

Arbeitskreis 3 „Messmethoden und Systeme“

## MST 2022 – MultisensorTechnologie: Von (A)nwendungen bis (Z)ukunftstechnologien

Beiträge zum 213. DVW-Seminar am  
26. und 27. September 2022 in Hamburg



Schriftenreihe des DVW  
Band 103 / 2022

Wißner



Arbeitskreis 3 „Messmethoden und Systeme“

# MST 2022 – Multisensorstechnologie: Von (A)nwendungen bis (Z)ukunftstechnologien

Beiträge zum 213. DVW-Seminar am  
26. und 27. September 2022 in Hamburg

Redaktion:  
Annette Scheider  
Tanja Dufek  
Eike Barnefske

Herausgeber:  
DVW e.V. – Gesellschaft für Geodäsie,  
Geoinformation und Landmanagement



Schriftenreihe des DVW  
Band 103  
Wißner-Verlag

Herausgeber:  
DVW e. V. – Gesellschaft für Geodäsie,  
Geoinformation und Landmanagement

[www.dvw.de](http://www.dvw.de)  
INTERGEO®

Schriftenreihe des DVW  
Band 103

**Tipps zur Navigation in der PDF-Datei:**

Die PDF enthält zur Navigation Lesezeichen und Hyperlinks.  
Der Mausklick auf ein Lesezeichen führt zur ersten Seite des angewählten Beitrags.  
Der Mausklick auf einen dunkelblau markierten Abbildungs- oder Tabellenverweis im Text führt zur verknüpften Abbildung oder Tabelle. Zurück zur ursprünglichen Stelle im Text gelangt man mit dem Klick auf den dunkelblau markierten Verweis in der Abbildungsunterschrift oder Tabellenüberschrift.  
Internetadressen und E-Mail-Adressen sind ebenfalls mit Hyperlinks hinterlegt.  
Kostenfreier PDF-Download unter [www.geodesie.info](http://www.geodesie.info).

**Zitierhinweis:**

[Nachname, Vorname]: [Titel des Beitrags]. In: DVW e.V. (Hrsg.):  
MST 2022 – Multisensortechologie: Von (A)nwendungen bis  
(Z)ukunftstechnologien. DVW-Schriftenreihe, Band 103,  
Augsburg, 2022, S. x–y.

Bibliografische Information der Deutschen Nationalbibliothek:  
Die Deutsche Nationalbibliothek verzeichnet diese Publikation in der  
Deutschen Nationalbibliografie; detaillierte bibliografische Daten sind  
im Internet über <http://dnb.dnb.de> abrufbar.

ISBN: 978-3-95786-322-5  
ISSN 0940-4260

© Wißner-Verlag, Augsburg 2022  
[www.geodesie.info](http://www.geodesie.info)

Herstellung: Wißner-Verlag, Augsburg  
Bildnachweis Cover: Eike Barnefske / HafenCity Universität Hamburg

Das Werk und seine Teile sind urheberrechtlich geschützt. Jede Verwertung in  
anderen als den gesetzlich zugelassenen Fällen bedarf deshalb der vorherigen  
schriftlichen Einwilligung des Verlags.

# Inhalt

Vorwort	5
---------	---

## Session 1: Grundlagen: Qualität, Kommunikation, Auswertung

Lasse Klingbeil   Gereon Tombrink   Heiner Kuhlmann Qualitätsanalyse in Multisensorsystemen	9
--	---

Finn Linzer   Niklas-Maximilian Schild   Jens-André Paffenholz ROS im Multisensorsystem – Am Beispiel von geodätischen Anwendungen	19
---	----

Reiner Jäger Multisensornavigation, Georeferenzierung und SLAM auf Bayes'scher Grundlage – Grundlagen und Systementwicklungen	33
---	----

## Session 2: Multisensorstechnologie in Geosensornetzwerken und Infrastruktur

Focke Jarecki Klassische und bildbasierte Tachymetrie als Teilnetze multisensoraler untätigiger Überwachung des geomechanischen Gebirgsverhaltens	51
---	----

Erik Heinz Geosensornetzwerke mit IoT-Technologie und Kl-Auswertungen zur Überwachung großer Böschungssysteme	61
---	----

Otto Lerke   Sebastian Bahamon-Blanco   Martin Metzner   Ullrich Martin   Volker Schwieger Vorarbeiten zur Entwicklung eines Gleisfehlerdetektionssystems mit Regelzügen und Low-Cost-Sensorik	73
---	----

Slaven Kalenjuk   Werner Lienhart Einsatz kommerzieller, mobiler Laserscanning-Systeme für die Über- wachung der Verkehrsinfrastruktur: Herausforderungen, Lösungsansätze und Praxisbeispiele	83
--	----

### Session 3: Hydrographische Anwendungen

Tobias Neiß-Theuerkauff | Frank Wallhoff | Thomas Brinkhoff | Christian Denker |  
Tarek El-Mihoub | Timotheus Kisselbach | Holger Korte | Yves Korte-Wagner |  
Oliver Köckritz | Thomas Luhmann | Lars Nolle | Robin Rofalski | Christoph  
Tholen | Tobias Werner | Bernhard Schwarz-Röhr | Klaus Windeck  
Entwicklung innovativer Technologien für autonome maritime  
Systeme (EITAMS) \_\_\_\_\_ 103

Vincent E. Schneider  
RoboVaaS (Robotic Vessels as a Service) und seine Evolution –  
das modulare ASV SeaML:SeaLion als Multisensor-Trägersystem \_\_\_\_\_ 121

Markus Kraft  
Pipelinedetektion durch Autonomous Underwater Vehicles (AUVs) \_\_\_\_\_ 131

