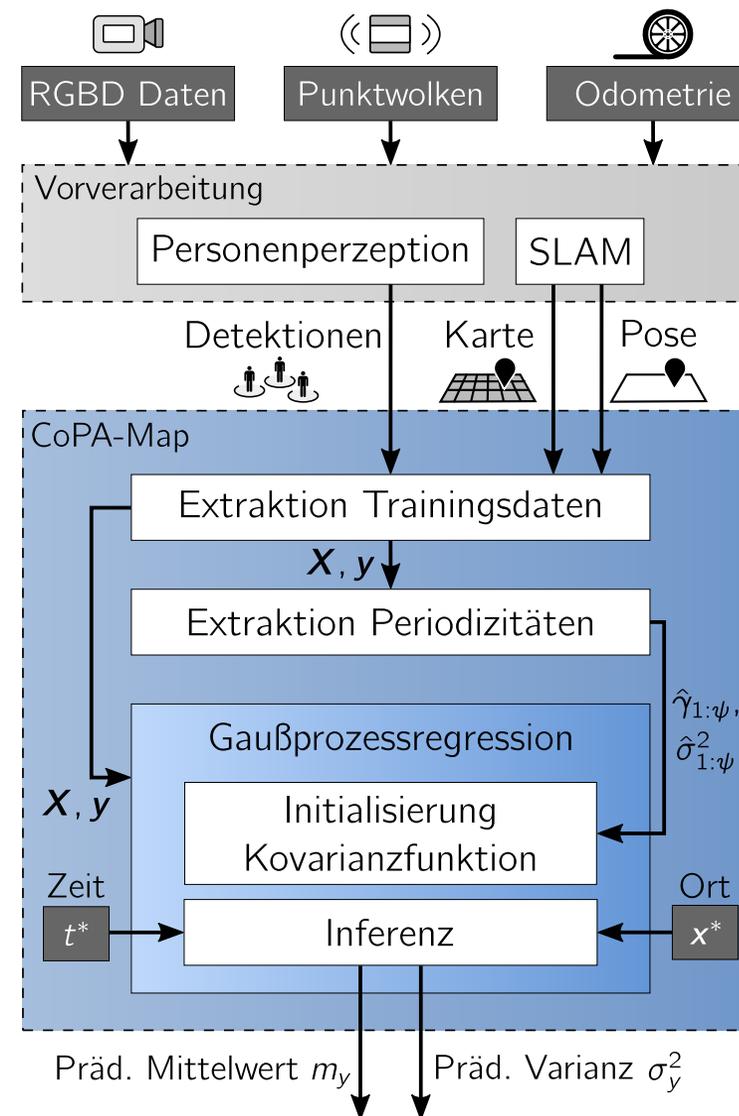
Continuous Pedestrian Activity Map: CoPA-Map

- **Langzeit**prädiktion des Personenaufkommens (räumlich/zeitlich)
- Eingangsdaten aus Messungen **mobiler** Robotersysteme
- Modell basierend auf Gaußprozessregression (GPR)

$$y_i \sim \mathcal{N}(f(\mathbf{x}_i), \sigma_i^2)$$

$$f(\mathbf{x}) \sim \mathcal{GP}(\mu_f(\mathbf{x}), k_f(\mathbf{x}, \mathbf{x}'))$$

für n Trainingspunkte $\mathbf{X} = \{\mathbf{x}_i \in \mathbb{R}^d\}_{i=1}^n$ mit Ausgängen $\mathbf{y} = \{y_i \in \mathbb{R}\}_{i=1}^n$



ψ : Anzahl Periodizitäten $\hat{\gamma}_{1:\psi}$: Menge initialer Periodendauern $\hat{\sigma}_{1:\psi}^2$: Menge initialer Varianzen

Regressionsproblem

Datenerzeugung

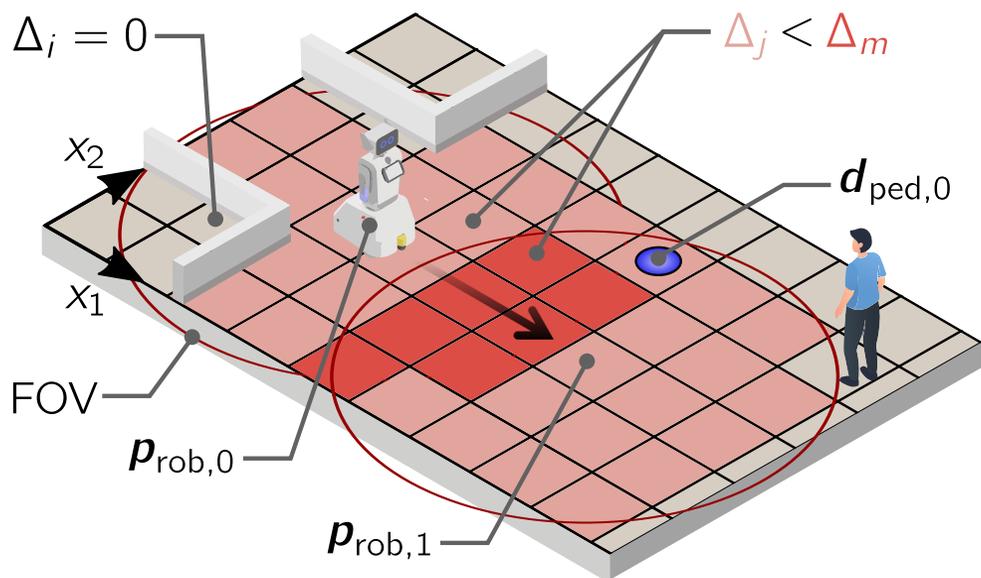
- Beweglicher Roboter → dünne/heterogene Datenverteilung
- Eingangsdaten

$$\mathbf{X} = \{(x_{1,i}, x_{2,i}, t_i)\}_{i=0}^n$$

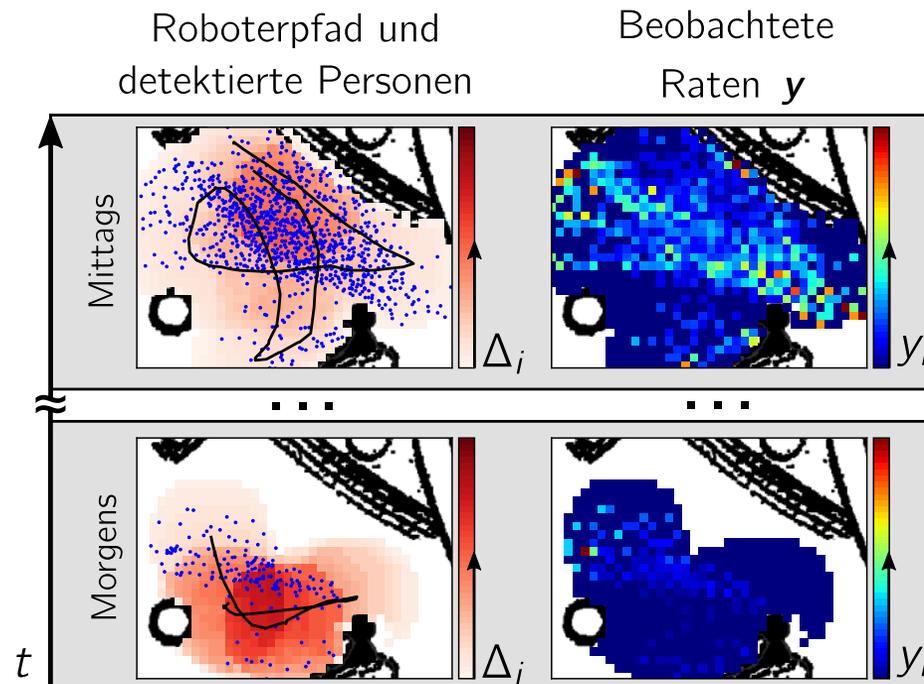
- Ausgangsdaten

Gezählte Personen Beobachtungsdauer

$$\mathbf{y} = \{c_i/\Delta_i\}_{i=0}^n$$



Variierende Zellbeobachtungsdauer und Personendetektion



Eingangsdaten und resultierende Beobachtungen für verschiedene Zeitpunkte

Heteroskedastische Gaußprozessregression

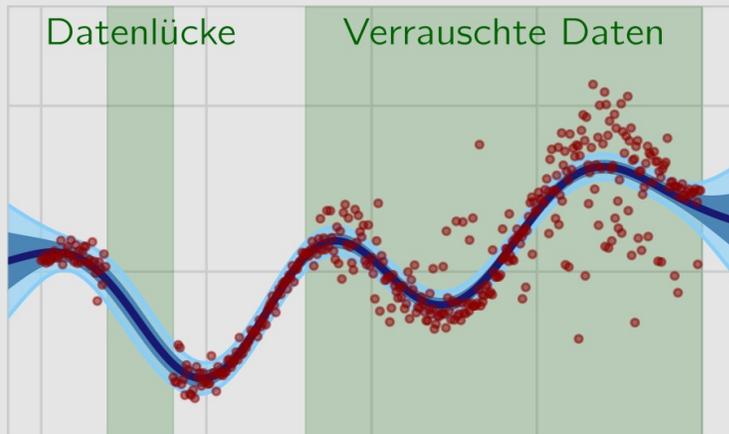
Ziel

- Mit gegebener Eingangsmatrix $\mathbf{X} = \{\mathbf{x}_i \in \mathbb{R}^3\}_{i=1}^n$ und Ausgangsvektor $\mathbf{y} = \{y_i \in \mathbb{R}\}_{i=1}^n$ finde $f : \mathbb{R}^3 \rightarrow \mathbb{R}$

Standard GPR

$$y_i = f(\mathbf{x}_i) + \varepsilon_i, \quad \varepsilon_i \sim \mathcal{N}(0, \sigma^2)$$
$$\mathbf{f} = f(\mathbf{x}) \sim \mathcal{GP}(\mu_f(\mathbf{x}), k_f(\mathbf{x}, \mathbf{x}'))$$

Exemplarischer 1-D Datensatz...



...gefitted mit normalverteilter Likelihood

Heteroskedastische Gaußprozessregression

Ziel

- Mit gegebener Eingangsmatrix $\mathbf{X} = \{\mathbf{x}_i \in \mathbb{R}^3\}_{i=1}^n$ und Ausgangsvektor $\mathbf{y} = \{y_i \in \mathbb{R}\}_{i=1}^n$ finde $f : \mathbb{R}^3 \rightarrow \mathbb{R}$

Standard GPR

$$y_i = f(\mathbf{x}_i) + \varepsilon_i, \quad \varepsilon_i \sim \mathcal{N}(0, \sigma^2)$$

$$\mathbf{f} = f(\mathbf{x}) \sim \mathcal{GP}(\mu_f(\mathbf{x}), k_f(\mathbf{x}, \mathbf{x}'))$$

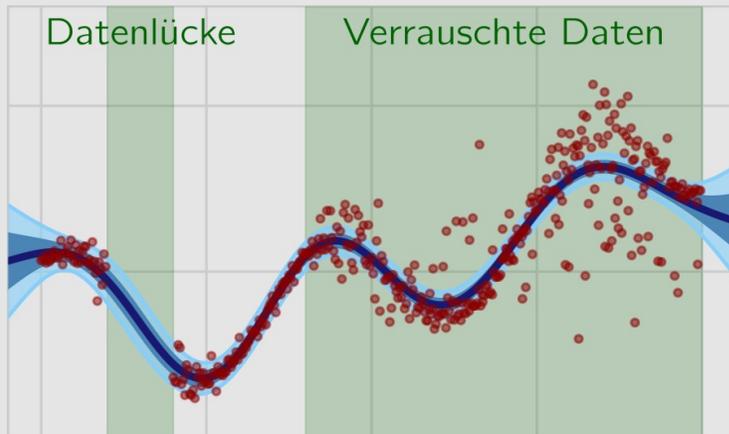
Heteroskedastische GPR

$$y_i \sim \mathcal{N}(f(\mathbf{x}_i), \sigma_i^2), \quad \sigma_i^2 = \zeta(g(\mathbf{x}_i))$$

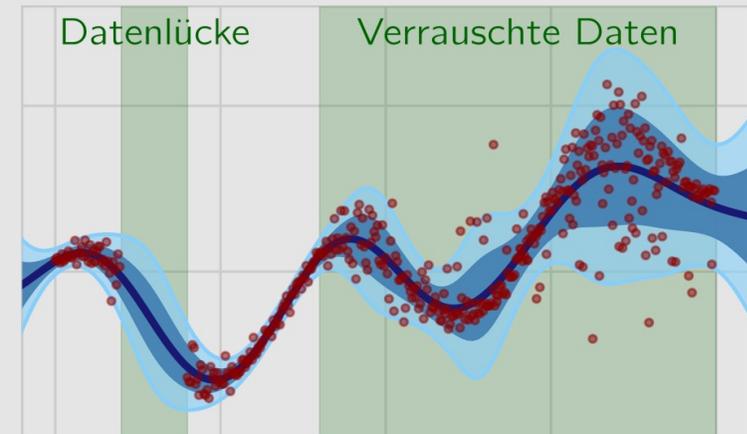
$$f(\mathbf{x}) \sim \mathcal{GP}(\mu_f(\mathbf{x}), k_f(\mathbf{x}, \mathbf{x}'))$$

$$g(\mathbf{x}) \sim \mathcal{GP}(\mu_g(\mathbf{x}), k_g(\mathbf{x}, \mathbf{x}'))$$

Exemplarischer 1-D Datensatz...



