

# Navigation mit einem Bodenradar als Lokalisierungssensor

## Navigation with a ground penetrating radar as localization sensor

**Ilja Stasewitsch  
Jan Schattenberg  
Ludger Frerichs**

*Institut für mobile Maschinen und Nutzfahrzeuge  
Technische Universität Braunschweig*

**S**ysteme zur Lokalisierung von mobilen Robotern haben je nach Messprinzip gewisse Nachteile. So stoßen beispielsweise Systeme mit Kameras in rauen Umgebungen mit Staub, Schmutz und Wetter an ihre Grenzen. Um diese Probleme zu überwinden, wird ein robustes Lokalisierungssystem entwickelt, das aus einem Bodenradar und einer Monte-Carlo-Lokalisierung besteht. Zu diesem Zweck tastet das Radar langzeitstabile Merkmale im Untergrund ab, die für die Lokalisierung verwendet werden. Neben der Lokalisierung wird auch die Navigation mit diesem System dargestellt.

*[Schlüsselwörter: Navigation, Bodenradar, Lokalisierung, Künstlich Neuronale Netz, Mobilroboter]*

**S**ystems for localizing mobile robots have certain disadvantages depending on the measurement principle. For example, systems with cameras reach their limits in harsh environments with dust, dirt and weather. To overcome these problems, a robust localization system is being developed that consists of ground-based radar and Monte Carlo localization. For this purpose, the radar scans long-term stable features in the subsurface that are used for localization. In addition to localization, navigation is also represented.

*[Keywords: Navigation, Ground Penetrating Radar, Localization, Artificial Neural Network, Mobile Robot]*

### 1 EINLEITUNG

Ein mobiler Roboter zeichnet sich dadurch aus, dass er sich frei im Raum bewegen kann, ohne dass eine physische oder elektromechanische Führung erforderlich ist. Nach [1] beschäftigt sich die mobile Robotik mit Methoden und Algorithmen zur Navigation solcher Roboter. Die Hauptaufgaben dafür sind Kartierung, Lokalisierung, Umfelderkennung, Sensorinterpretation von nicht-visuellen Sensoren, Bahnfolgeregelung sowie Aufgaben- und Bahnplanung. Die Lokalisierung ist der zentrale Punkt in der Navigation, da dieses Modul sich im Regelkreis der Bahnfolgeregelung befindet und ein Roboter nur auf dieser Basis den Weg zu

seiner Zielposition steuern kann. Für die absolute Lokalisierung stellen Kalman-Filter und Monte-Carlo-Lokalisierung den Stand der Technik dar [2]. Das Problem der Lokalisierung ist oft mit der Kartierung verbunden. Im Falle der gleichzeitigen Lokalisierung und Kartierung (englisch: Simultaneous Localization and Mapping) erfolgt die Lokalisierung parallel zur Kartierung. Hierfür stellt die Graph-SLAM-Methode den aktuellen Stand der Technik dar [3].

### 1.1 MOTIVATION

Die Lokalisierung ist für die Navigation von mobilen Robotern essentiell, daher sind Robustheit und Genauigkeit wichtige Kriterien für sie. Bestehende Lokalisierungssysteme haben den Nachteil, dass entweder die Robustheit oder die Genauigkeit in bestimmten Situationen nicht ausreichend ist. Dies schränkt sowohl die Anwendungsbereiche als auch die Einsatzdauer (kein 24/7-Betrieb) dieser Systeme ein. Bei GNSS-Techniken wie GPS erhöht sich z. B. die Ungenauigkeit durch die Abschattung von Gebäuden und unterliegt zudem Genauigkeitsschwankungen durch Mehrwegempfang. Optische Sensoren haben den Nachteil, dass ihre Funktion bei schlechten Umweltbedingungen (Regen, Nebel, Staub usw.) eingeschränkt sein kann, was sogar zu Sensorausfällen führen kann. Andere Möglichkeiten der Lokalisierung, welche nicht auf optischen Sensoren oder GNSS-Techniken basieren, verwenden beispielsweise RFID-Lesegeräte [4] oder rotierende Radarsensoren [5]. Die RFID-Technik hat den Nachteil, dass eine Infrastruktur aufgebaut und gewartet werden muss. Bei der Lokalisierung mit einem rotierenden Radarsensor kann zwar eine hohe Genauigkeit erreicht werden, allerdings besitzt ein solches Sensor-System nur ein zweidimensionales Sichtfeld und eine geringe Scanfrequenz. Dies schränkt die Einsatzmöglichkeiten ein.

### 1.2 ZIELSETZUNG

Um die oben genannten Anforderungen zu erfüllen bzw. die Nachteile der beschriebenen Techniken zu beseitigen, wird in diesem Aufsatz ein Lokalisierungssystem mit einem Bodenradar vorgestellt. Dieser Sensor mit mehreren Antennen misst ein Tiefenprofil des Bodens, einen

sogenannten Sweep pro Antenne, der Merkmale des Untergrundes enthält. Zur Lokalisierung eines Roboters werden die stabilen Strukturen des Bodens verwendet, die in der Regel die unveränderlichen natürlichen oder künstlichen Bodenstrukturen sind. In [6] wird mit diesem Verfahren ein Straßenfahrzeug bis zu einer Geschwindigkeit von 100 km/h lokalisiert. Als Algorithmus wird die Partikelschwarmoptimierung verwendet. Mit jeder Radarmessung sucht der Algorithmus nach der Fahrzeugposition, die am besten in die gitterbasierte Karte passt. Ein Partikel hat fünf Zustände: x-Position, y-Position, Höhe des Sensors, Orientierung und Rollwinkel. Die Höhe und die Rollneigung sind erforderlich, um die Karoserieschwingung des Fahrzeugs zu berücksichtigen.