### Session 4: Anwendungen und Projekte

Lukasz Rojek | Matthias Möller | Markus Richter | Monika Bischoff-Schaefer  
PlantSens: Ein schienenbasiertes Multisensor-Messsystem für eine auto-  
matisierte, bedarfs- und zielgerechte Bewässerung von Nutzpflanzen-  
beständen im Gewächshaus \_\_\_\_\_ 145

Paul Rawiel  
Positionierung von E-Bikes eines Free-Floating E-Bike-Sharing-Systems \_\_\_\_\_ 161

Eike Barnefske | Harald Sternberg  
Automatisch semantisch-segmentierte Punktwolken – Möglichkeiten und  
Herausforderungen \_\_\_\_\_ 173

# Vorwort

Nach dem Online-Seminar in 2021 freut sich der Arbeitskreis 3 „Messmethoden und Systeme“, das 213. DVW-Seminar „MST 2022 – Multisensortechnologie: Von (A)nwendungen bis (Z)ukunftstechnologien“ in Präsenz durchzuführen und damit die Tradition der MST-Seminare fortzusetzen.

Multisensortechnologie ist aus dem (geodätischen) Alltag nicht mehr wegzudenken und zeichnet sich durch vielfältige Einsatzmöglichkeiten in Praxis und Forschung aus. Der Titel zeigt, dass das Seminar einen weiten Bogen spannen will: Es geht um die Qualität und Auswertung von Multisensorsystemen, um Multisensortechnologie in ROS (Robot Operating System) und Geonetzerwerken sowie unterschiedlichste Anwendungen und Projekte mit einem Schwerpunkt in Infrastruktur und Hydrographie. Das Programm zeigt die Vielfalt der Multisensortechnologie, geht aber auch auf die Grundlagen und Herausforderung ein. Es richtet sich damit an Kolleginnen und Kollegen aus der Berufspraxis, aus Wirtschaft und Behörden sowie aus Lehre und Forschung. Kolleginnen und Kollegen – auch in Ausbildung – aus den Bereichen der Geodäsie, der Geoinformatik und aus Nachbardisziplinen, die Multisensortechnologie nutzen und sich über modernen Entwicklungen informieren möchten, sind die Zielgruppe für dieses Seminar.

Wir freuen uns auf interessante Vorträge in diesem spannenden Aufgabenfeld und auf einen Austausch und anregende Diskussionen mit Ihnen. Ein herzlicher Dank gilt den Vortragenden für ihre Mitgestaltung des Seminars und ihre schriftlichen Beiträge, die auch im Nachgang des Seminars von Nutzen sein werden. Viel Spaß beim Lesen!

Bochum und Hamburg, im August 2022  
Brigitte Gundlich      Harald Sternberg



# **Session 1: Grundlagen: Qualität, Kommunikation, Auswertung**

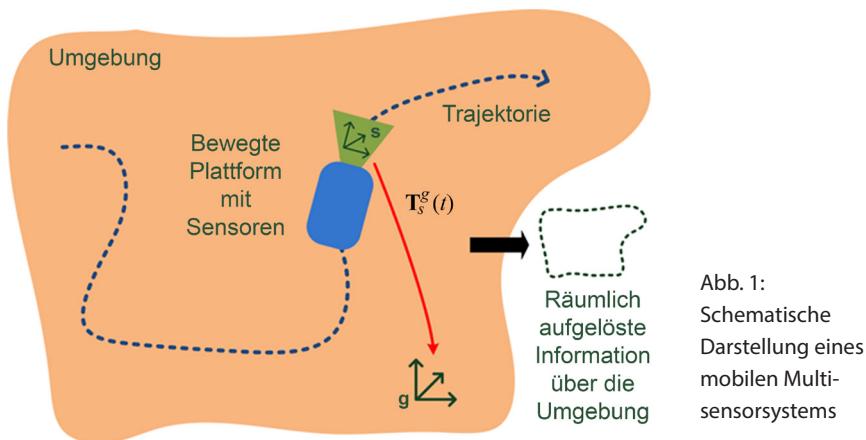


# Qualitätsanalyse in Multisensorsystemen

Lasse Klingbeil | Gereon Tombrink | Heiner Kuhlmann

## 1 Einleitung und Motivation

Die Grundidee bei der Anwendung mobiler Multisensorsysteme ist die Vermessung der Umgebung mit Hilfe von Sensoren, die sich auf einer bewegten Plattform befinden. „Vermessung der Umgebung“ bedeutet dabei zunächst sehr allgemein die Generierung räumlich aufgelöster Informationen über die Umgebung oder Objekte darin. Die Art der Information wird dabei von der Art des Sensors bestimmt, der auf der mobilen Sensorplattform befestigt ist.



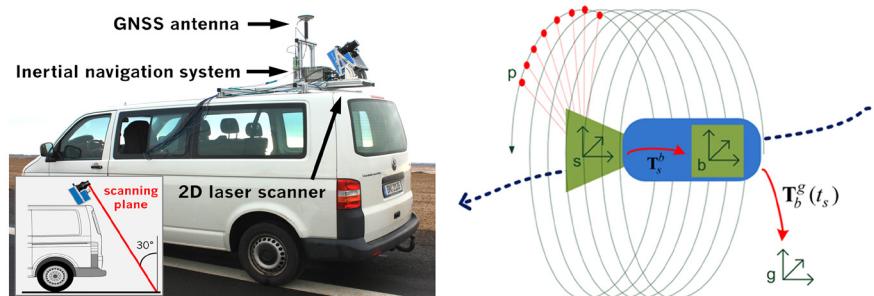
Mit einem Laserscanner lassen sich zum Beispiel Winkel und Abstände zu Objekten der Umgebung messen, um daraus z. B. dreidimensionale Modelle zu generieren. Mit Kameras und entsprechenden photogrammetrischen Methoden ist das ebenfalls möglich, wobei hier zusätzlich noch radiometrische Informationen über den Zustand der Objekte erfasst werden können (z. B. Farbe oder Reflektivität des Sonnenlichts bei verschiedenen Wellenlängen). In diesem Beitrag fokussieren wir uns auf die Erzeugung von Punktwolken mit Laserscanner-basierten Multisensorsystemen.