...gefitted mit normalverteilter Likelihood



...gefitted mit **heteroskedastisch** normalverteilter Likelihood

Kovarianzfunktion

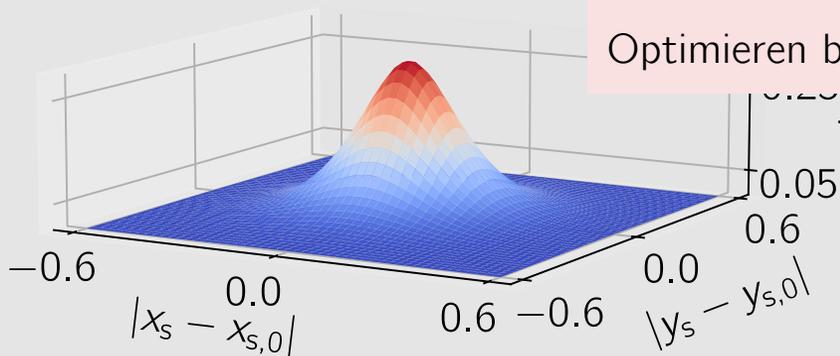
Mehrdimensionaler Produktkernel

- Kodierung von a priori Informationen in \mathbf{f}
- Räumlich-zeitliche Kovarianzfunktion
- Separiere jedes $\mathbf{x}_i = [\mathbf{x}_s, x_t]_i^T$, $\mathbf{x}_s \in \mathbb{R}^2$, $x_t \in \mathbb{R}$

$$k_f(\mathbf{x}_s, x_t, \mathbf{x}'_s, x'_t) = k_s(\|\mathbf{x}_s - \mathbf{x}'_s\|_2) \cdot k_t(|x_t - x'_t|)$$

Räumlicher Kernel (Matérn 5/2)

$$k_s(r) = \sigma_s^2 \left(1 + \frac{\sqrt{5}r}{l_s} + \frac{5r^2}{3l_s^2} \right) \exp\left(-\frac{\sqrt{5}r}{l_s}\right)$$

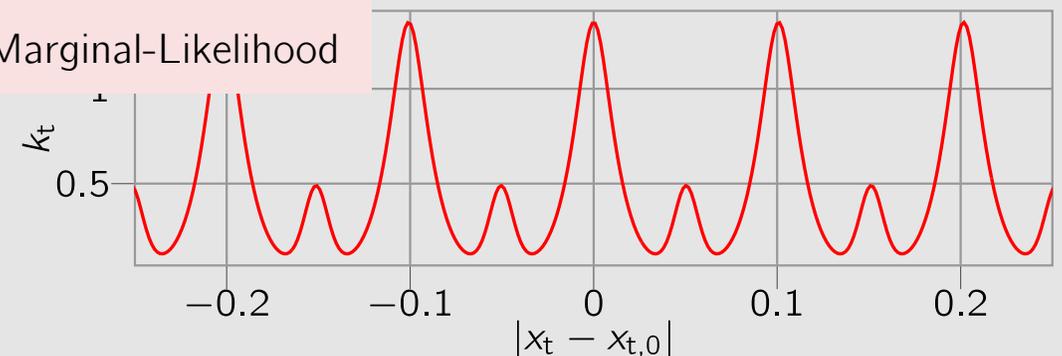


Hyperparameter

Optimieren basierend auf Log-Marginal-Likelihood

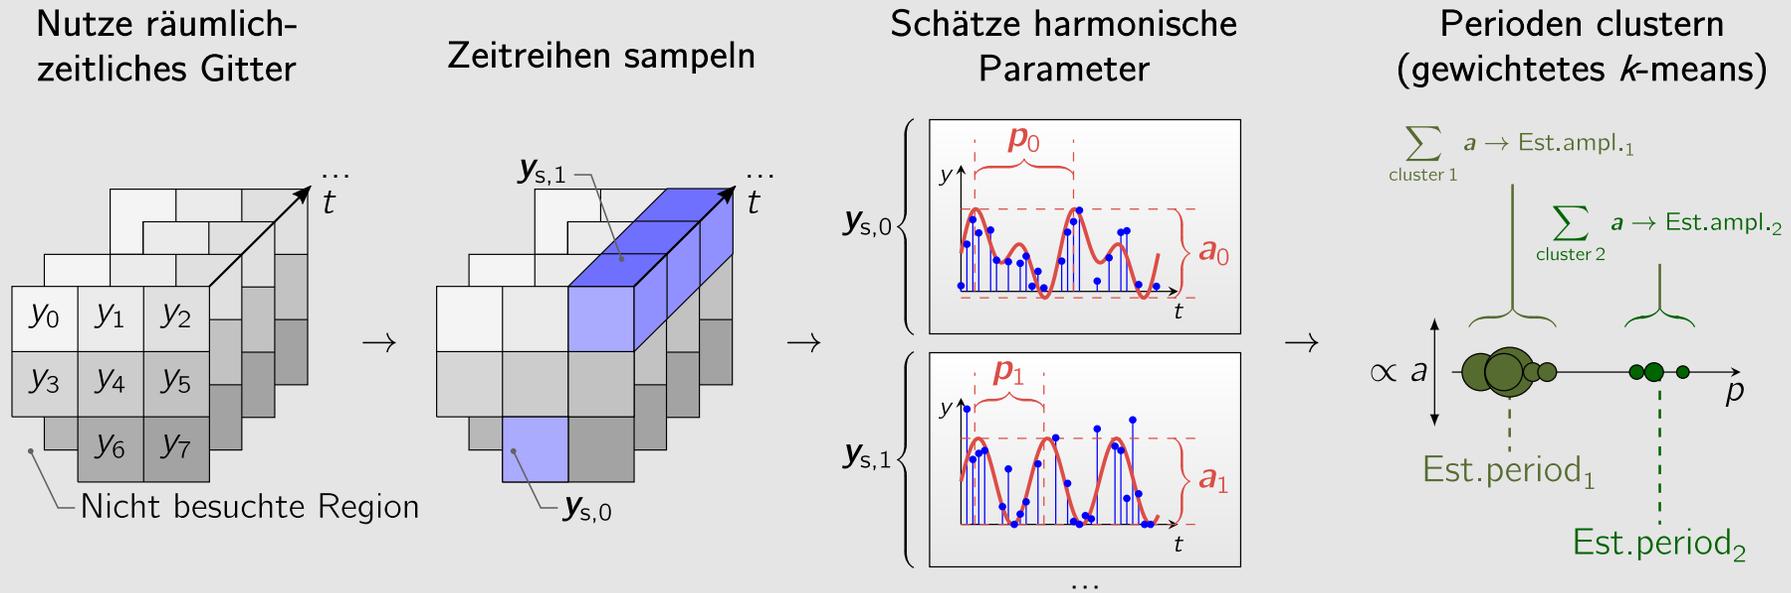
Zeitlicher Kernel (Periodisch)

$$k_t(r) = \sum_{i=0}^{\psi} \sigma_{t,i}^2 \exp\left(-\frac{1}{2} \frac{\sin^2(\gamma_i^{-1} r)}{l_{t,i}^2}\right)$$



Hyperparameterinitialisierung

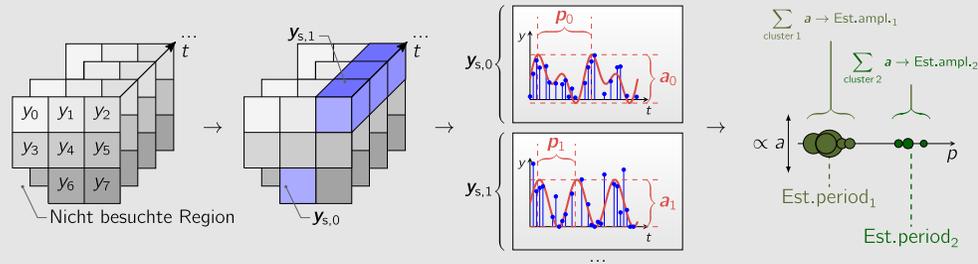
Initialisierungsroutine



Hyperparameterinitialisierung

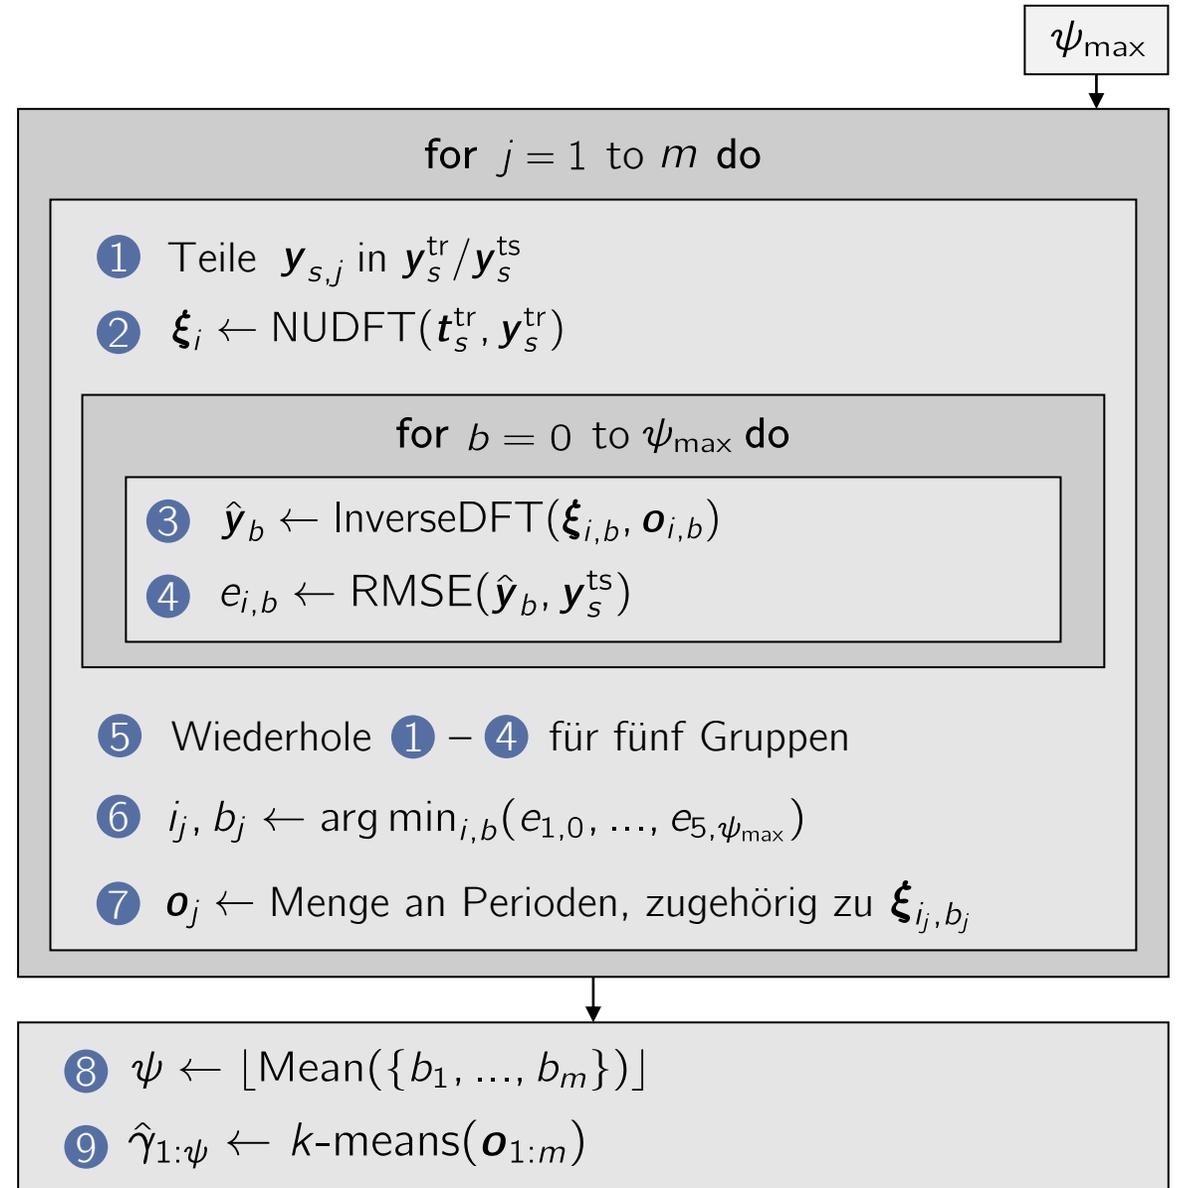
Initialisierungsroutine

- Basierend auf Sampling von m Zeitreihen



Algorithmus: Finde ψ (Anzahl) und γ_i (Periodendauern)

- 1 Erstelle zusammenhängende Trainings-/Testsets
- 2 Nichtuniforme diskrete Fouriertransformation
- 3 Rekonstruiere reduziertes Signal
- 4 – 5 Fehler speichern und 5-fold CV durchführen
- 6 – 7 Beste Perioden basierend auf Fehler speichern
- 8 Anzahl an Perioden als gewichteter Mittelwert
- 9 Perioden über gewichtetes Clustering



Modelloptimierung

Posterior Verteilung

$$p(\mathbf{f}, \mathbf{g} | \mathbf{y}) = \frac{\overbrace{p(\mathbf{y} | \mathbf{f}, \mathbf{g})}^{\text{Likelihood}} \cdot p(\mathbf{f}, \mathbf{g})}{\underbrace{p(\mathbf{y})}_{\text{Marginal Likelihood}}}$$

Prior Approximation

- Approximiere den Prior

$$p(\mathbf{f} | \mathbf{X}) = \mathcal{N}(0, \mathbf{K}_{\mathbf{f}\mathbf{f}}), \quad \mathbf{K}_{\mathbf{f}\mathbf{f}} = k_f(\mathbf{X}, \mathbf{X})$$

- Nyström Approximation

$$\mathbf{K}_{\mathbf{f}\mathbf{f}} \approx \mathbf{K}_{\mathbf{f}\mathbf{u}_f} \mathbf{K}_{\mathbf{u}_f\mathbf{u}_f}^{-1} \mathbf{K}_{\mathbf{u}_f\mathbf{f}}$$

- Basierend auf induzierenden Punkten

$$\mathbf{u}_f = f(\mathbf{Z}), \quad \mathbf{Z} = \{\mathbf{z}_i\}_{i=1}^m, \quad m \ll n$$

($p(\mathbf{g})$ folgt entsprechend)

Modelloptimierung

Posterior Verteilung

$$q(\mathbf{f})q(\mathbf{g}) \approx p(\mathbf{f}, \mathbf{g} | \mathbf{y}) = \frac{\overbrace{p(\mathbf{y} | \mathbf{f}, \mathbf{g})}^{\text{Likelihood}} \cdot p(\mathbf{f}, \mathbf{g})}{\underbrace{p(\mathbf{y})}_{\text{Marginal Likelihood}}}$$

Posterior Approximation

- Finde untere Schranke für $p(\mathbf{f}, \mathbf{g} | \mathbf{y})$ mit $q(\mathbf{f})$ und $q(\mathbf{g})$
- Minimiere $\text{KL}(q(\mathbf{f})q(\mathbf{g}) || p(\mathbf{f}, \mathbf{g} | \mathbf{y}))$
- Entspricht Maximierung der variationalen unteren Schranke

$$\mathcal{L} = \sum_{i=1}^n \int q(\mathbf{f}_i) q(\mathbf{g}_i) \log p(\mathbf{y}_i | \mathbf{f}_i, \mathbf{g}_i) d\mathbf{f}_i d\mathbf{g}_i$$

$$- \text{KL}(q(\mathbf{u}_f) || p(\mathbf{u}_f)) - \text{KL}(q(\mathbf{u}_g) || p(\mathbf{u}_g))$$

Prior Approximation

- Approximiere den Prior

$$p(\mathbf{f} | \mathbf{X}) = \mathcal{N}(0, \mathbf{K}_{ff}), \quad \mathbf{K}_{ff} = k_f(\mathbf{X}, \mathbf{X})$$

- Nyström Approximation

$$\mathbf{K}_{ff} \approx \mathbf{K}_{fu_f} \mathbf{K}_{u_f u_f}^{-1} \mathbf{K}_{f u_f}^T$$

- Basierend auf induzierenden Punkten

$$\mathbf{u}_f = f(\mathbf{Z}), \quad \mathbf{Z} = \{\mathbf{z}_i\}_{i=1}^m, \quad m \ll n$$

($p(\mathbf{g})$ folgt entsprechend)

Modelloptimierung

Komplexität

$$\mathcal{O}(n m^2 + 2nm)$$

Posterior Verteilung

$$q(\mathbf{f})q(\mathbf{g}) \approx p(\mathbf{f}, \mathbf{g} | \mathbf{y}) = \frac{\overbrace{p(\mathbf{y} | \mathbf{f}, \mathbf{g})}^{\text{Likelihood}} \cdot p(\mathbf{f}, \mathbf{g})}{\underbrace{p(\mathbf{y})}_{\text{Marginal Likelihood}}}$$

Posterior Approximation

- Finde untere Schranke für $p(\mathbf{f}, \mathbf{g} | \mathbf{y})$ mit $q(\mathbf{f})$ und $q(\mathbf{g})$
- Minimiere $\text{KL}(q(\mathbf{f})q(\mathbf{g}) || p(\mathbf{f}, \mathbf{g} | \mathbf{y}))$
- Entspricht Maximierung der variationalen unteren Schranke

$$\mathcal{L} = \sum_{i=1}^n \int q(\mathbf{f}_i) q(\mathbf{g}_i) \log p(\mathbf{y}_i | \mathbf{f}_i, \mathbf{g}_i) d\mathbf{f}_i d\mathbf{g}_i$$

$$- \text{KL}(q(\mathbf{u}_f) || p(\mathbf{u}_f)) - \text{KL}(q(\mathbf{u}_g) || p(\mathbf{u}_g))$$