Dieser Ansatz wurde von den Autoren für Offroad-Fahrzeuge mit der Monte-Carlo-Lokalisierung (Partikelfilter) bereits in [7] aufgegriffen, aber wie in [6] wurde der Roboter nur lokalisiert. In diesem Aufsatz soll ein Versuchsboter nicht nur lokalisiert werden, sondern mit dem Bodenradar-Lokalisierungssystem navigiert werden. D. h. der Regelkreis der Bahnfolgeregelung soll geschlossen werden.

## 2 VERSUCHSROBOTER UND -UMGEBUNG

Für die Entwicklung des Lokalisierungssystems wird ein Testroboter verwendet, der in Abbildung 1 dargestellt ist. Er verfügt über drei unabhängige Fahr-Lenk-Module, durch die ein holonomer Roboter entsteht. Die Module haben einen Lenkwinkel von  $\pm 180^\circ$  und können individuell gesteuert werden. Dadurch kann der Roboter sowohl seitwärts fahren als auch auf der Stelle drehen. Das Lenk- und Antriebskonzept ermöglicht eine Kartierung mit mäandrierenden Bahnen und schwer zugänglichen Bereichen. Für die externe Indoor-Lokalisierung wird ein SICK Nav350 eingesetzt, der über einen landmarkenbasierten Lokalisierungsalgorithmus verfügt. Abbildung 2 zeigt eine Landmarke als Beispiel, welche in der Versuchshalle installiert



Abbildung 1. Holonomer Versuchsroboter mit SICK Nav 350 und GNSS-Antennen zur Lokalisierung

wurde. Im Außenbereich kommt ein RTK-GNSS mit zwei Empfangsantennen zum Einsatz. Die Orientierung des Fahrzeugs wird durch die zweite GNSS-Antenne bestimmt. Zur Bahnregelung des Roboters wird der Bahnführungsrechner HG G-73650ZD des Projektpartners Götting KG verwendet. Dieser nutzt einen geometrischen Ansatz mit einer Vorausschaulänge und eine Vorsteuerung [8]. Die

Vorsteuerung ist essentiell, da eine Regelung erst bei einer Abweichung eine Stellgröße ausgibt. Die Regelung wird an die Fahrgeschwindigkeit angepasst. Die Fahrgeschwindigkeit selbst wird zu Beginn und zum Ende einer Bahn bzw. eines Bahnsegments über Rampen gesteuert.

Für Indoor-Szenarien wird als Versuchsfeld die Versuchshalle des Instituts für mobile Maschinen und Nutzfahrzeuge (IMN) der TU Braunschweig genutzt. In dieser sind 10 Reflektor-Landmarken installiert (siehe Abbildung 2). Zwei davon befinden sich außerhalb des Gebäudes, um Innen- und Außenszenarien zu testen. Die Landmarken wurden mit einer Totalstation (Tachymeter) vermessen, um eine gute Genauigkeit bei der Lokalisierung zu erreichen.



Abbildung 2. Links: Reflektorlandmarke. Rechts: Versuchshalle des IMN als Versuchsfeld

## 3 BODENRADAR

Das Konzept des Radars (radio detection and ranging) ist bereits 1904 erstmalig zum Patent angemeldet worden. Diese Technik ist z. B. in [9] theoretisch gut aufgearbeitet. Heute werden Radarsysteme für viele Aufgaben im Bereich der Detektion und Lokalisierung von Objekten eingesetzt, bspw. in der Flugsicherung oder in der KFZ-Umfeldsensorik. Weiterhin werden Bodenradare z. B. im Bauwesen, bei der Lokalisierung von Versorgungsleitungen, in der Archäologie und beim Minenräumen verwendet. Ein Radarsystem bestimmt den Abstand eines Objekts, indem die Laufzeit oder Phasenverschiebung eines ausgesendeten und vom Objekt zurück gestreuten Signals gemessen wird. Im einfachsten Fall wird ein impulsförmiges (ggf. trägerfrequentes) Signal verwendet, bei dem Laufzeit bzw. Abstand (im Zeitbereich) direkt gemessen werden; dies ist auch der Standard bei existierenden Bodenradarsystemen. Nachteilig ist, dass die Impulsform/Bandbreite normalerweise nicht verändert werden kann, sondern für verschiedene Anwendungen unterschiedliche Antennen verwendet werden. Grundsätzlich ist die Ortsauflösung abhängig von der Bandbreite, die nutzbare Bandbreite ist aber durch die Antenne sowie durch die Eindringtiefe begrenzt, da der (feuchte) Boden bei höheren Frequenzen überproportional stark dämpft. Typische Bodenradarsysteme sind so ausgelegt, dass Mittenfrequenz und Bandbreite ungefähr gleich sind. Ein 250-MHz-System erreicht in trockenen Böden einige Meter Eindringtiefe, wogegen 2-GHz-Geräte zur Untersuchung von Bauwerkstrukturen (Betonboden,

Aufbau von Fahrbahndecken) in trockenem Material geeignet sind. Beim Bodenradar sind die zu vermessenden Szenarien im Wesentlichen statisch. Daher kann das Radarsystem insoweit vereinfacht werden, dass auf eine Dopplerauswertung mit Hilfe von trägerfrequenten oder modulierten Signalen (Puls-Doppler, FMCW usw.) verzichtet wird und mit einem Stepped-Frequency-Radar im Frequenzbereich gemessen wird.