Eine interessante und nicht leicht zu beantwortende Frage ist, welche Qualität die mit Hilfe solcher kinematisch messenden Systeme generierten Daten haben. Es gibt unterschiedliche Qualitätsmerkmale, die dabei betrachtet werden

können, und die sich auf die Zuverlässigkeit, die Integrität und die Genauigkeit der Daten beziehen (Heunecke et al. 2013). Wir konzentrieren uns in diesem Beitrag auf die metrische Genauigkeit. Dazu beschreiben wir zunächst das Prinzip der Aufnahme und die notwendigen Verarbeitungsschritte. Dann erläutern wir die Faktoren, die einen Einfluss auf die Genauigkeit der Ergebnisse haben. Neben der eigentlichen Messung des Scanners sind das im Wesentlichen die Systemkalibrierung, sowie die Schätzung der Trajektorie des Systems. Wir stellen weiterhin eine Einrichtung vor, mit der es möglich ist, einige Qualitätsaspekte von Multisensorsystem zu untersuchen. Dabei beschreiben wir insbesondere ein Verfahren zur Evaluierung der Trajektorienschätzung, welches auf einem Schienensystem und einer Methode zur Auswertung von Mehrfachmessungen basiert.

## 2 Prozessierung und Abweichungsquellen beim kinematischen Laserscanning

**Abb. 2** (links) zeigt das am Institut für Geodäsie und Geoinformation entwickelte kinematische Laserscanningsystem. Es beinhaltet wie die meisten dieser Systeme einen Profillaserscanner, sowie eine Inertiale Navigationssystem, bestehend aus hochwertigen Drehraten- und Beschleunigungssensoren und einem Mehrfrequenz-GNSS-Empfänger.



**Abb. 2:** Aufbau des Systems der Universität Bonn (links). Schematische Darstellung eines Laserscanner-basierten Multisensorsystems (rechts).

In **Abb. 2** rechts ist das Messprinzip dargestellt. Der Laserscanner führt in schneller Abfolge Distanzmessungen durch, die durch die Bewegung der Plattform die Umgebung spiralförmig abscannen. Das Inertiale Navigationssystem liefert zu jedem Zeitpunkt  $t_s$ , an dem der Laserscanner eine Distanzmessung durchführt, die Position und Orientierung der Plattform im übergeordneten

Koordinatensystem der Umgebung  $\mathbf{T}_b^g(t_s)$ . Bestimmt der Laserscanner also über Distanz- und Winkelmessung einen Punkt  $\mathbf{p}^s$  in seinem eigenen lokalen Koordinatensystem, kann dieser mit Hilfe der Trajektorieninformation in das globale Koordinatensystem der Umgebung transformiert werden, wenn zusätzlich die Transformation  $\mathbf{T}_s^b$  zwischen dem Sensorkoordinatensystem und dem Plattformkoordinatensystem bekannt ist:

$$\mathbf{p}^g = \mathbf{T}_b^g(t_s) \mathbf{T}_s^b \mathbf{p}^s(t_s)$$

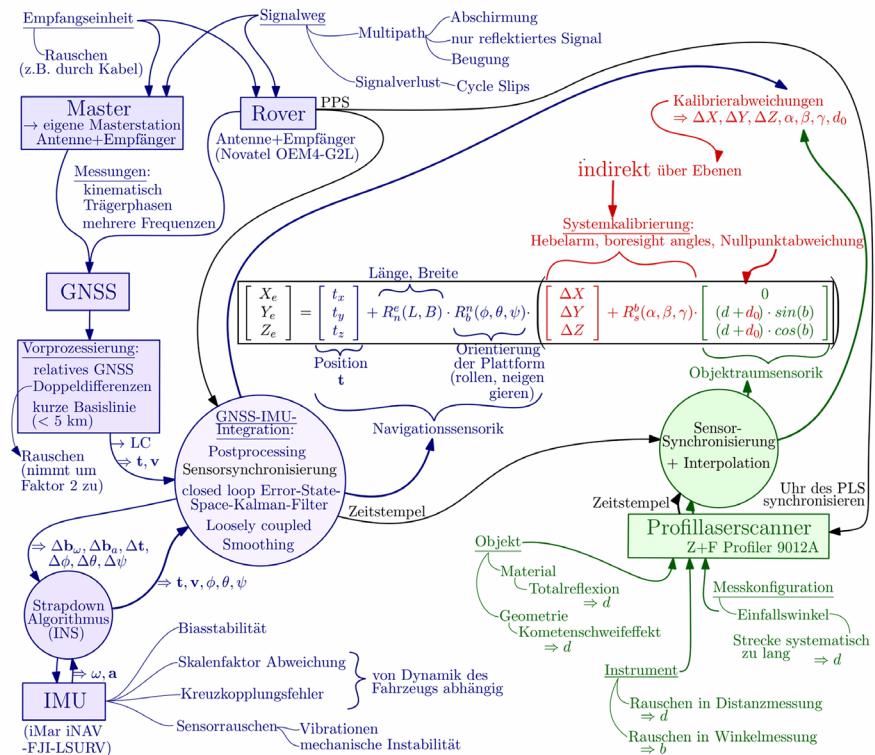
Genauer lässt sich der Zusammenhang wie folgt aufschreiben:

$$\begin{bmatrix} x_e \\ y_e \\ z_e \end{bmatrix} = \begin{bmatrix} t_x \\ t_y \\ t_z \end{bmatrix} + \mathbf{R}_n^e(L, B) \mathbf{R}_b^n(\phi, \theta, \psi) \cdot \left[ \begin{bmatrix} \Delta_x \\ \Delta_y \\ \Delta_z \end{bmatrix} + \mathbf{R}_s^b(\alpha, \beta, \gamma) \cdot \begin{bmatrix} 0 \\ d \cdot \sin b \\ d \cdot \cos b \end{bmatrix} \right]$$

Dabei sind  $d$  und  $b$  die vom Scanner erfasste Messgrößen Distanz und Scanwinkel,  $\Delta x, \Delta y, \Delta z, \alpha, \beta, \gamma$  sind die translatorischen und rotatorischen Parameter der Systemkalibrierung (Hebelarm und Boresight Winkel),  $t_x, t_y, t_z, \Phi, \Theta, \Psi$  sind die Trajektorienparameter (Position und Orientierung),  $L$  und  $B$  sind die Länge und Breite. Das Ergebnis  $x_e, y_e, z_e$  entspricht dem Punkt  $\mathbf{p}^g$  in der oberen Formel, also dem gemessenen Laserpunkt in einem globalen Koordinatensystem. Die (roten) Parameter der Systemkalibrierung werden üblicherweise als zeitkonstant angenommen. Die (blauen) Trajektorienparameter müssen zu jedem Zeitpunkt einer Lasermessung bekannt sein. Dabei werden  $L$  und  $B$  nur für die Transformation in das tangential zum Ellipsoid liegende Navigationssystem benötigt, welches nicht für alle Zeitpunkte neu berechnet werden muss.

Im Idealfall sind die Unsicherheiten aller oben genannten Parameter z. B. in Form einer Kovarianzmatrix bekannt, so dass sich die Unsicherheit des resultierenden Messpunktes im globalen System über Vorwärtsmodellierung bestimmen lässt. Abb. 3 zeigt anschaulich, warum dieser Idealfall nicht ohne Weiteres erreicht werden kann. Während für die Messung des Profilscanners und die Systemkalibrierung ein stochastisches Modell näherungsweise aufgestellt werden kann (Heinz et al. 2018, Heinz et al. 2020), ist das für die Trajektorienparameter nahezu unmöglich. Die Trajektorie wird mit Hilfe von meist rekursiven Schätzverfahren wie dem Kalman-Filter, aus den Beobachtungen der Drehraten- und Beschleunigungssensoren und den GNSS-Beobachtungen berechnet. Dabei spielen eine Vielzahl meist nicht gut bekannter systematischer und sich gegenseitig bedingender Unsicherheiten eine Rolle, die sich über die in den Filteralgorithmen befindlichen System- und Sensormodelle nicht ausreichend abbilden lassen.

Eine Möglichkeit zur Analyse der Qualität der Messergebnisse ist die empirische Untersuchung der Genauigkeit auf Basis der resultierenden Punktfolke oder der zugrundeliegenden Trajektorie. Zu diesem Zweck wurde an der Universität Bonn eine Einrichtung entwickelt und aufgebaut. Einige damit generierten Ergebnisse, insbesondere zur Untersuchung der Trajektoriengenauigkeit, werden in diesem Beitrag vorgestellt.

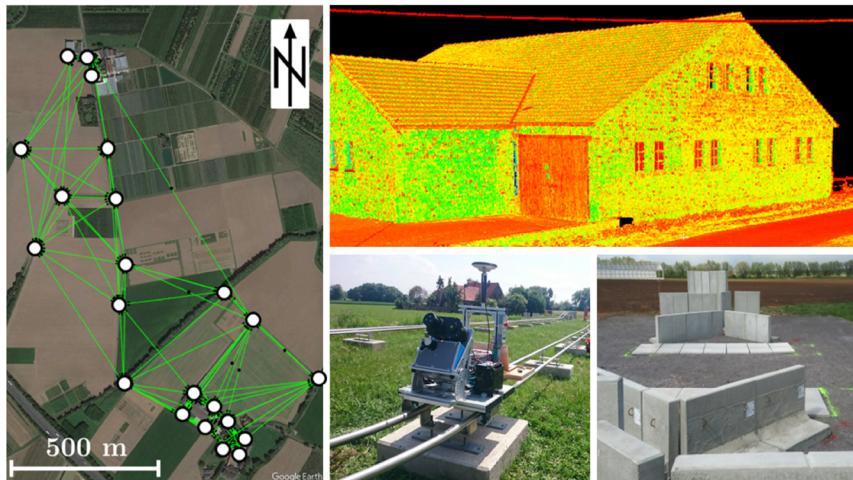


**Abb. 3:** Aufstellung der Einflussfaktoren auf die Punktfolkerstellung beim kinematischen Laserscanning (hier am Beispiel des Bonner Messsystems). Die grünen Teile beziehen sich auf die Scannermessungen, die roten auf die Systemkalibrierung und die blauen auf die Trajektorienbestimmung.