Prior Approximation

- Approximiere den Prior

$$p(\mathbf{f} | \mathbf{X}) = \mathcal{N}(0, \mathbf{K}_{ff}), \quad \mathbf{K}_{ff} = k_f(\mathbf{X}, \mathbf{X})$$

- Nyström Approximation

$$\mathbf{K}_{ff} \approx \mathbf{K}_{f\mathbf{u}_f} \mathbf{K}_{\mathbf{u}_f\mathbf{u}_f}^{-1} \mathbf{K}_{\mathbf{u}_f\mathbf{u}_f}^T$$

- Basierend auf induzierenden Punkten

$$\mathbf{u}_f = f(\mathbf{Z}), \quad \mathbf{Z} = \{\mathbf{z}_i\}_{i=1}^m, \quad m \ll n$$

($p(\mathbf{g})$ folgt entsprechend)

Modellinferenz

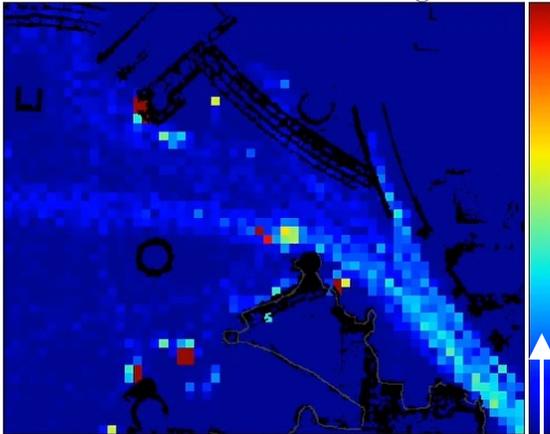
Prädiktion

- Posterior predictive distribution

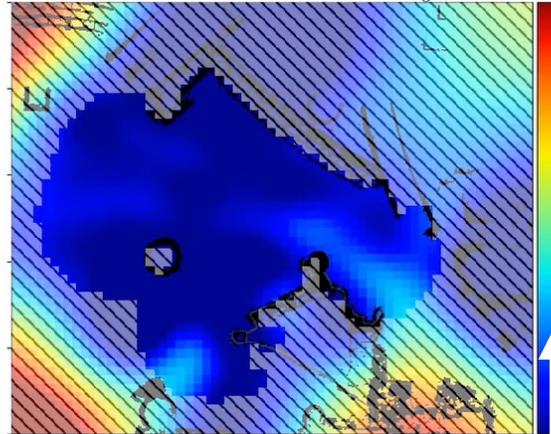
$$p(\mathbf{y}_i^* | \mathbf{y}_i, \mathbf{x}_i) = \int p(\mathbf{y}_i^* | \mathbf{f}_i^*, \mathbf{g}_i^*) q(\mathbf{f}_i^*) q(\mathbf{g}_i^*) d\mathbf{f}_i^* d\mathbf{g}_i^*$$

- Prädiktiver Mittelwert $m_y(\mathbf{x}_i^*)$ und Varianz $\sigma_y^2(\mathbf{x}_i^*)$ folgen aus $p(\mathbf{y}_i^* | \mathbf{y}_i, \mathbf{x}_i)$

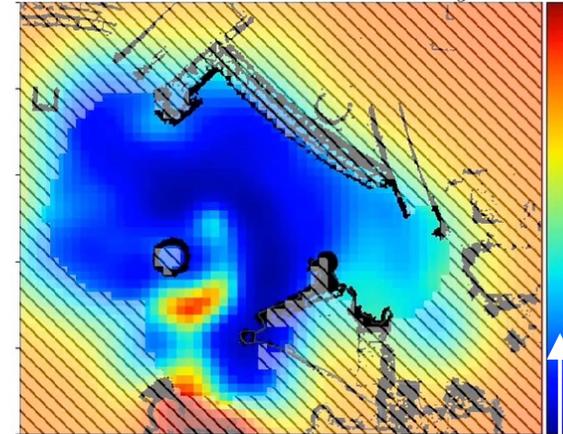
Ground Truth Rate



Prädiktiver Mittelwert



Prädiktive Standardabweichung



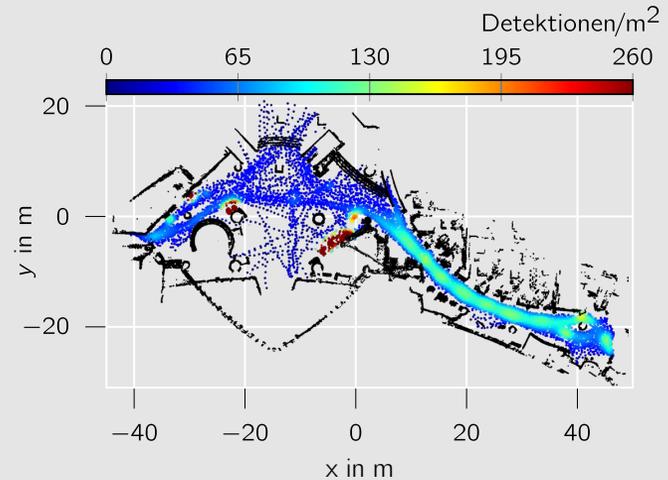
Prädiktion

Tag: 11, 09:00 Uhr

Ergebnisse

Setup

- Zwei Langzeitdatensätze mit realen Personendetektionen
 - Büroumgebung, 10 Tage für Training
 - Einkaufszentrum, 10 Tage für Training



Karte und exemplarische Detektionen auf Einkaufszentrum-Datensatz

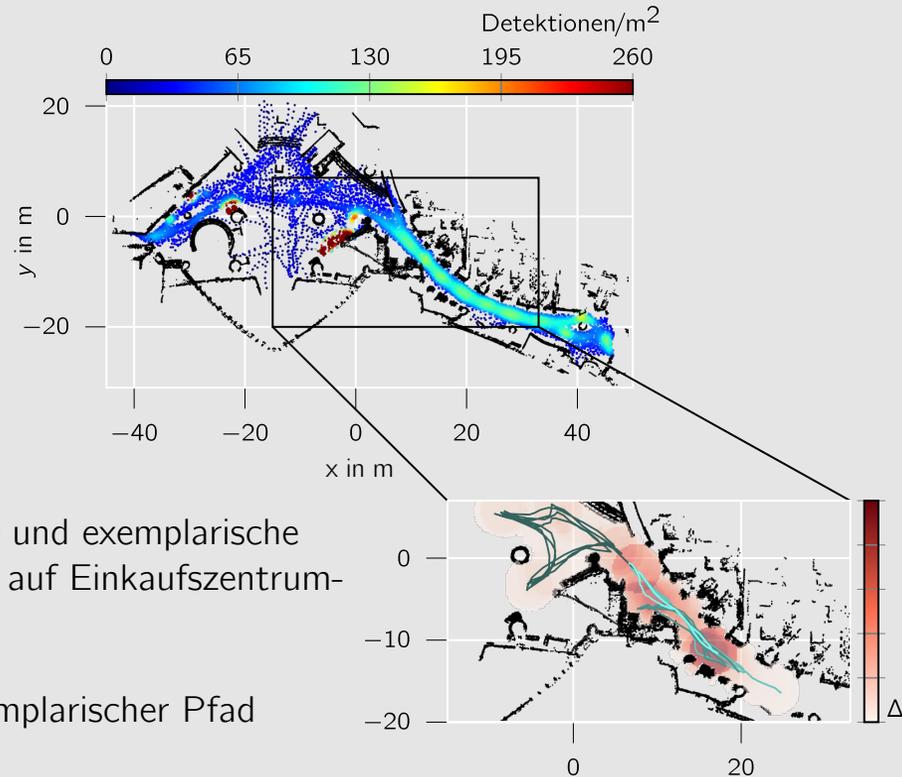
Vergleich zum Stand der Technik

- Maximum-Likelihood (ML) Schätzung
- Poisson Spektral Modell (**FreMEn**, Jovan et al., 2016)
- Warped-Hypertime Modell (**WHyTe**, Vintr et al., 2019)
- Homoskedastischer Log-Gauß-Cox Prozess

Ergebnisse

Setup

- Zwei Langzeitdatensätze mit realen Personendetektionen
 - Büroumgebung, 10 Tage für Training
 - Einkaufszentrum, 10 Tage für Training



Oben: Karte und exemplarische Detektionen auf Einkaufszentrum-Datensatz.

Rechts: Exemplarischer Pfad

Vergleich zum Stand der Technik

- Maximum-Likelihood (ML) Schätzung
- Poisson Spektral Modell (**FreMEn**, Jovan et al., 2016)
- Warped-Hypertime Modell (**WHyTe**, Vintr et al., 2019)
- Homoskedastischer Log-Gauß-Cox Prozess

Ergebnisse: Standardmetriken (NRMSE, χ^2 -Distanz)

- Test: Neun Robotertrajektorien pro Datensatz
- Variierende örtliche/zeitliche Auflösung
- CoPA-Map: Bessere Ergebnisse insbesondere bei bewegtem Robotersystem

Service Disturbance

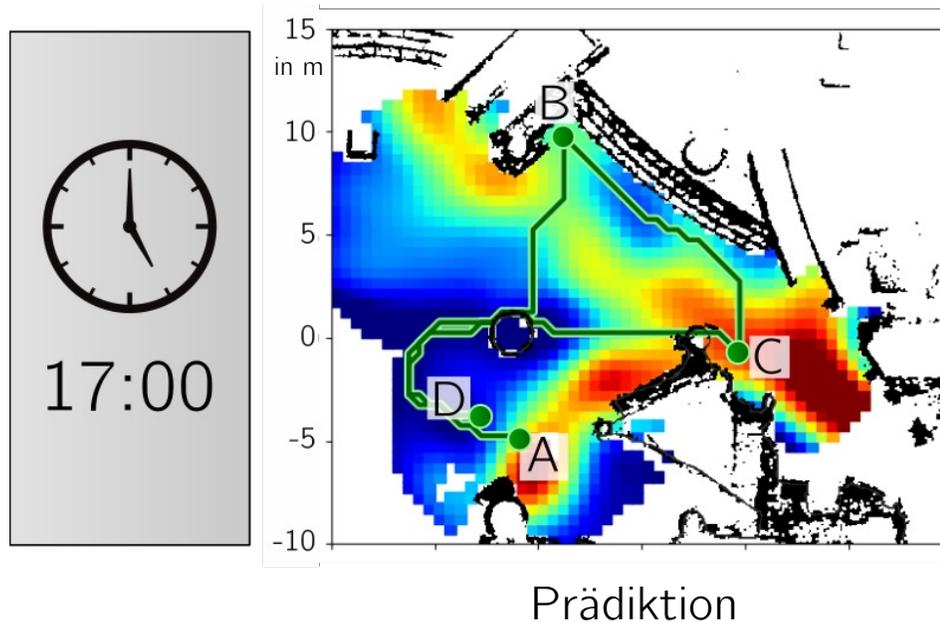
Anwendungsorientierte Evaluation (Vintr et al., 2020)

- **Idee:** Modell nutzen um Störung von Personen zu vermeiden
- *Service Disturbance E* mit *servicing ratio r*

$$E(\lfloor pr \rfloor) = \sum_{k=1}^{\lfloor pr \rfloor} e_k$$

- Anzahl an p imaginären Navigationsszenarien zu unterschiedlichen Zeitpunkten
- Erwartete Begegnungen (*Expected encounters*)

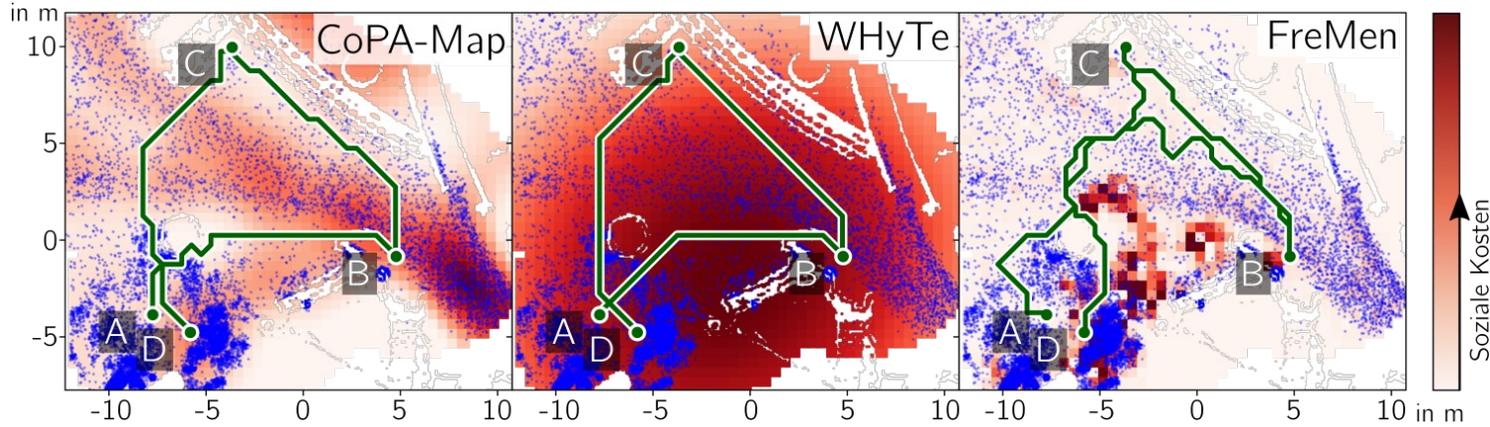
$$EE = \int_0^1 E(\lfloor pr \rfloor) dr$$



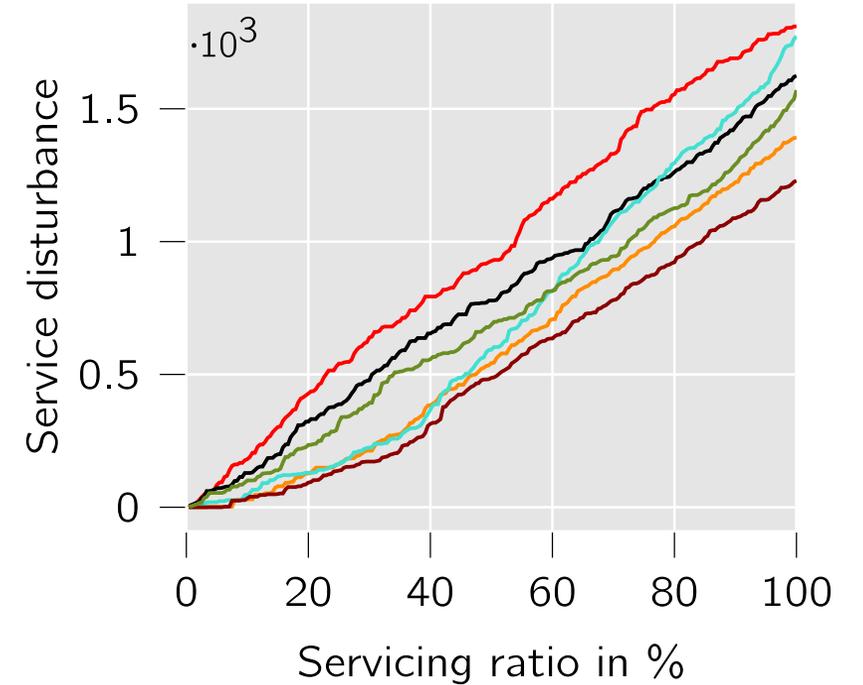
Service Disturbance: Ergebnisse

Evaluation

- 4 Tage, 12 Stunden pro Tag, 5 Navigationsaufgaben pro Stunde $\Rightarrow \rho = 240$
- *Wie viele Begegnungen mit Personen traten auf, wenn ein Anteil r an Navigationsaufgaben durchgeführt werden muss?*