### 3.1 STEPPED-FREQUENCY-RADAR

Beim Stepped-Frequency-Radar wird die Frequenz schrittweise linear  $f_{\text{Schritt}}$  erhöht und sinusförmige Wellen in einer Zeitdauer von  $T_{\text{Welle}}$  ausgesendet. Das Prinzip ist in Abbildung 3 dargestellt. Gemessen werden die Phase und Amplitude jeder Frequenz. Die anschließende Signalverarbeitung [10] auf einem Computer wandelt es mittels der inversen Fouriertransformation (IFFT) in den Zeitbereich (A-Scan) um. Dies ermöglicht wiederum eine größere Flexibilität in der Messung und Signalauswertung sowie bei moderatem technischem Aufwand eine sehr große Bandbreite.

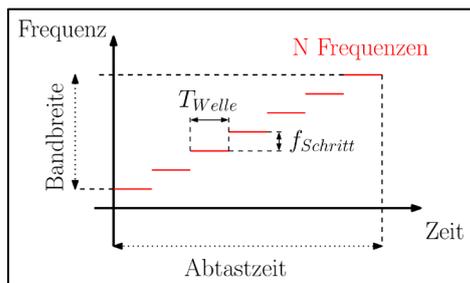


Abbildung 3. Schrittweise Erhöhung der Frequenz beim Stepped-Frequency-Radar mit Frequenzschrittweite  $f_{\text{Schritt}}$  und  $T_{\text{Welle}}$  als Zeitdauer einer Welle

Das Konzept des Bodenradars zur Lokalisierung für diesen Aufsatz des Projektpartners SF Microwave GmbH, ist in Abbildung 4 dargestellt. Das eingesetzte Radar deckt einen Frequenzbereich von 50 - 4400 MHz ab. Die zugehörigen Antennen stellt ist. Die zugehörigen Antennen sind auf eine hohe Auflösung im Nahbereich optimiert (500 – 4000 MHz). Das komplette System besteht aus drei Komponenten: dem Sensor selbst, einer Schaltmatrix und 11 Antennen. Der Sensor verfügt über eine Ultrahochfrequenzschaltung (UHF), die wie die Schaltmatrix von einem Mikrocontroller ( $\mu\text{C}$ ) gesteuert wird. Die Start-, Schritt- und Endfrequenz kann im Mikrocontroller eingestellt werden. Die Schaltmatrix sendet das Signal von der UHF-Schaltung an eine der 5 Sendeantennen (Tx) und leitet das Signal von der jeweiligen Empfangsantenne (Rx) zurück an die UHF-Schaltung. Diese Antennengruppe führt zu 10 Sweeps, indem zuerst Tx1 sendet und Rx1 empfängt, dann Tx1 sendet und Rx2 empfängt, dann Tx2 sendet und Rx2 empfängt usw. Mehr Antennen liefern mehr Informationen für die Lokalisierung der Position und soll die Bestimmung der Orientierung verbessern.

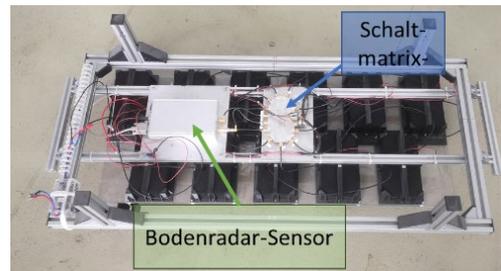
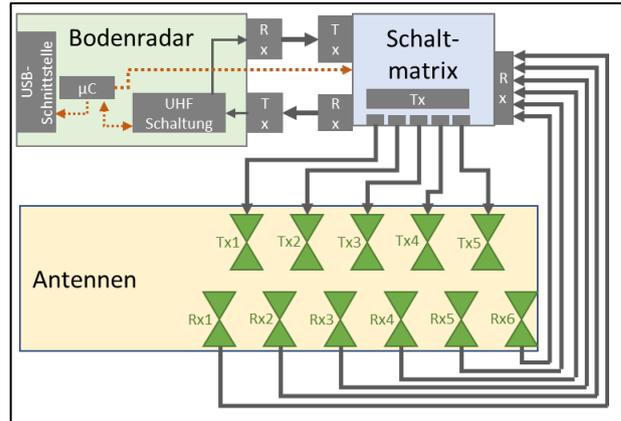


Abbildung 4. Prototypisches Stepped-Frequency-Bodenradar zur Lokalisierung. Oben: Konzept Mitte: Oberseite mit Sensor mit Schaltmatrix. Unten: Unterseite des Antennen-Arrays

### 3.2 SIGNALVERARBEITUNG ZUR LOKALISIERUNG

Um die Sweeps für die Lokalisierung nutzen zu können, müssen sie in geeigneter Weise verarbeitet werden. Nach der Transformation in den Zeitbereich werden Bereiche ohne Information bzw. stark verrauschte Bereiche durch Abschneiden des Daten-Arrays verworfen. Die anschließende Signalverarbeitungskette, die in Abbildung 5 dargestellt ist, läuft in 4 Schritten ab:

1. Anwenden eines Hochpassfilters: Ein Hochpassfilter 1. Ordnung nach Gl. (1) wird verwendet, um konstantes Rauschen und Reflexionen in den Koaxialkabeln sowie zwischen Erde und Antenne zu eliminieren. Die Filterparametrisierung erfolgt nur über den Parameter  $l$ . Anstelle einer Zeitdifferenz wird die zurückgelegte Länge  $\Delta L$  verwendet.

$$y_{i+1} = \frac{l}{l + \Delta L} (y_i + x_{i+1} - x_i) \quad (1)$$

2. **Logarithmieren in Dezibel:** Durch das Logarithmieren nach Gl. (2) werden die Radardaten interpretierbar, da der Wertebereich der Hochpass-gefilterten Daten mehrere Größenordnungen umfasst.