### 3 Kalibrier- und Evaluierungseinrichtung

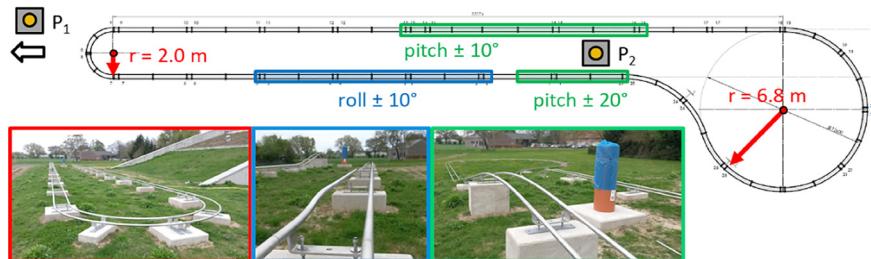
Die Kalibriereinrichtung (Abb. 4) wurde am Campus Klein-Altendorf, den Außenlaboren der Universität Bonn, errichtet und besteht aus vier Komponenten:

1. Netz aus Kontrollpunkten
2. TLS-Referenzpunktwolken
3. Kalibrierfeld zur Ebenen-basierten Systemkalibrierung
4. Schienenbahn als Referenztrajektorie



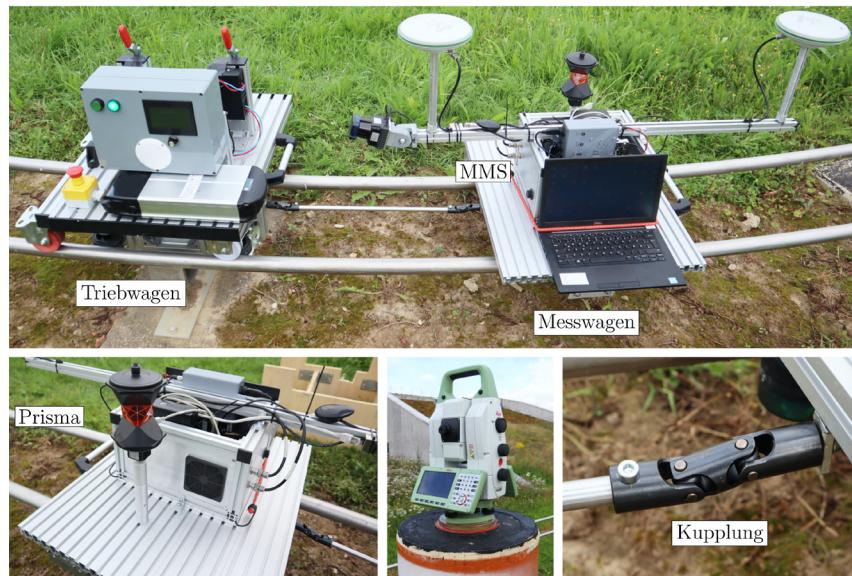
**Abb. 4:** Einrichtung für die Kalibrierung und Evaluierung von Multisensorsystemen: links: Netz aus Kontrollpunkten (Quelle: Google Earth, modifiziert), oben rechts: TLS-Referenzpunktwolke, unten mittig: schienengebundene Referenztrajektorie, unten rechts: ebenen-basiertes Kalibrierfeld für Systeme mit Laserscannern

Das Netz aus Kontrollpunkten besteht aus 6 Pfeilern, 15 Gebäudepunkten sowie 16 Bodenpunkten und wurde mithilfe von GNSS, Tachymetrie und Nivellierinstrumenten lage- und höhenmäßig eingemessen und an das deutsche Landesvermessungssystem angeschlossen. Die Genauigkeit der Punkte wurde über mehrere Epochen gemessen und mit einer Standardabweichung von <1mm geschätzt. An den Gebäudepunkten lassen sich Targets befestigen, die in den Punktwolken sichtbar sind. Von mehreren Gebäuden wurden TLS-Referenzpunktwolken erstellt, und mit dem bestehenden Netz georeferenziert. Das Kalibrierfeld zur Ebenen-basierten Systemkalibrierung besteht aus mehreren stabilen eingemessenen Ebenen und ermöglicht die hochgenaue Messung der Lage zwischen GNSS/IMU-Einheit und Laserscanner (Heinz et al. 2020).



**Abb. 5:** Aufbau der Schienenbahn: Einzelne Elemente der Schienenbahn realisieren translatorische und rotatorische Änderungen der Trajektorienparameter.

Die **Schienenbahn** ist in [Abb. 5](#) dargestellt. Sie hat eine Länge von rund 140 m und weist Änderungen in Lage und Höhe sowie Orientierungsänderungen (Roll-Winkel  $\pm 10^\circ$ , Pitch-Winkel  $\pm 20^\circ$  und Kurswinkel  $\pm 180^\circ$ ) auf. Auf der Schienenbahn lässt sich eine definierte Trajektorie unter kontrollierten Bedingungen wiederholt abfahren. Dadurch kann die Qualität der Trajektorienschätzung untersucht werden. Direkt neben der Schienenbahn befinden sich zwei Vermessungspfeiler, sodass auch das Tracking von Systemen möglich ist (z. B. mit einem Tachymeter oder einem Lasertracker). [Abb. 6](#) zeigt den Wagen, mit dem sich das zu testende System automatisiert auf der Strecke bewegen lässt.



**Abb. 6:** Der automatisierte Messwagen ermöglicht wiederholtes Abfahren der Strecke, wobei die Position eines Prismas mit Hilfe eines Tachymeters bestimmt werden kann.

## 4 Evaluierung der Trajektoriengenauigkeit

Die oben beschriebene Schienenbahn lässt sich nun zur Bestimmung einiger Qualitätsparameter der Trajektorienbestimmung verwenden. Abb. 7 zeigt, wie sich im Falle einer Trajektorie Präzision und Richtigkeit beschreiben lassen.