CoPA-Map führt zu glatten Pfaden und vermeidet Bereiche mit hoher Personendichte



Service disturbance (Begegnungen) in Abhängigkeit des *servicing ratio* r

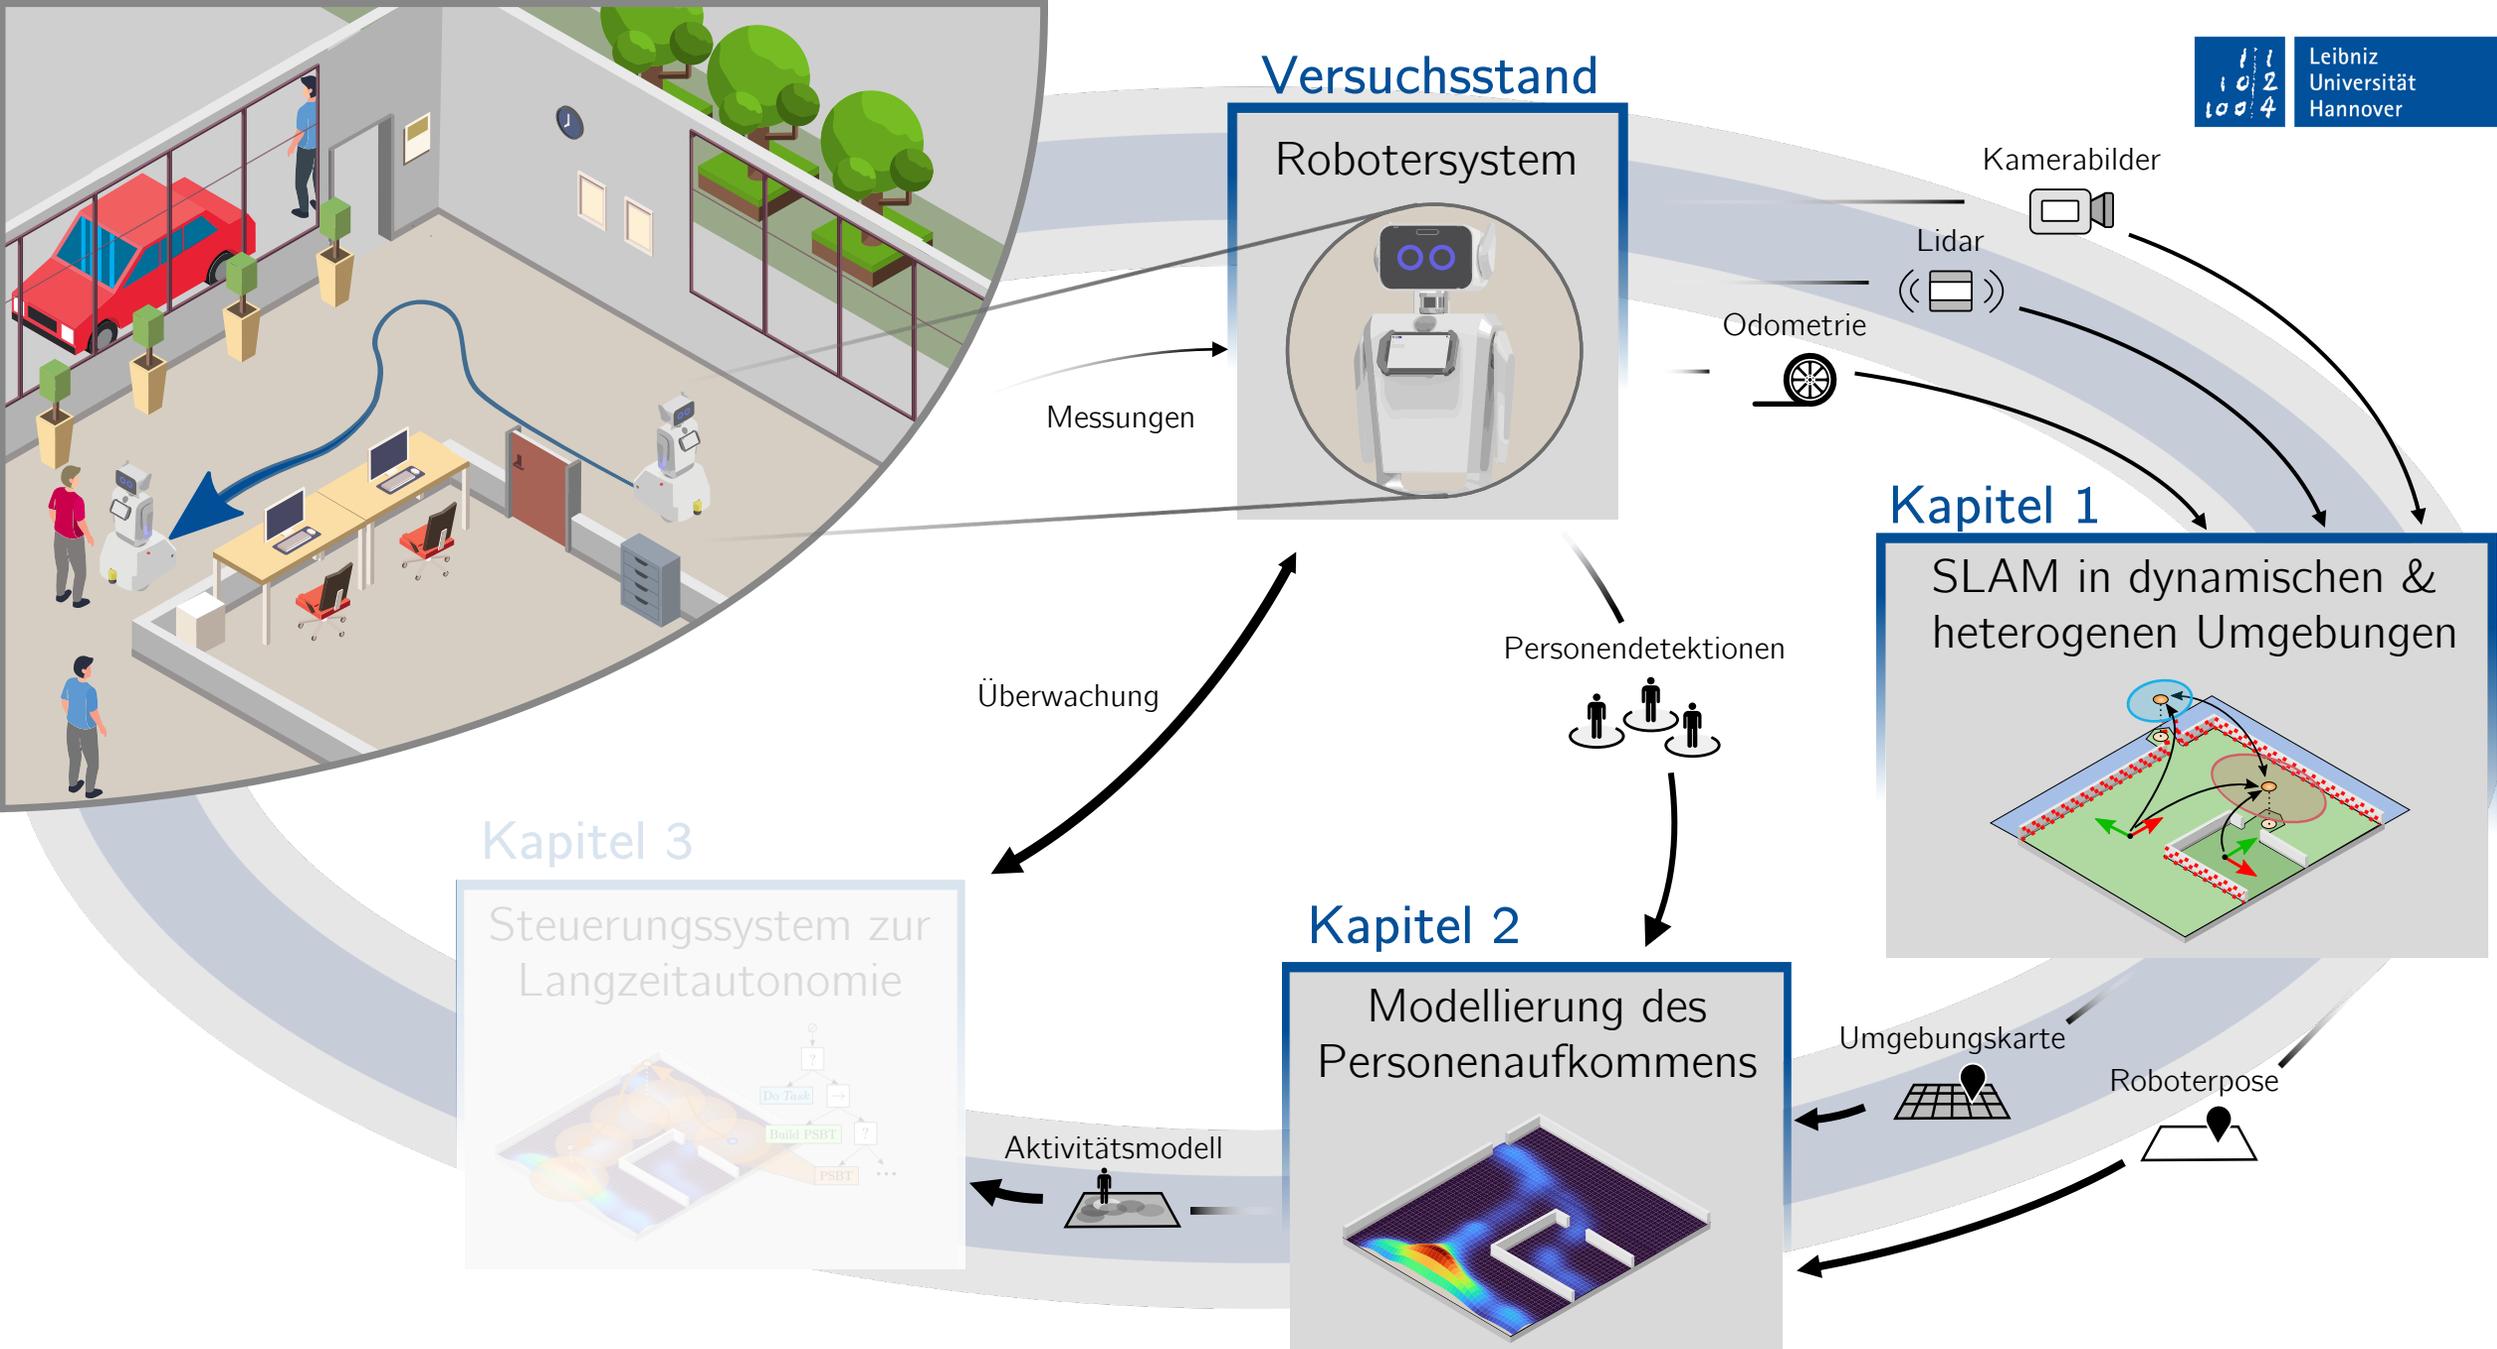
Forschungsfrage 2

Wie kann **menschliche Aktivität** räumlich-zeitlich basierend auf **Langzeitbeobachtungen mobiler Roboter** modelliert werden?

Antwort

- A-priori Informationen über Abhängigkeiten und Periodizitäten in einem **Kernel** enkodieren
- **Heteroskedastischen** Gaußprozess zur **kontinuierlichen** Modellierung dünner Datenverteilungen nutzen
- **Variationale Inferenz** für schnelles, wiederholbares Modelltraining
- Publiziert in [4]

[4] [Marvin Stüde und Moritz Schappler \(2022\)](#). "Non-Parametric Modeling of Spatio-Temporal Human Activity Based on Mobile Robot Observations".
In: *2022 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*



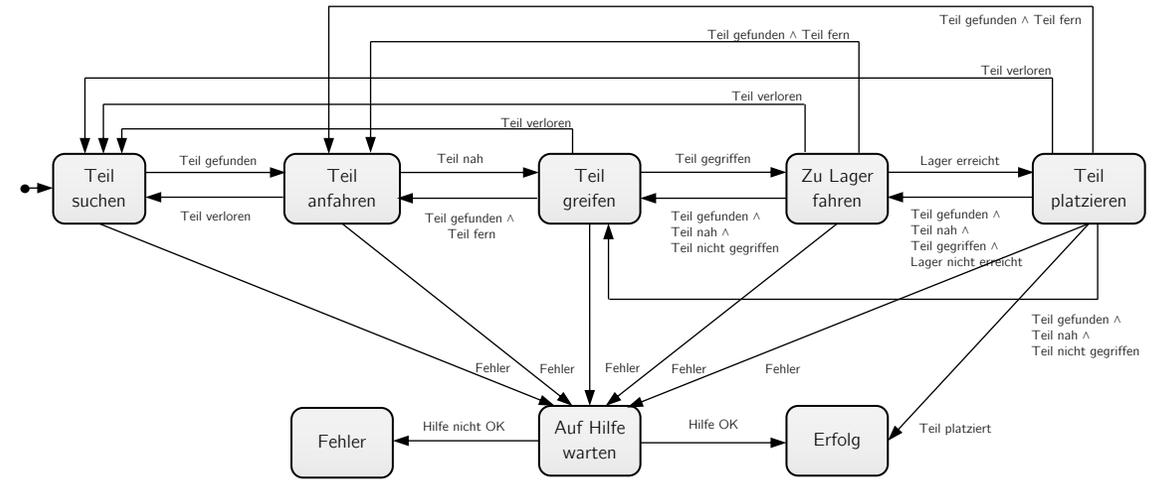
Motivation

Steuerungssystem zur Langzeitautonomie

- Aufgaben steuern/durchführen
- Anforderungen
 - Reaktive Ausführung → Reaktion auf Chancen und Fehler
 - Hierarchische Deliberation
 - Kontinuierliche Planung und Deliberation

Stand der Technik

- FSM: Schlechte Wiederverwendbarkeit & Erweiterbarkeit
- Restriktive/Problemabhängige Modelldefinition



Zustandsmaschine (FSM) (Beispiel eines Logistikszenarios)