$$z_{i+1} = 20 \log_{10}(|y_{i+1}|) \quad (2)$$

3. **Datenverschiebung auf einen Median von 0 dB:** Damit die Kosinusähnlichkeit zur Gewichtung der Partikel in der Monte-Carlo-Lokalisierung verwendbar ist, ist es notwendig, dass die Minimal- und Maximalwerte eines Sweeps den gleichen Abstand zu 0 dB haben. Zu diesem Zweck werden die Daten mit einer Konstante  $C$  nach Gl. (3) addiert.

$$w_{i+1} = z_{i+1} + C \quad (3)$$

4. **Anwendung des 0 dB-Schwellenwerts:** Um sicherzustellen, dass negative Werte keinen zu großen Einfluss auf die Kosinusähnlichkeit haben, da sie wenig Informationen zur Unterscheidung von Sweeps haben, werden sie begrenzt. Dazu muss nach Gl. (4) die Konstante  $C_{0dB}$  bestimmt werden.

$$v_{i+1} = \begin{cases} w_{i+1}, & \text{wenn } w_{i+1} > C_{0dB} \\ 0 \text{ dB}, & \text{sonst} \end{cases} \quad (4)$$

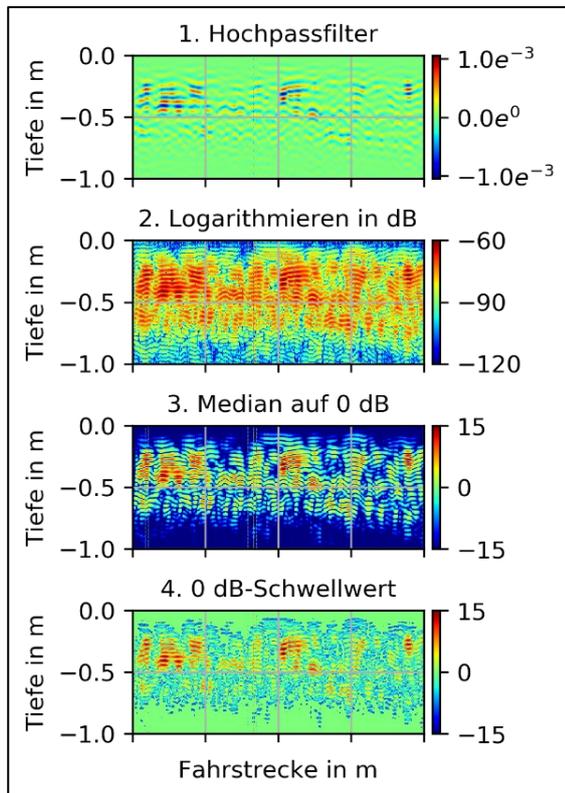


Abbildung 5. Signalverarbeitung der Bodenradardaten

#### 4 LOKALISIERUNG

Der in diesem Projekt entwickelte Lokalisierungsansatz besteht aus zwei Schritten. Im 1. Schritt wird eine Bodenkarte mit der externen Lokalisierung (s. Abschnitt 2) und den Radardaten (s. Abschnitt 3) erstellt. Im 2. Schritt wird ein Roboter mit aktuell gemessenen Sweeps und der Bodenkarte, aber ohne Verwendung des externen Lokalisierungssystems, lokalisiert. Dieser Algorithmus besteht aus einer Monte-Carlo-Lokalisierung (MCL) und einem Extended Kalman-Filter (EKF). Die Orientierung des Roboters wird aber mit der Odometrie und den Positionen der MCL berechnet wird (s. Abschnitt 4.2). Die Übersicht über das Bodenradar-Lokalisierungssystem ist in Abbildung 6 dargestellt. Die entwickelte MCL für dieses System ist bereits [7] ausführlich erläutert. Ein EKF ist Stand der Technik und wird z. B. in [2] erklärt, so dass an dieser Stelle nur die Konfiguration erwähnt wird.

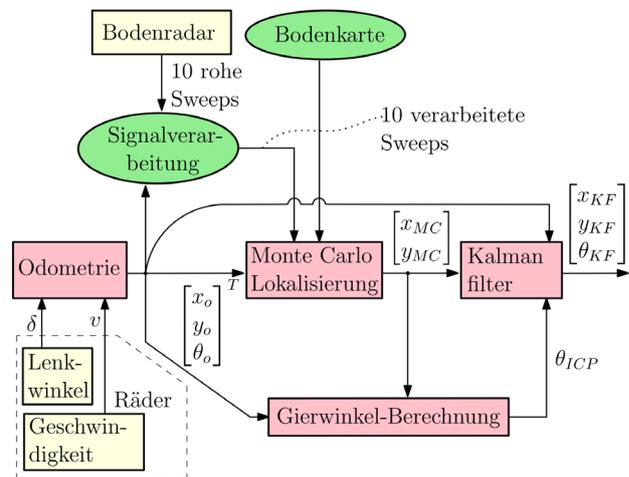


Abbildung 6. Überblick über das entwickelte Lokalisierungssystem mit dem Bodenradar als Lokalisierungssensor

Die Gewichtung eines Partikels erfolgt nach der Kosinusähnlichkeit  $cs \in [-1,1]$  aus Gl. (5), welche eine Verbindung zum Korrelationskoeffizient von Pearson hat. Die Variablen sind die Sweeps aus der Bodenkarte  $a$  und den aktuellen Sweeps  $b$  (hochpassgefiltert mit der Odometrie). Je größer die Übereinstimmung zwischen Karte und aktueller Messung, desto größer ist  $cs$  und somit wahrscheinlicher befindet sich der Roboter an dieser Position.