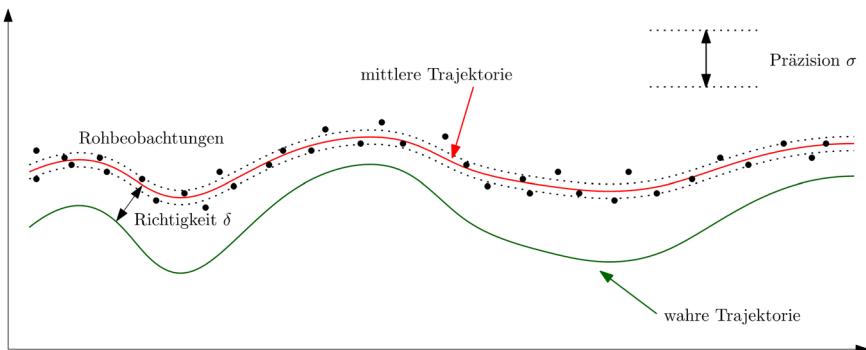


Abb. 7: Präzision und Richtigkeit der Trajektorie

Aus Mehrfachbefahrung derselben Trajektorie lässt sich eine mittlere Trajektorie bestimmen. Die Abweichung der einzelnen Positionen bzw. Winkel von dieser mittleren Trajektorie bestimmen die Präzision der Trajektorienbestimmung. Der Unterschied zwischen der mittleren Trajektorie und der wahren Trajektorie bestimmt die Richtigkeit.

Da bei der Mehrfachbefahrung nicht immer an den gleichen Stellen der Trajektorie eine Position und Orientierung gemessen wird, birgt die Mittelbildung eine Herausforderung. Diese konnten wir durch eine Sortierung der Punkte entlang der Bogenlänge mit anschließender Anpassung stückweise kubischer Polynome lösen. Die Abweichung entlang der Trajektorie kann durch den fehlenden Zeitbezug nicht bestimmt werden, so dass die Präzision lediglich als horizontale und vertikale Querabweichung bestimmt werden kann.

Abb. 8 zeigt die Ergebnisse der Präzisionsbestimmung. Die Verteilung der Abweichung scheint kaum systematische Abweichung zu beinhalten, die vertikale Standardabweichung ist mit etwa 7 mm etwas höher als die horizontale (4 mm). Die Standardabweichungen für den Roll und Pitch-Winkel sind beide etwa  $0,03^\circ$  (Pitch ist hier nicht dargestellt). Der Yaw-Winkel streut erwartungsgemäß etwas mehr ( $0,11^\circ$ ). Durch das Verfahren ist es auch möglich, die Standardabweichung räumlich aufzutragen. So ist klar erkennbar, dass in einigen Bereichen der Trajektorie, die Streuung im Yaw-Winkel größer ist. Auf diese Weise lassen sich eventuell Probleme im Aufbau oder in den Schätzalgorithmen aufdecken.