Motivation

Steuerungssystem zur Langzeitautonomie

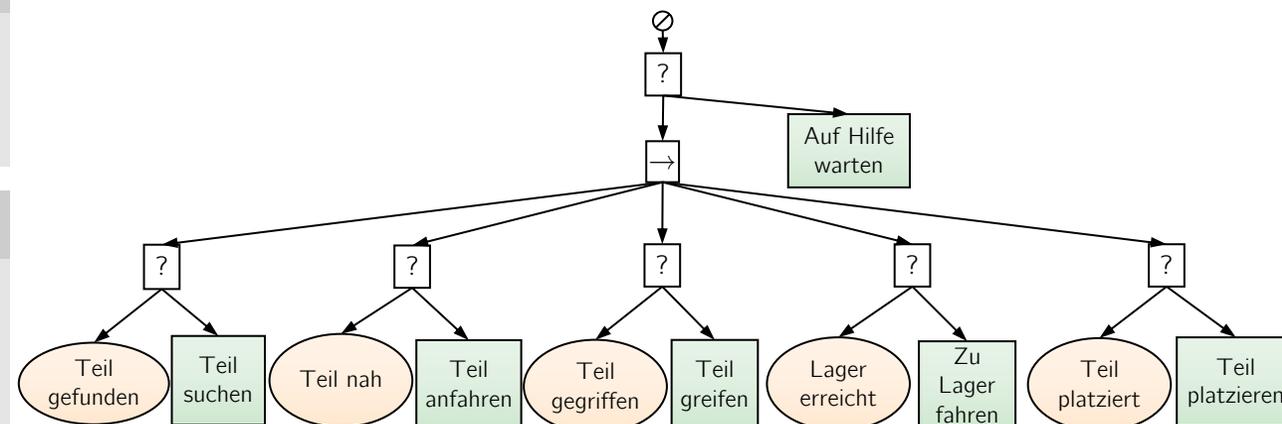
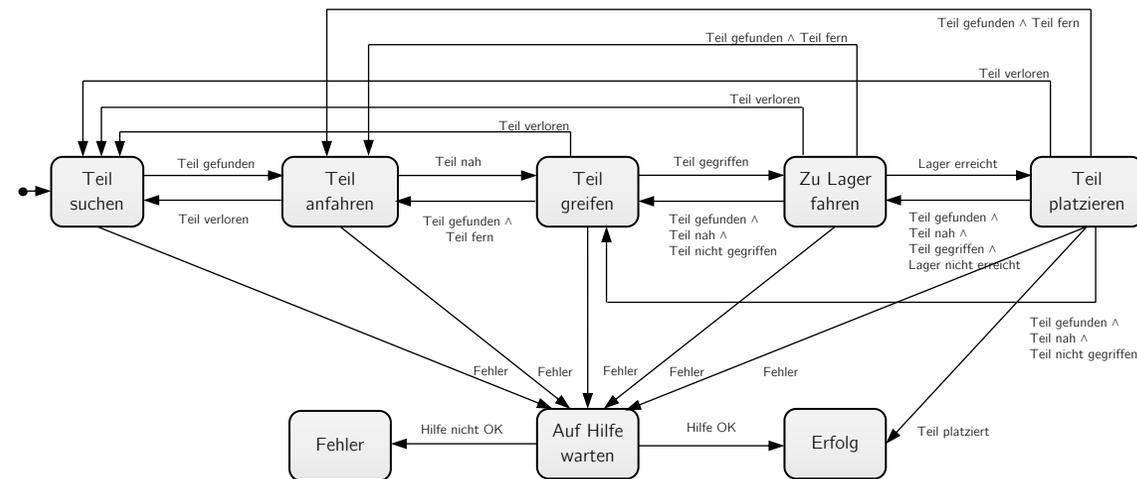
- Aufgaben steuern/durchführen
- Anforderungen
 - Reaktive Ausführung → Reaktion auf Chancen und Fehler
 - Hierarchische Deliberation
 - Kontinuierliche Planung und Deliberation

Stand der Technik

- FSM: Schlechte Wiederverwendbarkeit & Erweiterbarkeit
- Restriktive/Problemabhängige Modelldefinition

Behavior Trees

- + Modularität & Wiederverwendbarkeit
- + Reaktivität
- + Hierarchische Organisation
- + Geeignet für stochastische Analyse (Colledanchise et al., 2014) & automatische Synthese (Colledanchise et al., 2019)



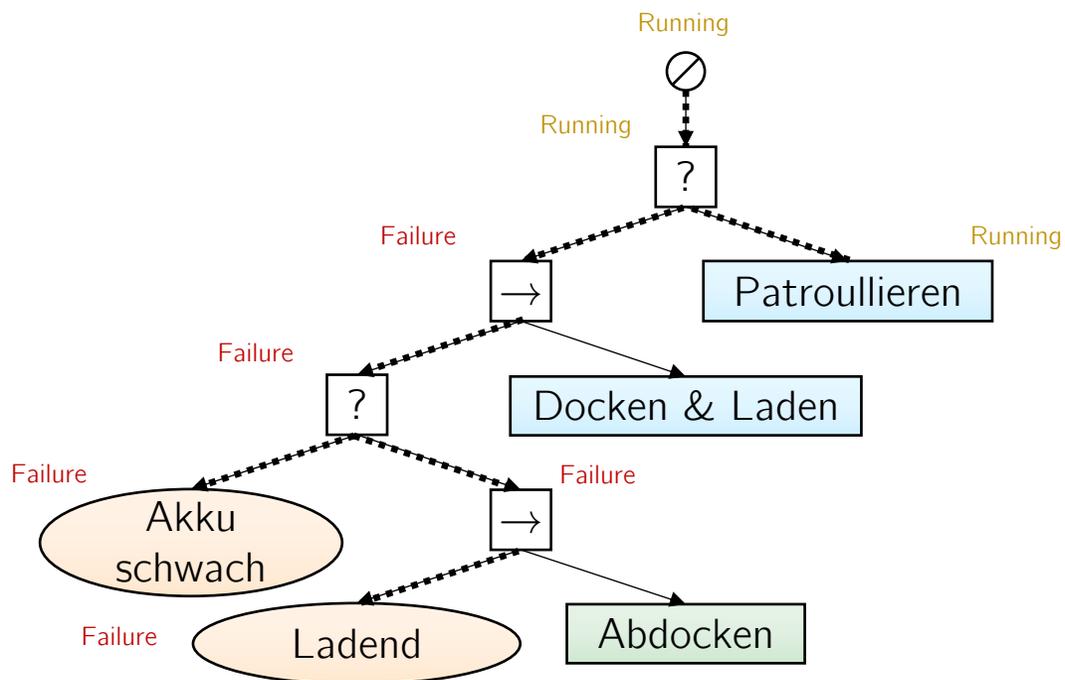
Zustandsmaschine (FSM, o) und äquivalenter Behavior Tree (u)
(Beispiel eines Logistikszenarios)

Behavior Trees

Behavior Trees

- Gerichteter Baum mit Knoten für Steuerungsablauf und Aufgabendurchführung
- Kindknoten geben entweder **Success**, **Failure** oder **Running** zurück
- Leserichtung: Links nach rechts, oben nach unten

Legende



Behavior Tree zur Beschreibung eines autonomen Ladeverhaltens
(Regulärer Betrieb)

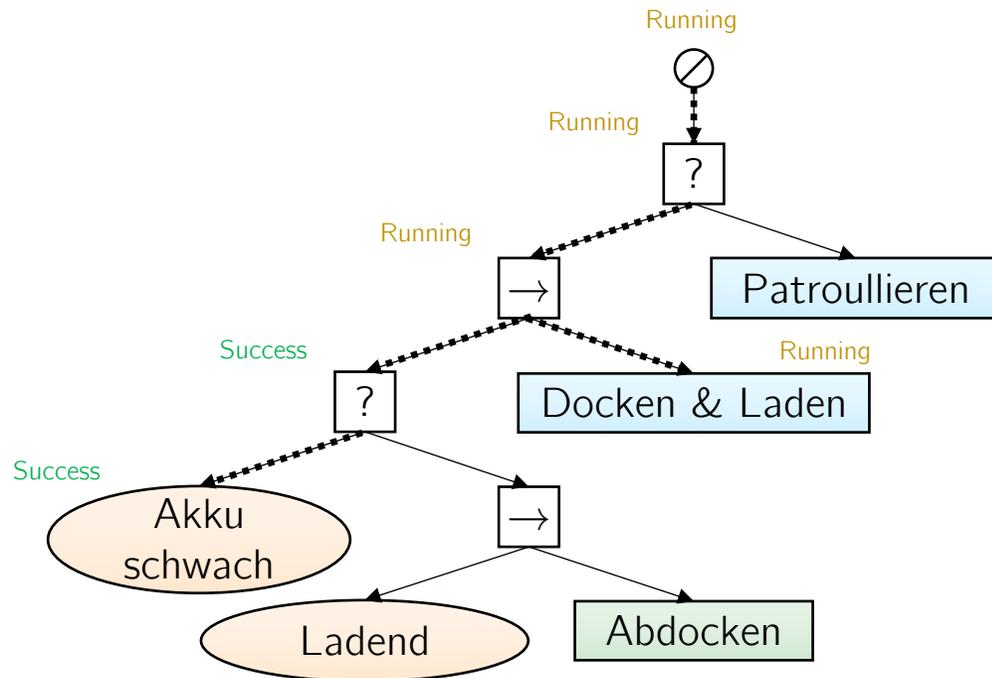
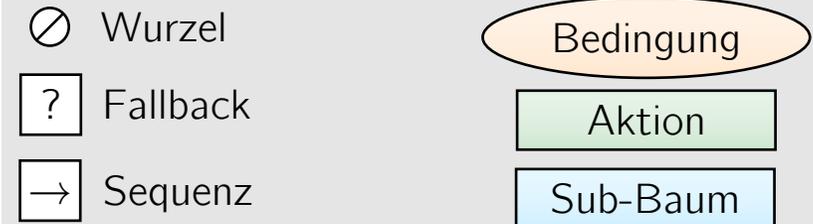


Behavior Trees

Behavior Trees

- Gerichteter Baum mit Knoten für Steuerungsablauf und Aufgabendurchführung
- Kindknoten geben entweder **Success**, **Failure** oder **Running** zurück
- Leserichtung: Links nach rechts, oben nach unten

Legende



Behavior Tree zur Beschreibung eines autonomen Ladeverhaltens
(Andocken und Laden)



Motivation

Steuerungs- und Überwachungssystem

1. Systemüberwachung & -wiederherstellung

- Softwarekomponenten überwachen
- Wiederherstellungsverhalten durchführen

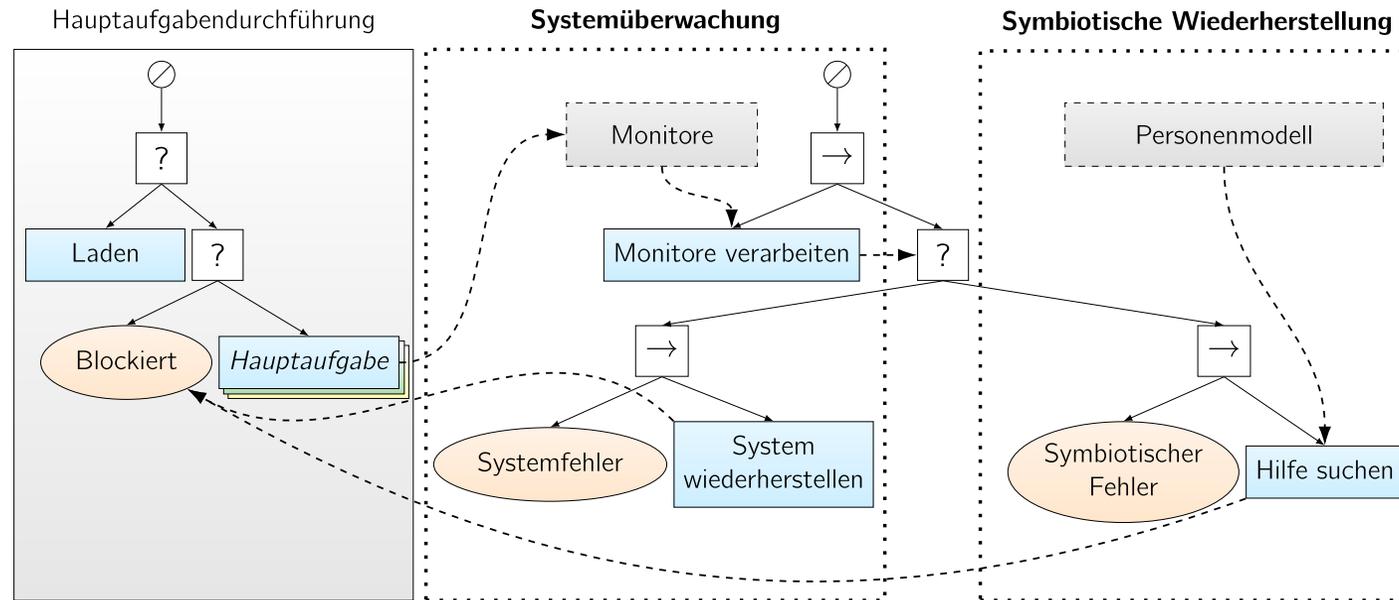
2. Symbiotische Aufgabendurchführung

- Menschliche Hilfe durch Unbeteiligte, Teleoperation

Symbiotische Autonomie

Erkennen **individuell unlösbarer** Situationen und **aktiver Einbezug des Menschen** in die Problemlösung (Rosenthal et al., 2012)

- Stand der Technik:
 - Kaum Arbeiten zu proaktiver Suche
 - Evaluation i.d.R. simulativ



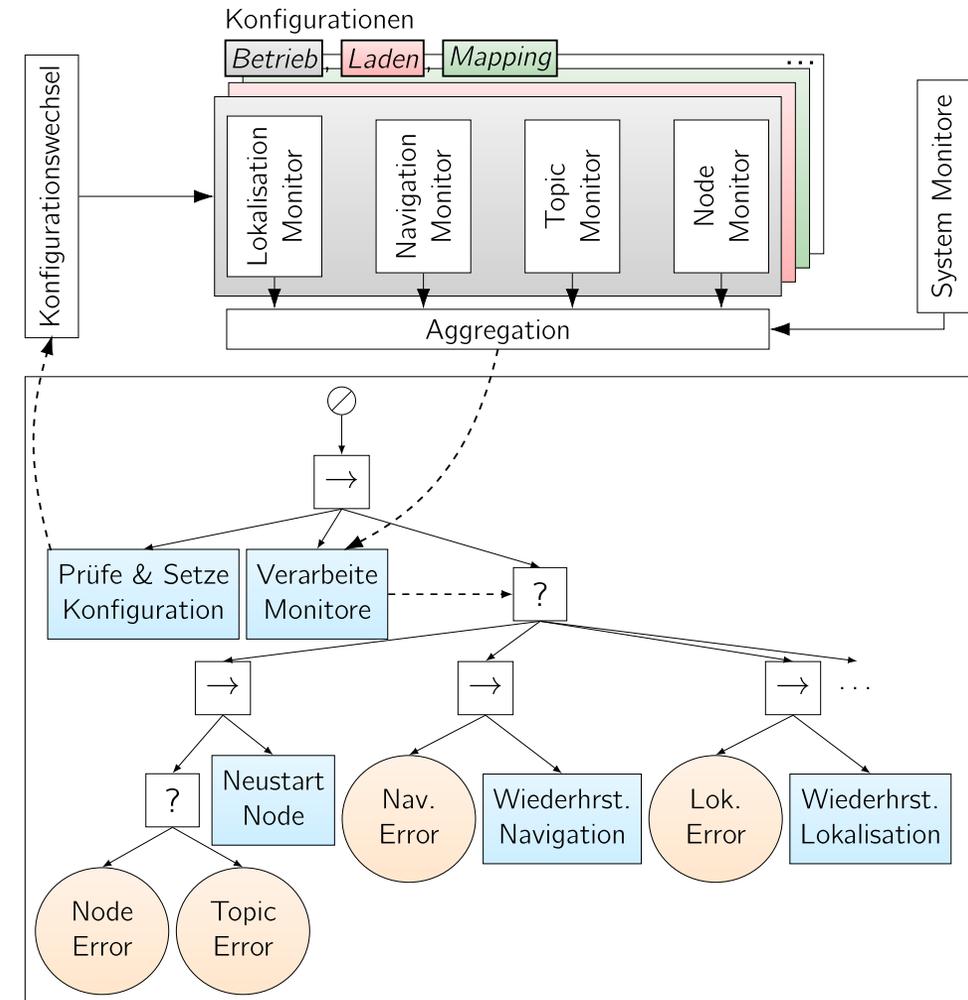
Struktur des Behavior Tree basierten Steuerungssystems

Behavior Tree zur Systemüberwachung

Monitore & Wiederherstellung

- Überwachung von Systemkomponenten und Software
- Teilweise mehrstufiger Wiederherstellungsprozess