$$cs = \frac{\sum_{i=1}^n a_i b_i}{\sqrt{\sum_{i=1}^n a_i^2} \cdot \sqrt{\sum_{i=1}^n b_i^2}} \quad (5)$$

Die Positionslösung der entwickelten MCL rauscht; um dies zu reduzieren, werden die besten 10 von 100 Partikeln gemittelt. Jeder eingehende Sweep zur Lokalisierung wird mit der Distanz aus der Odometrie des jeweiligen Messpunktes hochpassgefiltert. Die Odometrie wird mit Hilfe der Fahrgeschwindigkeit  $v$  und des Lenkwinkels  $\delta$  des lenkenden Antriebsrads nach Gl. (5) berechnet. Der Radstand des Roboters ist  $l_r = 0,6$  m. Die MCL- Position

$x_{MC}, y_{MC}$  zeigt ein sprunghaftes Verhalten. Um dies zu reduzieren, wird eine EKF genutzt, wobei die Odometrie zur Prädiktion dient. Die Prozess-Kovarianzmatrix (6) wird dazu mit hohem Vertrauen gewichtet und die Beobachtungs-Kovarianzmatrix (7) wird weniger stark gewichtet. Der Gierwinkel der MCL ist mit einem hohen Fehler behaftet, weshalb – wie im Abschnitt 4.2 erklärt wird – der Gierwinkel  $\theta_{ICP}$  mit dem iterativen Closest-Point-Algorithmus (ICP) berechnet wird.

$$\begin{bmatrix} \dot{x}_o \\ \dot{y}_o \\ \dot{\theta}_o \end{bmatrix} = \begin{bmatrix} v \cos \theta_o \\ v \sin \theta_o \\ \frac{v}{l_r} \tan \delta \end{bmatrix} \quad (5)$$

$$\text{diag}(\mathbf{Q}) = [1 \quad 1 \quad 2]^T \cdot 10^{-4} \quad (6)$$

$$\text{diag}(\mathbf{R}) = [1 \quad 1 \quad 10]^T \quad (7)$$

#### 4.1 KARTIERUNG

Die Bodenkarte zur Lokalisierung eines Roboters wird durch Verschmelzung der externen Lokalisierung und der verarbeiteten Radardaten erstellt. Jeder Radar-Sweep wird mit einer Position dieses Lokalisierungssystems referenziert. Die Karte wird zur Datenreduzierung als Quadtree gespeichert, wobei jeder Punkt einen gefilterten Sweep als Nutzdaten erhält (siehe Abbildung 7). Ein Quadtree unterteilt einen zweidimensionalen Raum rekursiv in vier Regionen. Dies ist dateneffizient und die Suche nach Punkten wird mit logarithmischer Komplexität realisiert.

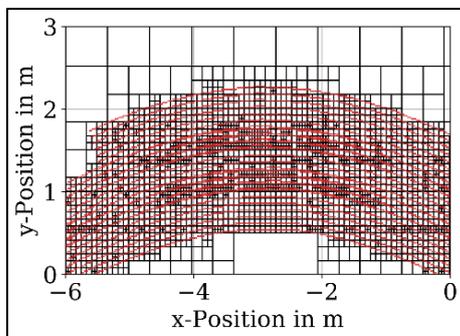


Abbildung 7. Dünne Bodenradarkarte als Quadtree

Die Bodenkarte weist jedoch Fehlstellen auf, da die Messpunkte einen Abstand von 8,5 cm haben. Dieser Abstand ist der Querabstand zwischen einer Sende- und Empfangsantenne. Entlang der gefahrenen Strecke ist die Karte dicht, wenn die Fahrgeschwindigkeit für die Abtastfrequenz des Sensors niedrig genug ist. Um die Karte wie in Abbildung 8 dichter zu machen, wird der Quadtree in einen räumlichen k-d-Baum umgewandelt. Dadurch lassen sich die nächsten Nachbarn zu jeder Messspur eines fehlenden Punktes suchen und den Abstand zu ihm zu bestimmen. Die Karte kann durch lineare Interpolation gemäß Gl. (8) mit  $d$  als Abstand und  $s$  als Sweep dichter gemacht werden. Je

zentraler jedoch der Fehlerpunkt zwischen zwei Messspuren liegt, desto größer ist der Interpolationsfehler aufgrund der großen Abstände. Diese interpolierten Sweeps eignen sich nur bedingt zur Lokalisierung.

$$s_i = \frac{d_1 s_2 + d_2 s_1}{d_1 + d_2} \quad (8)$$

Um den Fehler zu reduzieren, wurden zwei künstliche neuronale Netze (KNN) trainiert, um die Interpolation zu verbessern. Eine praktische Implementierung zu KNN ist z. B. in [11] erläutert. Das entwickelte KNN stellt eine nichtlineare Interpolationsfunktion, die die Gl. (8) nachahmt und in Abb. 7 visualisiert ist. Sie besteht aus zwei KNNs, wobei das erste KNN  $\varphi_1$  Merkmale aus Sweeps  $s_1, s_2$  generiert und ein zweites KNN diese mit Abständen  $d_1, d_2$  verarbeitet, um den interpolierten Sweep  $s_i$  zu generieren. Die KNNs sind voll verschaltet (fully connected), wobei  $\varphi_1$  zwei versteckte Schichten und  $\varphi_2$  nur eine versteckte Schicht hat. Als Aktivierungsfunktion wurde ReLU verwendet. Als Trainings- und Testdaten werden verschiedene Abstände 0 cm, 1 cm, ..., 4 cm von der Ground Truth zum darüber oder darunter liegenden Pfad verwendet. Der mittlere quadratische Fehler wird als Verlustfunktion verwendet, da die Verwendung der Kosinusähnlichkeit weniger effektiv war. Die Testdaten und das Training in Abbildung 9 beweisen, dass es keine Überanpassung gibt. Das KNNs ist in der Lage, die Sweeps in Bezug auf die Kosinusähnlichkeit um durchschnittlich 22 % im Vergleich zur linearen Interpolation zu verbessern.