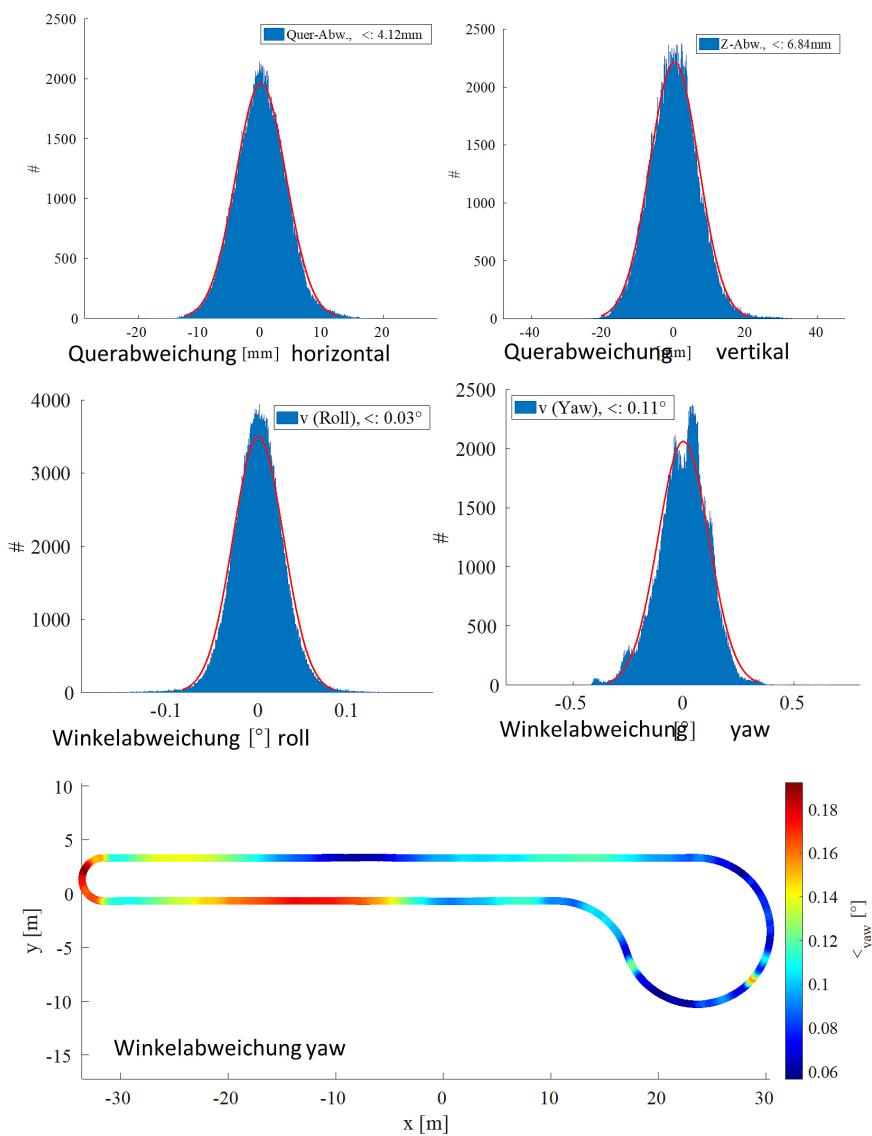


Abb. 8: Präzision der einzelnen Trajektorienparameter nach Mehrfachmessung

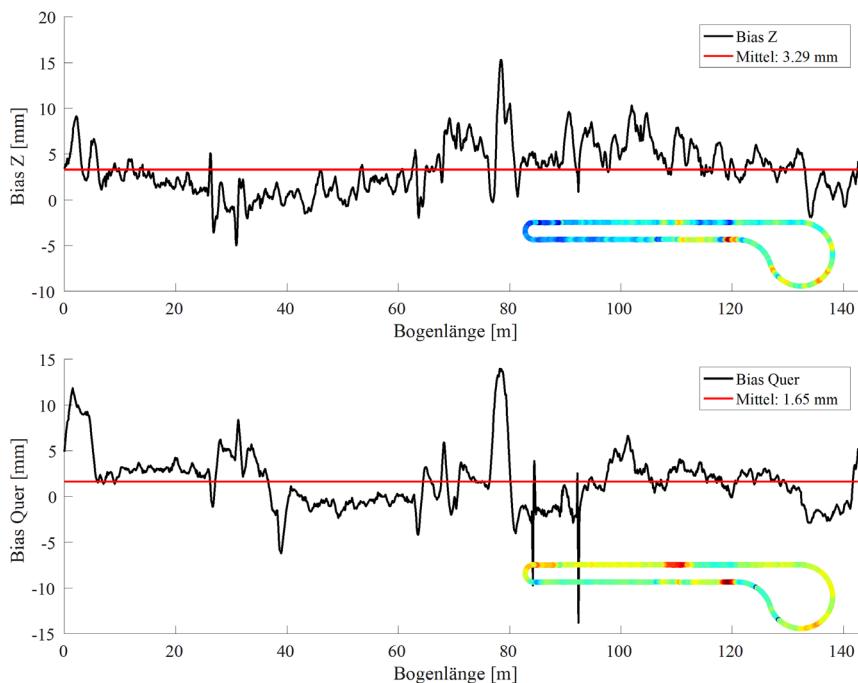


Abb. 9: Abweichung der mittleren geschätzten Trajektorie von der Referenztrajektorie

In der hier vorgestellten Untersuchung wurde die wahre Trajektorie durch eine Mehrfachmessung mit einem zielverfolgenden Tachymeter und anschließender Mittelung wie oben beschrieben bestimmt. Die Abweichung der mittleren durch die GNSS/IMU-Einheit bestimmten Trajektorie von eben dieser mittels Tachymeter bestimmten Referenztrajektorie ist in Abb. 9 entlang der Bogenlänge dargestellt. Man kann erkennen, dass es Bereiche höherer Abweichungen an bestimmten Stellen der Bahn gibt. Diese lokalen Abweichungen können nun eingehender untersucht werden.

## 5 Zusammenfassung und Ausblick

Aufgrund der komplexen Verarbeitungskette, insbesondere zur Berechnung der Trajektorie, ist eine Vorwärtsmodellierung der Unsicherheiten von kinematische aufgenommenen Punktewolken sehr schwierig. Eine Möglichkeit dennoch Aussagen über die Genauigkeit zu treffen, liegt in der empirischen Analyse der Endergebnisse oder von Zwischenschritten. Dazu haben wir eine Testumgebung

entwickelt, die hochgenau georeferenzierte Objekte und Punkte beinhaltet, mit denen sich die Qualität der Punktwolke analysieren lässt. Ergebnisse dazu wurden in Heinz et al. (2020) veröffentlicht. Weiterhin haben wir dort eine Schienenbahn aufgebaut, mit der es möglich ist, Multisensorsysteme mehrfach eine definierte Trajektorie abfahren zu lassen und so Genauigkeitsparameter der Trajektorienschätzung zu bestimmen und räumlich zu analysieren. Aktuelle Arbeiten beschäftigen sich damit, die Schätzergebnisse mit den Daten eines übergeordneten Messsystems, wie einem Tachymeter, zu synchronisieren um auch Aussagen über die Längsabweichung der Schätzung machen zu können.

## Literatur

- Heinz, E., Holst, C., Kuhlmann, H., Klingbeil, L. (2020): Design and Evaluation of a Permanently Installed Plane-Based Calibration Field for Mobile Laser Scanning Systems. In: *Remote Sensing* 2020, 12, 555. DOI: [10.3390/rs12030555](https://doi.org/10.3390/rs12030555).
- Heinz, E., Mettenleiter, M., Kuhlmann, H., Holst, C. (2018): Strategy for Determining the Stochastic Distance Characteristics of the 2D Laser Scanner Z+F Profiler 9012 with Special Focus on the Close Range. In: *Sensors*, 18, 2253. DOI: [10.3390/s18072253](https://doi.org/10.3390/s18072253).
- Heunecke, O., Kuhlmann, H., Welsch, W., Eichhorn, A., Neuner, H. (2013): Handbuch Ingenieurgeodäsie – Auswertung geodätischer Überwachungsmessungen. 2., neu bearbeitete und erweiterte Auflage, Herbert Wichmann Verlag, Berlin.