Name	Detektion	Wiederherstellungsreaktion
Node Monitor	Node nicht pingbar	Node neu starten
Topic Monitor	Sendefrequenz nicht in Toleranzband	Sendernode neu starten
CPU, RAM, NTP, Netzwerkmonitor	Nicht in Toleranzband	Nachricht senden
Navigationsmonitor	Kein globaler Pfad gefunden und MoveBase Wiederherstellung fehlgeschl.	<ol style="list-style-type: none"> 1. Warten und neu starten 2. Rückwärtsfahrt 3. Teleoperation anfordern
Lokalisationsmonitor	Kein Schleifenschluss erkannt	<ol style="list-style-type: none"> 1. Langsam rotieren 2. Lokalisation neu starten 3. Langsam rotieren 4. Teleoperation anfordern



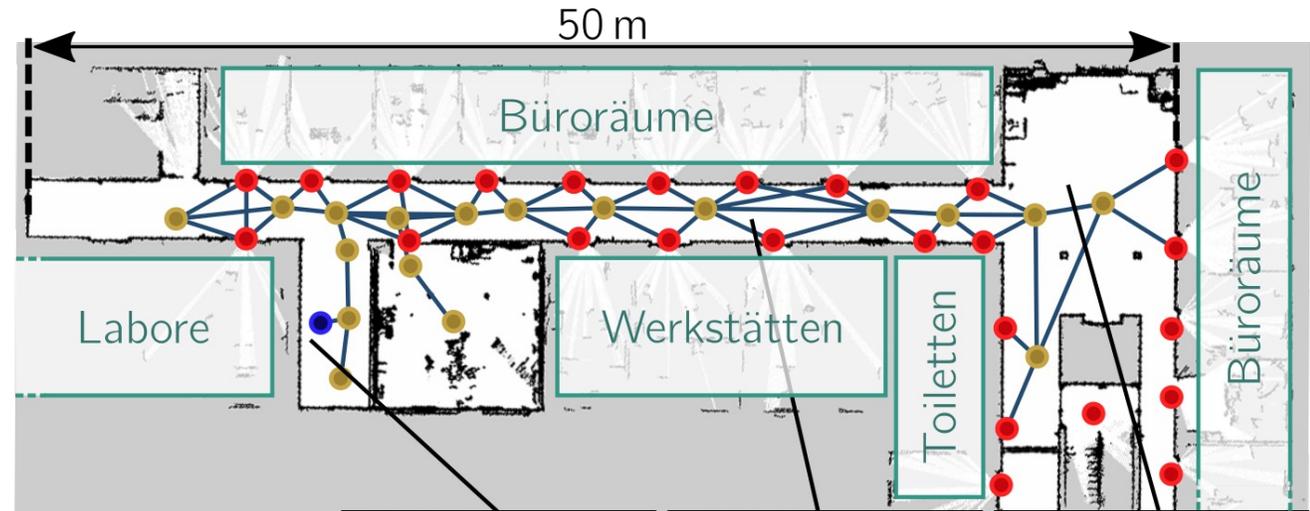
Ergebnisse

Aufgabe

- Evaluationszeitraum: 16 Tage
- Tagsüber Patrouillieren eines Flures (9:00 – 17:00 Uhr)
- Laden sobald notwendig sowie nachts

Kriterien

- Mittlere Bewegungsdauer pro Tag t_m
- Mittlere Betriebsdauer pro Tag t_o
- Autonomieanteil $A\% = t_m/t_o$
- Anzahl/Erfolg von Wiederherstellungsverhalten



-  Wegpunkt
-  POI/Raum
-  Ladestation

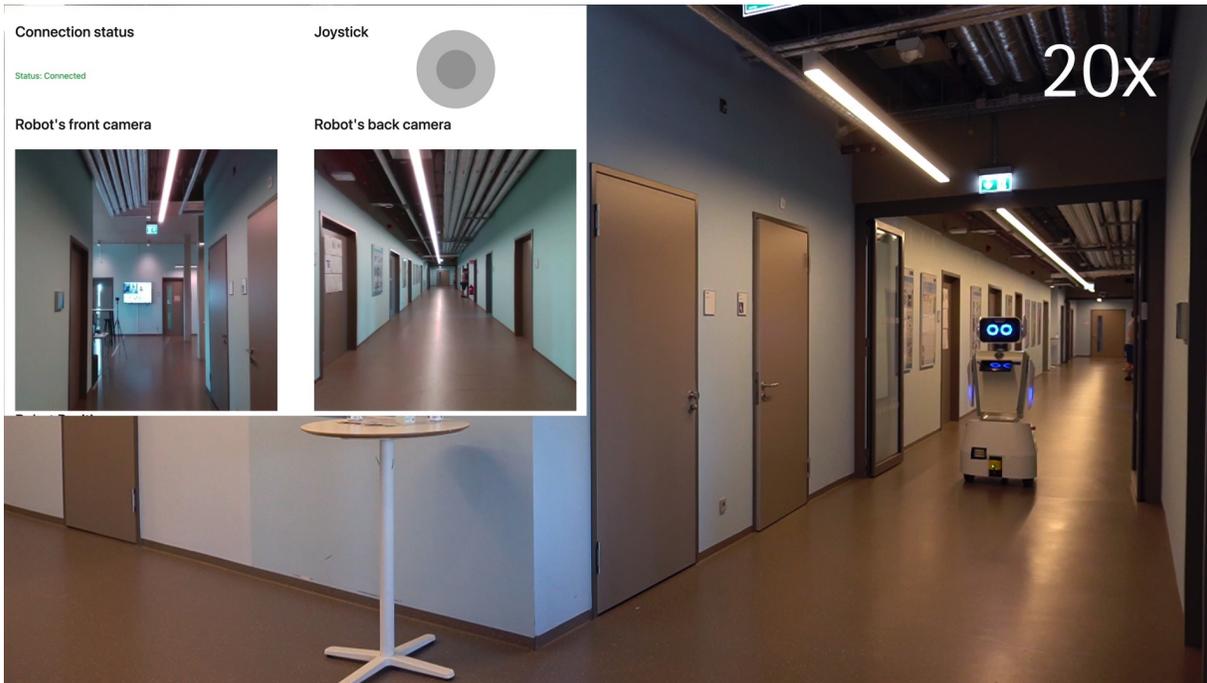


Zur Validierung genutzte Umgebung

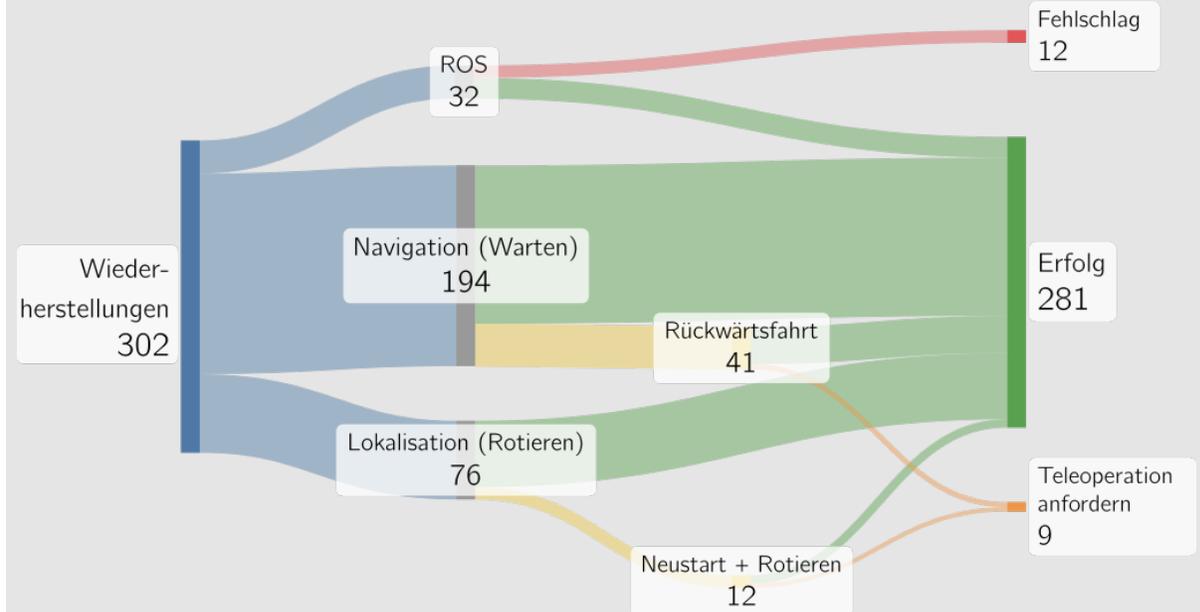
Ergebnisse

Metriken

- Mittlere tägliche Bewegungsdauer $t_m = 5,5$ h
- Mittlere tägliche Betriebsdauer $t_o = 5,9$ h
- Autonomieanteil $A\% = 93\%$
- Zurückgelegte Distanz 66,6 km



Wiederherstellungsverhalten



- Fehler i.d.R. durch simple Wiederherstellungen lösbar
- Teleoperation über Webschnittstelle
- Vier ungeplante Interventionen notwendig
- Hauptproblem: Umgebungsänderungen, Blockaden

Symbiotische Autonomie: Behavior Tree zur Personensuche

Idee

- Behavior Tree (BT) Framework nutzen, um Personen zu finden
- Synthese des BT basierend auf stochastischem Umgebungsmodell des Personenaufkommens

Stochastic Behavior Trees (Colledanchise et al., 2014)

- BT in diskrete Markov Kette (DTMC) konvertieren

$$A_{\text{sbt}} : \langle p_s(t), p_f(t), \mu, \nu \rangle, C_{\text{sbt}} : \langle p_s(t), p_f(t) \rangle$$

Erfolgswahrsch. \uparrow $p_s(t)$ \uparrow Fehlschlagsrate $p_f(t)$
 Fehlschlagswahrsch. \uparrow $p_f(t)$ \uparrow Erfolgsrate μ

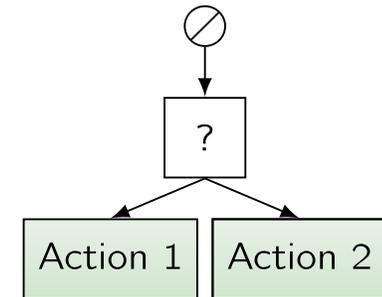
- Erfolgswahrscheinlichkeit (BT)

$$p_{s,T}(t) = \sum_{i:s_i \in \mathbb{S}_S} \pi_i(t)$$

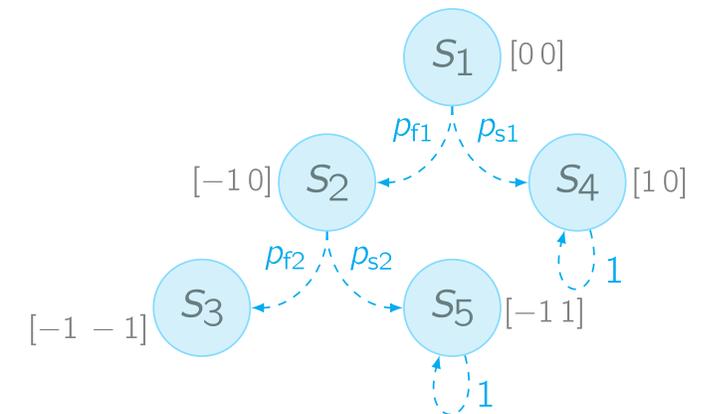
$\pi_i(t)$ ← Zustandswahrscheinlichkeit
 $i:s_i \in \mathbb{S}_S$ ← Menge erfolgreicher Zustände

- Erfolgsrate

$$\mu_T = \text{avg} \left(\frac{\sum_{i=1}^{|\mathbb{S}_S|} u_{i1}^S(\kappa) \log(h_{i1}^S(\kappa))}{\sum_{i=1}^{|\mathbb{S}_S|} u_{i1}^S(\kappa)} \right)^{-1}$$



Beispielhafter Behavior Tree



Zugehörige Markov Kette

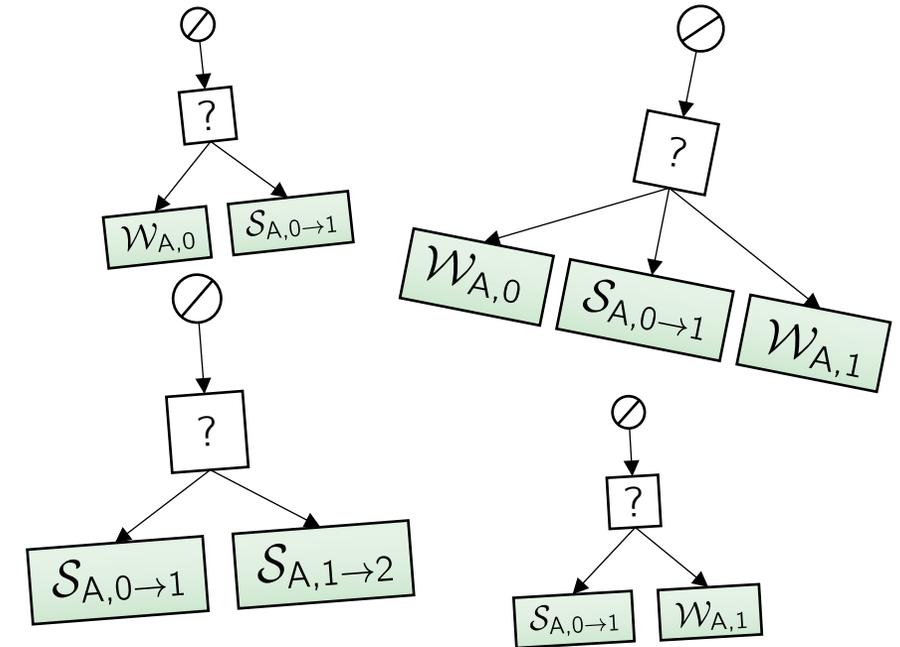
Behavior-Tree-basierte Personensuche

Ziel

- Eine Sequenz aus Aktionen finden, welche zu einer möglichst geringen Dauer bis zum Antreffen von Personen führt
- ⇒ Wo sollte der Roboter suchen, und wo auf Personen warten?