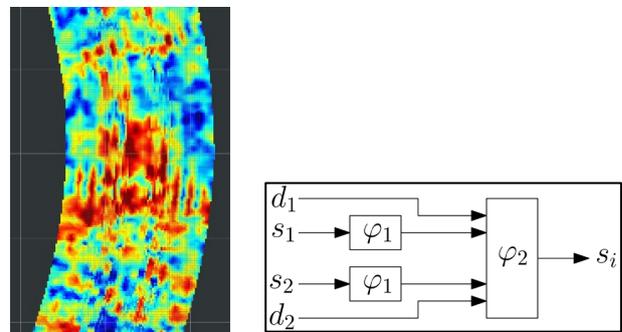


Abbildung 8. Links: Draufsicht auf eine verdichtete Bodenradarkarte als 2D-Punktwolke. Rechts: Nichtlineare Interpolation eines Sweeps  $s_i$  durch zwei künstliche neuronale Netze  $\varphi_1, \varphi_2$  mit den nächstgelegenen Sweeps  $s_1, s_2$  und deren Abstand  $d_1, d_2$

#### 4.2 BERECHNUNG DER ORIENTIERUNG

Der Gierwinkel des MCL weist einen hohen Fehler auf. Um einen stabilen Gierwinkel zu erhalten, werden 6 xy-Positionen des MCL auf einer Länge von 1 m gespeichert und eine lokale Odometrie parallel zu dieser Speicherung aufgezeichnet. D.h. die Punkte haben einen Abstand von 20 cm. Wenn der Speicher alle 6 Positionen enthält, werden diese Positionen und die Positionen der lokalen

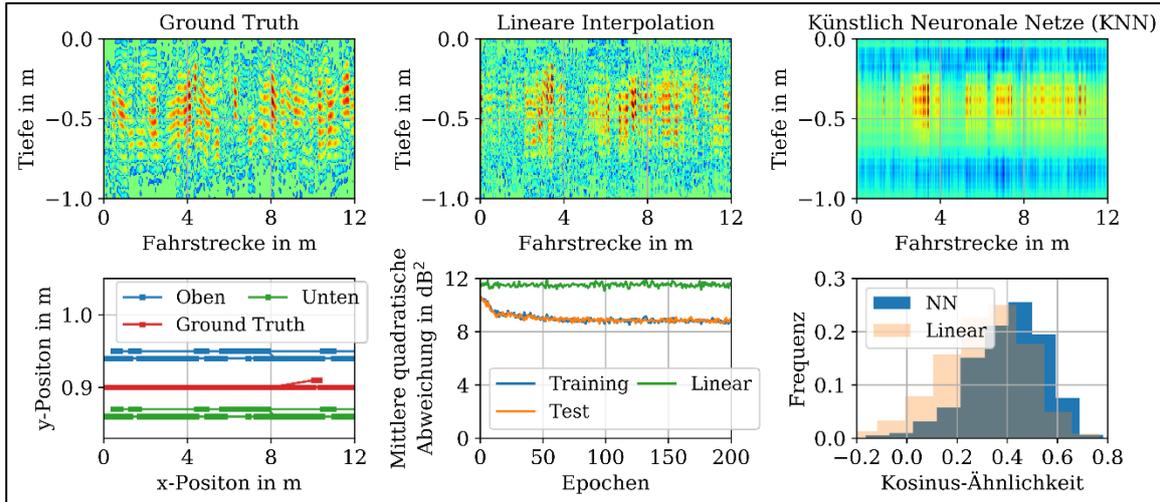


Abbildung 9. Interpolation der lateralen Fehlstellen zur Verdichtung der Karte zur Lokalisierung. Die Interpolation mit den KNNs zeigt eine Verbesserung der Kosinus-Ähnlichkeit um 22 %. Es werden mehrere Bahnen und Ground-Truth-Daten sowie Trainingsdaten verwendet, d.h. hier wird nur ein Ausschnitt gezeigt.

Odometrie in zwei Punktwolken umgewandelt. Die beiden Punktwolken werden mit Hilfe Iterative Closest Point Algorithmus (ICP) übereinandergelegt. Der erste Punkt der MCL-Punktwolke wird als Ausgangsposition und -orientierung für die gesuchte Transformation verwendet. Schließlich wird die Orientierung des ICP zur letzten Orientierung der lokalen Odometrie addiert, um den erforderlichen Gierwinkel zu erhalten. Alle 20 cm wird der Algorithmus ausgeführt, zwischen den Iterationen wird der Gierwinkel durch die Odometrie gestützt. In Abbildung 10 wird der Ansatz visualisiert.

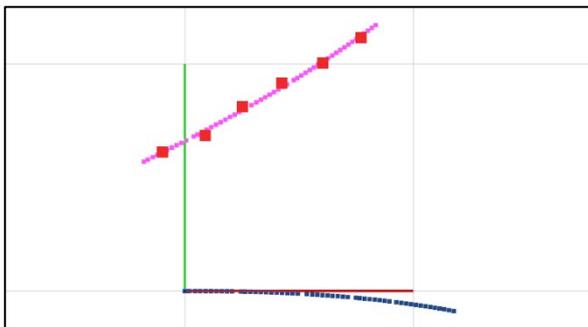


Abbildung 10. Berechnung der Orientierung (Gierwinkel) mit dem Iterative Closest Point Algorithmus (ICP). Rote Punkte: MCL-Positionen; blaue Punkte: lokale Odometrie; pinke Punkte: transformierte Odometrie in MCL-Positionen

## 5 VERSUCHE ZUR LOKALISIERUNG UND NAVIGATION

Die Parameter aus Abschnitt 2 und 3 haben einen großen Einfluss auf die Lokalisierungsqualität. Diese Parameter wurden mit Hilfe eines genetischen Algorithmus und gemischt-ganzzahliger Optimierung bestimmt. Es wurde folgender Parametersatz bestimmt:

- Startfrequenz: 400 MHz,
- Endfrequenz: 1600 MHz,
- Schrittfrequenz: 40 MHz,
- Länge der IFFT:  $2^9$ ,
- Fensterfunktion der IFFT: Kaiser-Fenster,
- Längenkonstante im Hochpassfilters:  $l = 1,0$  m,
- 0 dB Median:  $C = 80$  dB und
- 0 dB-Schwellwert:  $C_{0dB} = 80$  dB.

Diese Parameter wurden zur nachfolgenden Lokalisierung und Navigation verwendet.

### 5.1 LOKALISIERUNG

Es wird ein Experiment vorgestellt, um die Qualität des Lokalisierungssystems zu quantifizieren und die Funktionstüchtigkeit zu belegen. Der Abstand zwischen den Antennen und dem Boden lag bei 25 mm. Die Bodenkarte hatte eine Auflösung von 2 mm in der Ebene und eine Länge von ca. 12 m. Die Lokalisierung wurde alle 0,05 m bei der Fahrgeschwindigkeit von 0,1 m/s durchgeführt. Zwischen den Aktualisierungen wird die Lokalisierung durch Odometrie gestützt. Abbildung 11 zeigt die Lokalisierungsergebnisse auf einer Gerade. Nach einem Einschwingen ist die absolute laterale Abweichung kleiner 1 cm und die Orientierung weicht um ca.  $2^\circ$  ab. Diese Abweichungen wurde zur Lokalisierung mit dem SICK Nav350 berechnet, welcher der Ground Truth ist.

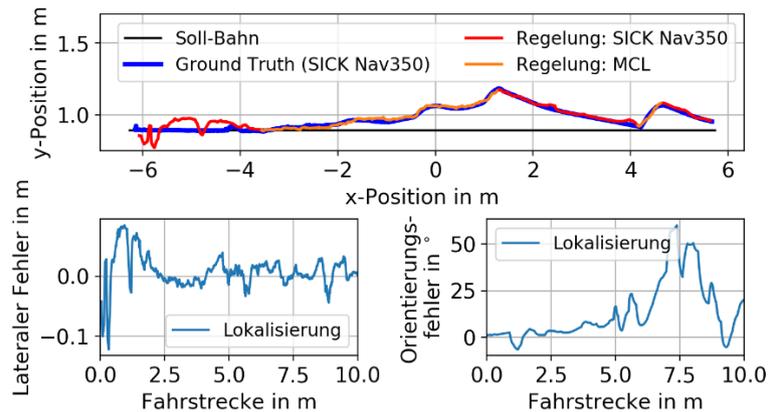


Abbildung 12. Navigation mit Bodenradar als Lokalisierungssystem. Beim Einschwingvorgang und bei zu großen lateralen Fehlern wird die Lokalisierung des SICK Nav350 verwendet.

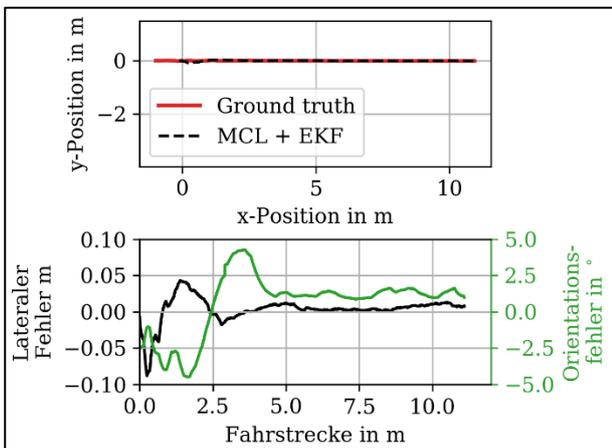


Abbildung 11. Test auf einer Gerade zur Validierung des Lokalisierungssystems mit einem Bodenradar als Sensor

## 5.2 NAVIGATION

Zur Darstellung der Navigation mit dem lokalisierenden Bodenradarsystem wurde das Experiment aus Abschnitt 5.1 durchgeführt. Die Ergebnisse sind in Abbildung 12 dargestellt. Nach einem Einschwingvorhang wird zur Bahnfolgeregelung das MCL (Bodenradar) verwendet. Mit der Fahrt vergrößert sich jedoch der laterale Fehler zur Soll-Bahn, da die Orientierung einen Fehler aufweist. Der Bahnregler will nicht gegenlenken, da die Fahrzeugorientierung bereits in Richtung der Soll-Bahn zeigt. Bei einer Abweichung von mehr als 20 cm wird die Positionslösung des SICK Nav350 gewählt, bis der laterale Fehler erneut kleine Werte aufweist. Doch aufgrund des großen Orientierungsfehlers ist eine Navigation mit dem entwickelten Lokalisierungssystem noch nicht möglich. Aber die MCL weist zur Lokalisierung mit dem SICK Nav350 nur kleine Abweichung in der Position auf. Zur Analyse des Problems müssen die Partikelgewichte betrachtet werden; eine stärkere Gewichtung der äußeren Antennen könnte innerhalb der MCL die Orientierung verbessern. Die Bestimmung

der Orientierung mit dem ICP muss analysiert und angepasst werden.