Ansatz

- Definiere atomare Aktionen $\mathcal{W}_{A,i} \supseteq A_{sbt}$ und $\mathcal{S}_{A,i \rightarrow j} \supseteq A_{sbt}$
 - $\mathcal{W}_{A,i}$: Warte an Ort x_i
 - $\mathcal{S}_{A,i \rightarrow j}$: Suche von Ort x_i zu Ort x_j } x_i, x_j aus Personenaufkommensmodell
 - Finde Wahrscheinlichkeiten für (Erfolg $p_s(t)$ / Fehlschlag $p_f(t)$)
 - Finde Raten für (Erfolg μ / Fehlschlag ν)
- Ermittle die beste Anordnung/Reihenfolge von Such- und Warteaktionen



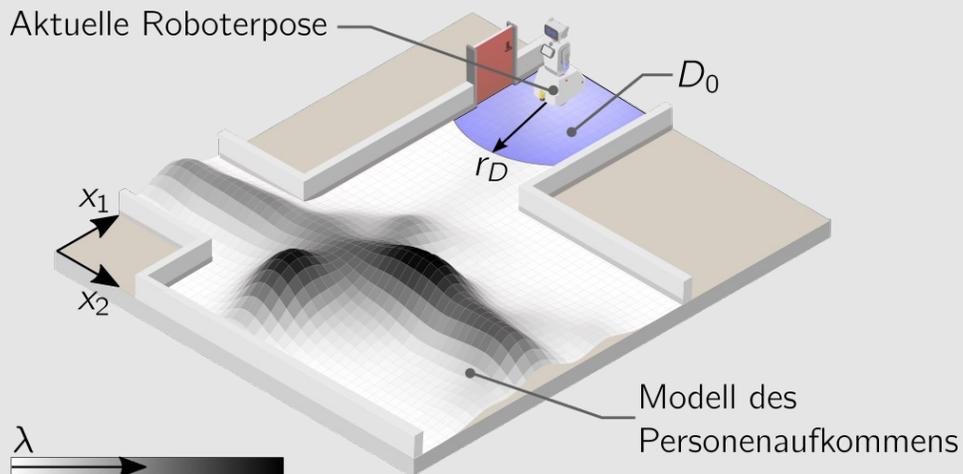
Aktionsdefinition

Warteaktion

- Erfolgsrate

$$\mu_w = \int_D \lambda(\mathbf{x}, t) d\mathbf{x}$$

- Fehlerrate über vorgegebene Konfidenz (z. B. $p'_s = 0,9$)
- Fehlschlagswahrscheinlichkeit $p_{f,w}(t)$ stückweise definiert



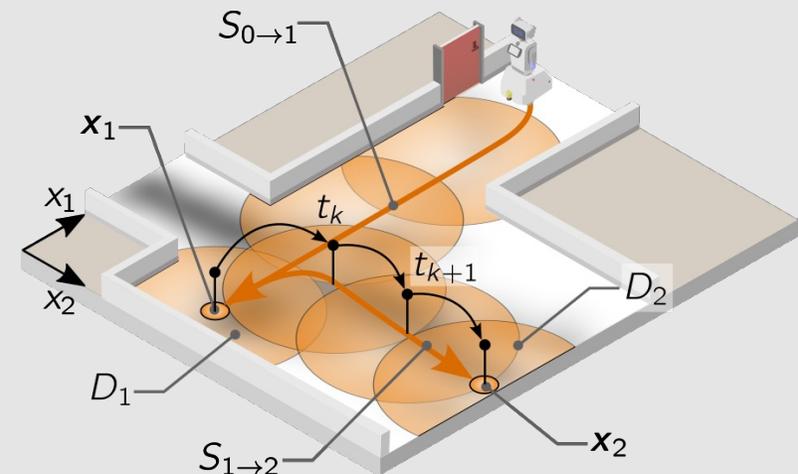
Suchaktion

- Erfolgsrate (zeitabhängig)

$$\mu_{sp}(t) = \int_{D(t)} \lambda(\mathbf{x}, t) d\mathbf{x}$$

⇒ Diskretisierung des Pfades mit $t_k = k \Delta t$ führt zu

$$\mu_{sp,tot}^{-1} = \arg \min_{t_k \in [t_0, t_0 + l/\bar{v}]} \left(t_k - \log(1 - p'_s) \mu_{sp,k}^{-1} \right)$$



t_0 : Startzeitpunkt der Suche l : Länge Suchpfad \bar{v} : Durchschn. Geschwindigkeit auf Suchpfad

Person Search Behavior Tree (PSBT)

Ziel

- Finde einen BT, der die Wahrscheinlichkeit maximiert auf Personen zu treffen

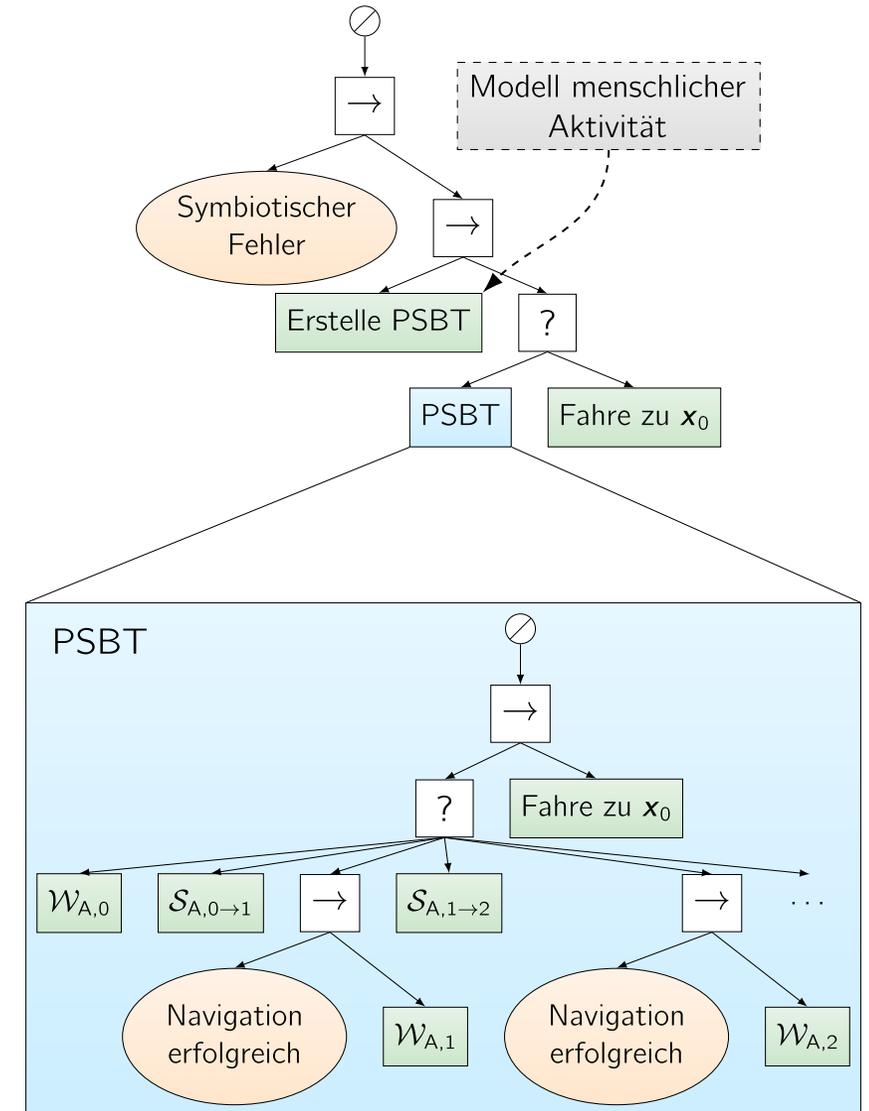
Sample n Orte mit Wahrscheinlichkeit $p \propto \lambda(\mathbf{x}, t)$

Berechne alle Aktionen $\mathcal{W}_{A,i}$ und $\mathcal{S}_{A,i \rightarrow j}$

Erstelle und löse das OTSP zur Komplexitätsreduktion

Für jede mögliche Kombination, löse die DTMC mit Generatormatrix $\mathbf{Q}(\mathbb{A}_{\text{sbt},\text{sp}}, \mathbb{A}_{\text{sbt},\text{w}})$

Wähle den Baum mit maximaler $p_{s,T}(t_{\max})$



Experimentelle Validierung

Umgebung und Modellerstellung

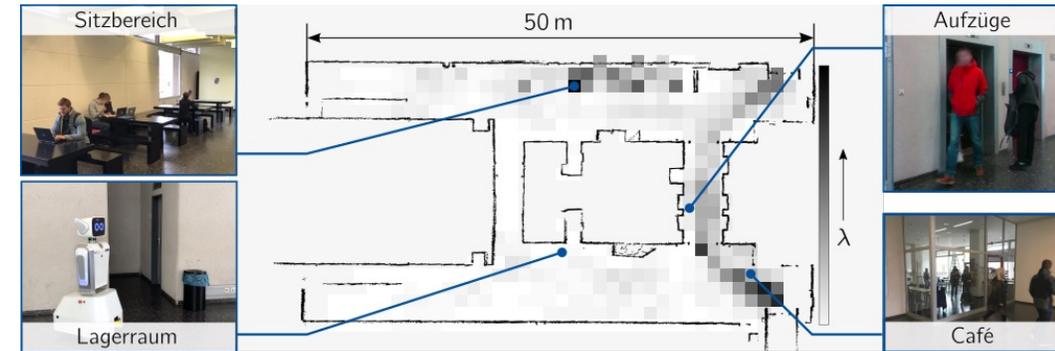
- Universitätsgebäude mit Hörsälen, Cafeteria, mehreren Eingängen, Sitzbereichen
- Statisches Aktivitätsmodell mit Daten von zwei Tagen

Vergleichsmethoden

- **GC/GM**: Greedy Planung zu einem (nahen, GC) Ort mit hoher Rate
- **W**: Warten am Startpunkt
- **RND**: Zufällige Zielsuche
- **PP**: Funktionsweise wie PSBT, aber nie wartend (*purely proactive*)

Experimente

- Modellbasierte Evaluation (simulativ)
- Onlineplanung und anschließende Personensuche (real)



Validierungsumgebung + erzeugtes Aktivitätsmodell



Ergebnisse

Durchführung

- Zwei Startpunkte, Alternierende Durchführung an fünf Werktagen
- Insgesamt 588 Testdurchläufe

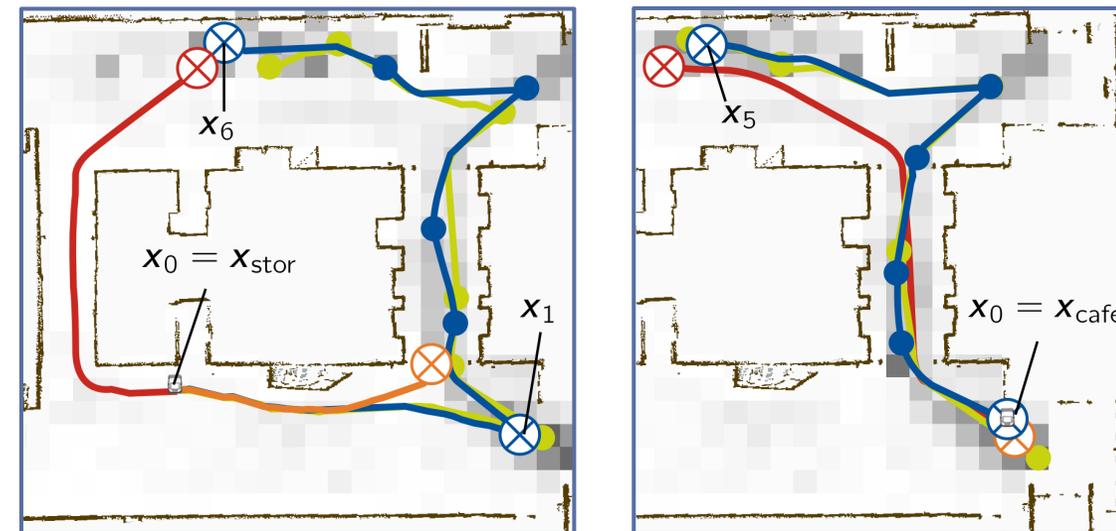
Zusammenfassung

- PSBT benötigt durchschn. mehr Zeit als Greedy Methoden
- Aber: Von insgesamt 198 Durchläufen 94% erfolgreich

Tab. (rechts): Ergebnisse des Realexperiments im Universitätsgebäude

\bar{t}_r : Durchschnittlich benötigte Zeit zum Finden einer Person

PSBT GC GM PP



Exemplarische Suchpfade für zwei Startpunkte. Gekreuzte Kreise geben Warteorte an.

Startort	Method	# Versuche	% erfolgreich	\bar{t}_r in s
x_{stor}	e		98,8%	
	PSBT	86	98,8%	120,5±61,2
	PP	93	88,2%	115,4±52,3
	GM	86	62,8%	89,1±49,7
x_{cafe}	GC	90	65,6%	89,1±49,7
	PSBT	112	91,1%	35,5±28,2
	PP	121	90,1%	63,0±48,9

Forschungsfrage 3

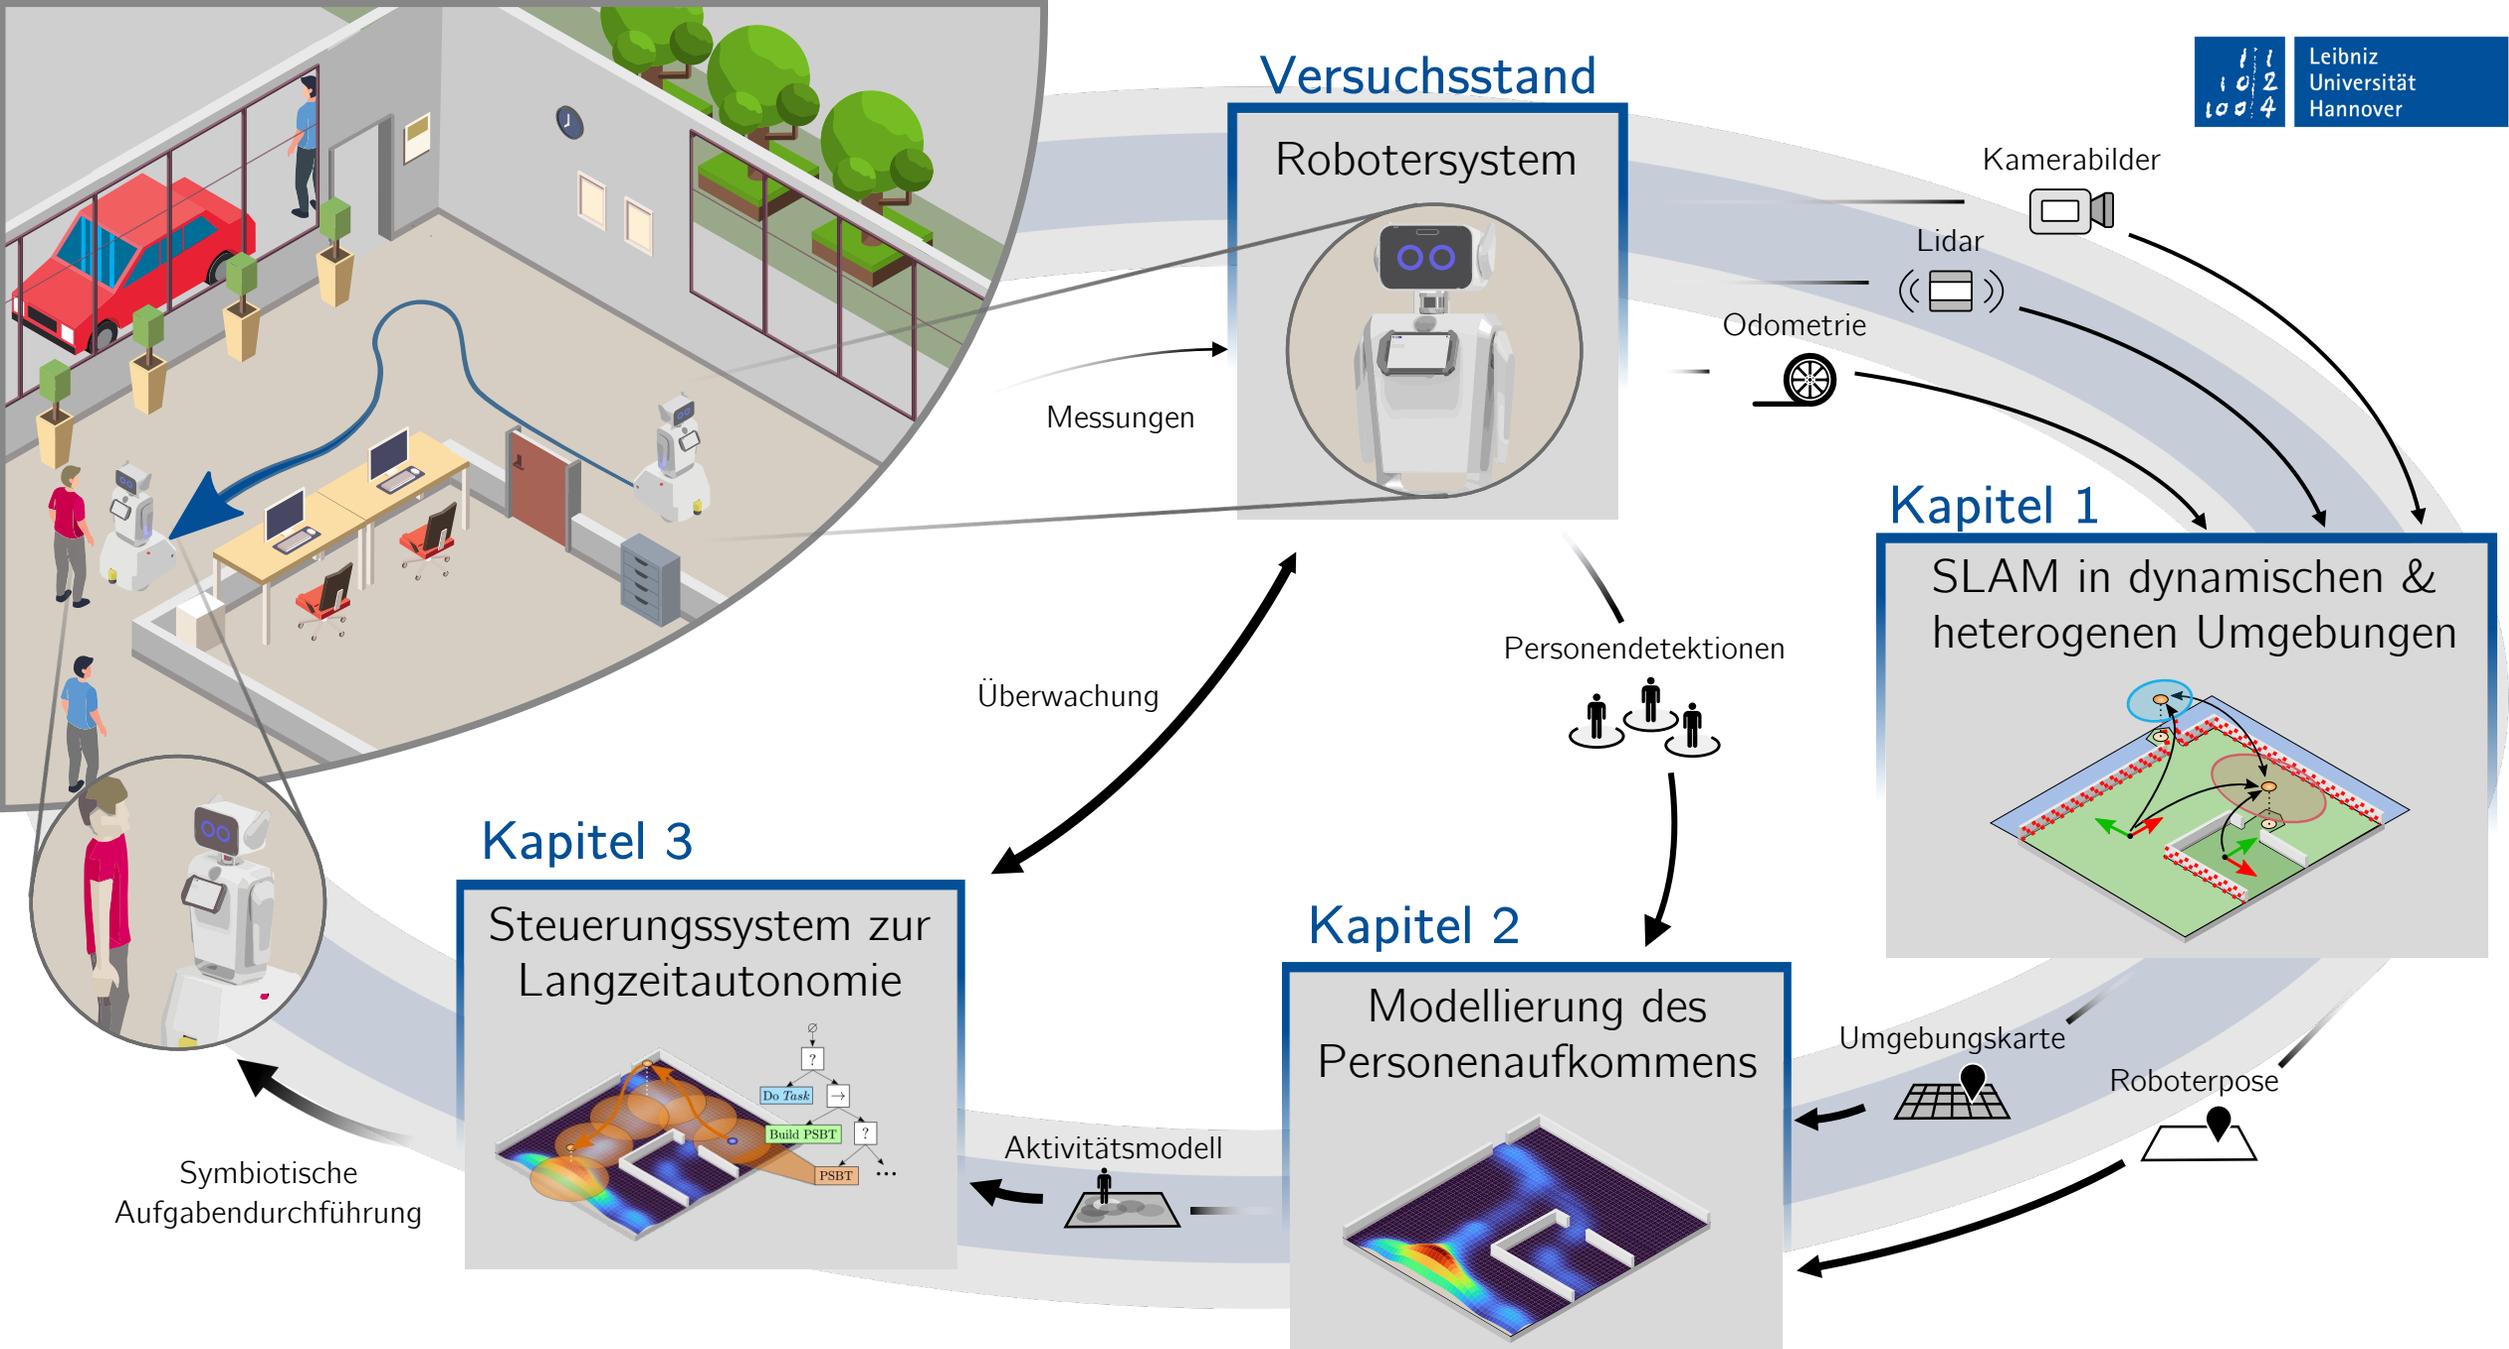
Wie können **Modelle menschlicher Aktivität** in autonome **Steuerungssysteme** integriert und zur **Verbesserung der Langzeitautonomie** genutzt werden?

Antwort

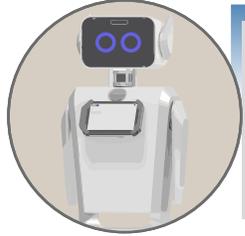
- **Reaktives** Überwachungs- und Steuerungssystem als **Behavior Tree** modellieren
- Automatische Synthese eines Behavior Trees bestehend aus **Warte-** und **Suchaktionen**
- Effiziente Suche nach Personen, die bei Problemlösung helfen könnten
- Publiziert in [1, 5]

[1] Marvin Stüde, Konrad Westermann, Moritz Schappler, und Svenja Spindeldreier (2021b). "Sobi: An Interactive Social Service Robot for Long-Term Autonomy in Open Environments".
In: *10th European Conference on Mobile Robotics (ECMR)*

[5] Marvin Stüde, Timo Lerche, Martin Alexander Petersen, und Svenja Spindeldreier (2021a). "Behavior-Tree-Based Person Search for Symbiotic Autonomous Mobile Robot Tasks".
In: *2021 IEEE International Conference on Robotics and Automation (ICRA)*

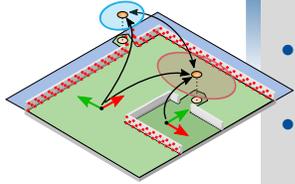


Versuchsstand Robotersystem



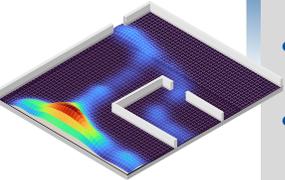
- Roboter für langzeitautonome Nutzung
- Innen- und Außenbereiche

Forschungsfrage 1 SLAM in dynamischen & heterogenen Umgebungen



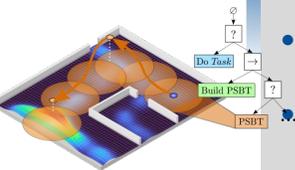
- Lidar-basierte Erweiterung für Graph VSLAM Verfahren
- Automatischer Konfigurationswechsel

Forschungsfrage 2 Modellierung des Personenaufkommens



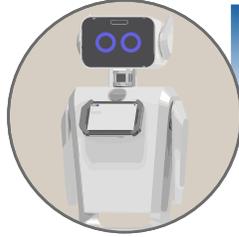
- Nichtparametrisches räumlich-zeitliches Modell
- Kontinuierliche Prädiktionsfunktion für lange Zeithorizonte

Forschungsfrage 3 Steuerungssystem zur Langzeitautonomie



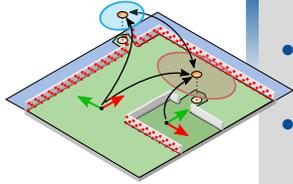
- Steuerungsmodell für symbiotische Autonomie
- Synthese eines stochastischen Behavior Trees

Versuchsstand Robotersystem



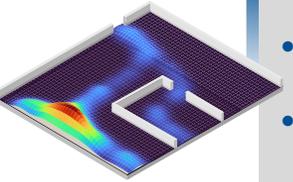
- Roboter für langzeitautonome Nutzung
- Innen- und Außenbereiche

Forschungsfrage 1 SLAM in dynamischen & heterogenen Umgebungen



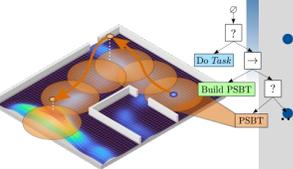
- Lidar-basierte Erweiterung für Graph VSLAM Verfahren
- Automatischer Konfigurationswechsel

Forschungsfrage 2 Modellierung des Personenaufkommens



- Nichtparametrisches räumlich-zeitliches Modell
- Kontinuierliche Prädiktionsfunktion für lange Zeithorizonte

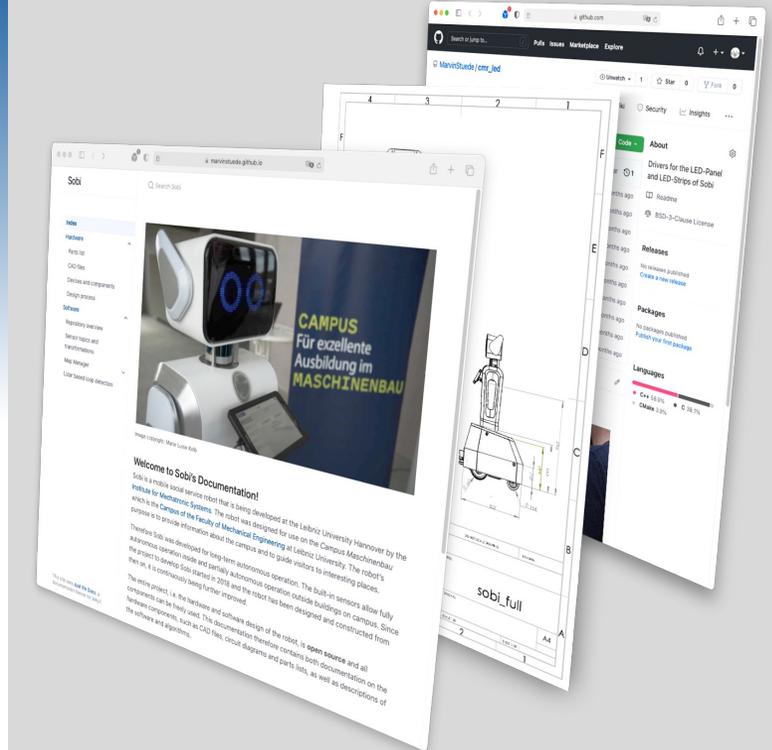
Forschungsfrage 3 Steuerungssystem zur Langzeitautonomie

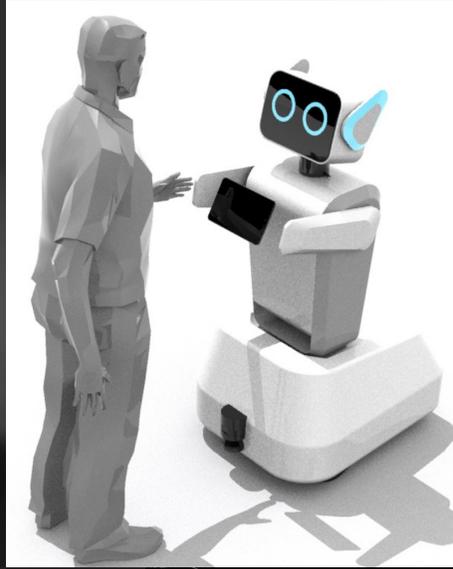
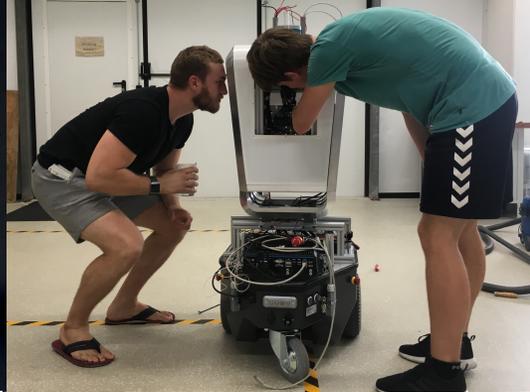
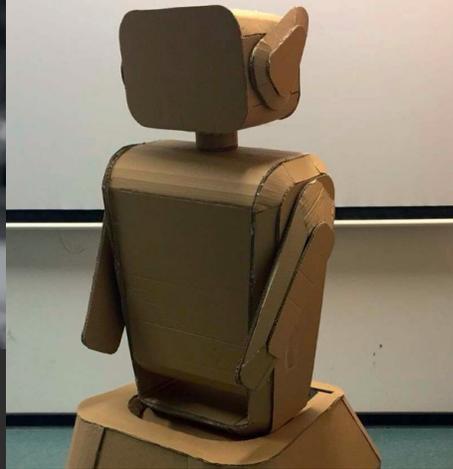
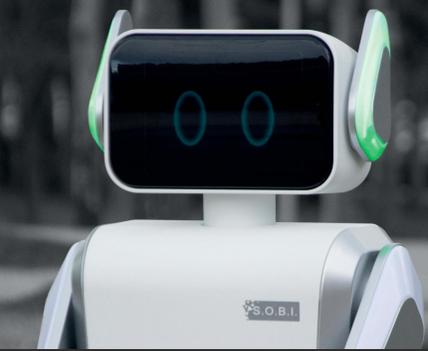


- Steuerungsmodell für symbiotische Autonomie
- Synthese eines stochastischen Behavior Trees

Open Source

<https://marvinstuede.github.io/Sobi/>





Danke!