## 6 FAZIT UND AUSBLICK

In diesem Beitrag wird ein Lokalisierungssystem vorgestellt, das auf Bodenradar-daten und einer Monte-Carlo-Lokalisierung basiert. Ziel ist es, die Probleme visueller Sensoren, wie Schmutz und/oder schlechte Bedingungen für GNSS, wie hohe Gebäude oder Innenräume, zu überwinden. Die Lokalisierungsgenauigkeit liegt beim lateralen Fehler und Orientierungsfehler innerhalb eines akzeptablen Bereichs. Das Navigieren mit diesem System ist allerdings noch nicht möglich, da aufgrund des Orientierungsfehlers die Soll-Bahn nicht gehalten und erreicht werden kann. Im nächsten Projektschritt muss die Schätzung der Orientierung verbessert werden, damit Fahrzeuge nicht nur lokalisiert, sondern auch navigiert werden können.

GEFÖRDERT VOM



Bundesministerium  
für Bildung  
und Forschung

## LITERATUR

- [1] J. Hertzberg, K. Lingemann und A. Nüchter. *Mobile Roboter: Eine Einführung aus Sicht der Informatik*. Berlin, Heidelberg: Springer-Verlag, 2012.
- [2] S. Thrun, W. Burgard und D. Fox. *Probabilistic robotics*. Cambridge Massachusetts; London, England: The MIT Press. 2005.
- [3] R. Valencia und J. Andrade-Cetto. *Mapping, planning and exploration with Pose SLAM*. Heidelberg Berlin: Springer, 2018.
- [4] D. Hahnel, W. Burgard, D. Fox, K. Fishkin und M. Philipose, "Mapping and localization with RFID technology," *IEEE International Conference on Robotics and Automation*, 2004. *Proceedings. ICRA 2004*, S. 1015-1020 Vol.1.
- [5] D. Vivet, F. Gérossier, P. Checchin, L. Trassoudaine, R. Chapuis, "Mobile Ground-Based Radar Sensor for Localization and Mapping: An Evaluation of two Approaches," *International Journal of Advanced Robotic Systems*. Vol. 10, No. 8, S. 307-315, August 2013.
- [6] M. Cornick, J. Koechling, B. Stanley und B. Zhang, "Localizing ground penetrating radar: A step toward robust autonomous ground vehicle localization," *Journal of field robotics*. Vol. 33, No. 1, S. 82-102, Januar 2016.
- [7] I. Stasewitsch, J. Schattenberg, L. Frerichs, K. Krüger, J. Schöbel, M. Lehr und T. Neugebauer, "Localization with a ground penetrating radar in harsh agricultural environments," in *VDI-Berichte: Proceedings at LAND. TECHNIK 2022: The Forum for Agricultural Engineering Innovations*. S. 153-162, Vol. 2395.
- [8] Götting KG, Hrsg., *Bahnführungsrechner HG G-73650ZD: Grundlagen, Inbetriebnahme und Software*, Götting KG, Lehrte, Germany, Doc. 2021.
- [9] H. Jol, Hrsg., "Ground penetrating radar: theory and applications," Amsterdam: Elsevier, 2008.
- [10] D. Seyfried, J. Schöbel, "Stepped-frequency radar signal processing," *Journal of Applied Geophysics*. Vol. 112, S. 42-51, Januar 2015.
- [11] F. Chollet, "Deep learning with Python," Shelter Island New York: Manning, 2021.

**M.Sc. Ilja Stasewitsch** promoviert seit 2015 am Institut für mobile Maschinen und Nutzfahrzeuge der Technischen Universität Braunschweig (TUBS). Er forscht zu Themen der mobilen Robotik, insbesondere an der Bahnfolgeregelung und der Lokalisierung. Seinen Bachelor im Wirtschaftsingenieurwesen Maschinenbau erwarb er 2011 an der TUBS. Im Jahr 2015 folgte der Masterabschluss ebenfalls an der TUBS in der Fahrzeugtechnik.

**Dr.-Ing. Jan Schattenberg** leitet seit 2014 die Arbeitsgruppe Automatisierungs- und Robotersysteme am Institut für mobile Maschinen und Nutzfahrzeuge der Technischen Universität Braunschweig (TUBS). Von 2008 bis 2014 war er wissenschaftlicher Mitarbeiter in dieser Arbeitsgruppe. Im Jahre 2020 folgt die Promotion zum Thema „Netzwerkumgebung zum ad-hoc Datenaustausch zwischen mobilen Maschinen“. Im Jahr 2007 schloss er das Maschinenbaustudium an der TUBS erfolgreich ab.

**Prof. Dr. Ludger Frerichs** leitet seit 2012 das Institut für mobile Maschinen und Nutzfahrzeuge der Technischen Universität Braunschweig (TUBS). Zuvor war er von 2008 bis 2011 Entwicklungsleiter bei STILL GmbH in Hamburg. Von 1990 bis 2008 war er bei der Claas Selbstfahrende Erntemaschinen GmbH angestellt, zuletzt als Leiter der Vorentwicklung. Im Jahr 1990 promovierte er an der Universität Hohenheim zum Thema „Grundlagen für das elektronische Traktor-Pflug-Management“. Das Maschinenbaustudium schloss er im Jahre 1985 an der TUBS ab.