## Kontakt

Dr. rer. nat. Lasse Klingbeil

Institut für Geodäsie und Geoinformation, Universität Bonn

Nussallee 17, 53115 Bonn

[klingbeil@igg.uni-bonn.de](mailto:klingbeil@igg.uni-bonn.de)

# ROS im Multisensorsystem – Am Beispiel von geodätischen Anwendungen

Finn Linzer | Niklas-Maximilian Schild | Jens-André Paffenholz

## 1 Motivation

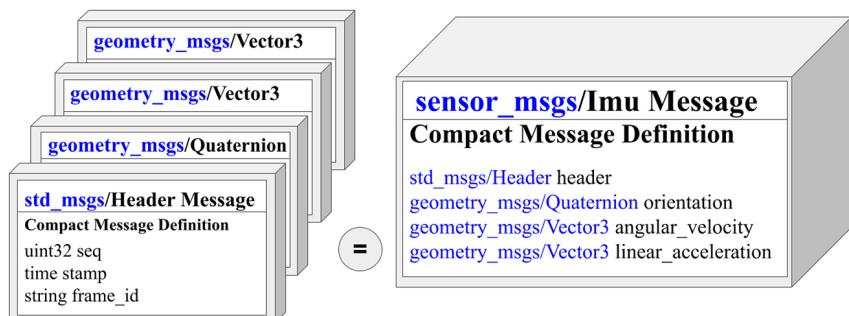
Im abwechslungsreichen Kontext geodätischer Problemstellungen müssen geeignete Sensoren und Methoden zusammengestellt und in Kombination miteinander ausgewertet werden. Dabei kann die Entwicklung geeigneter Multisensorsysteme (MSS) sehr komplex ausfallen, da die Erfassung der Messergebnisse bis hin zu einem Analyseergebnis miteinander verbunden werden muss. Neben dem Wissen um geodätische Messtechnik ist ein tiefer gehendes Verständnis für Prozesse aus der Informatik notwendig, um ein integriertes System zuverlässig aufzubauen. Von der tagesaktuellen Datenhaltung bis zur Echtzeitanwendung sind die Prozesse zur Aufnahme und Überwachung den Einsatzbedingungen anzupassen.

Das Robot Operating System (ROS) ist ein Open-Source-Framework, in dem über verschiedene Betriebssysteme (Windows, Linux, MacOS), Programmier- und Skriptsprachen (C++, Python, MATLAB®) hinweg Anwendungen implementiert werden können. Dieses Framework stammt, wie der Name schon sagt, aus dem Bereich der Robotik, aber aufgrund seiner Flexibilität ist es möglich, Anwendung in vielen anderen Bereichen zu finden. Die Prozesse eines MSS werden in Module aufgeteilt und mittels Interprozesskommunikation untereinander verbunden. Eindeutig definierte Schnittstellen vereinfachen eine zusammenhängende Integration.

In diesem Artikel werden die vielfältigen Ansätze beschrieben, mit denen mit Hilfe von ROS geodätische Umsetzungen gelungen sind. Anhand der Arbeit an drei Universitäten wird gezeigt, dass komplexe MSS im Rahmen geodätischer Forschung und Lehre effektiv weiterentwickelt werden können. Die Kontrolle über Messdaten und deren Verarbeitung bleibt dabei vollständig auf Seiten der Entwickler. Die entwickelten Verfahren sind darüber hinaus nachhaltig einsetzbar und können für zukünftige Aufgaben durch Austauschen der Module immer neu zusammengestellt werden. Durch den Open-Source-Ansatz und die Standardisierungen in ROS kann die Produktivität unter allen Beteiligten gesteigert werden.

## 2 Die Grundprinzipien von ROS

ROS ist ein Framework, in dem die Softwarearchitektur für MSS für einige grundlegende Komponenten wie Schnittstellen, Typisierungen, Netzprotokolle und Installationspakete bereits eindeutig festgelegt ist (ROS 2022). Die Übereinkunft auf gemeinsame Prinzipien erleichtert das Implementieren von Sensortreibern und Analysemethoden für das eigene Projekt wesentlich. Eine stets



**Abb. 1:** ROS-Datentypen können kompakt zusammengestellt ein Messergebnis beschreiben, unabhängig vom Hersteller (z. B. für eine IMU). Für ein einzelnes *Topic* festgelegt werden diese als *Message* an das Framework übergeben.

wachsende Community entwickelt Anwendungen für gängige Problemstellungen aus dem Bereich der Robotik. Für die Entwicklungen in der Geodäsie können Implementierungen zur GNSS-Positionierung, Laserscanner oder Filtermethoden in direkter Folge eingesetzt werden. Hinzu kommt, dass eine Vielzahl von Herstellern bereits ROS zur Steuerung und Datenakquise der jeweiligen Aktoren und Sensoren unterstützt. Daneben stehen Funktionsbibliotheken zur Verfügung, sodass gängige Anwendungsfälle mit geringer Entwicklungzeit ausführbar werden. Dies schafft eine nachhaltige Grundlage für den Ausbau eigener Systeme. Über Projekte und Partner hinweg schafft ROS eine gemeinsame Infrastruktur, die kooperativ weiterentwickelt wird.

Der Aufbau von ROS soll nachfolgend anhand der wichtigsten Begrifflichkeiten erläutert werden. Über sogenannte *Topics* wird ein kontrollierter Datenstrom zwischen den Anwendungen realisiert. Das *Topic* ist eine im Framework gesetzte Schnittstelle, über diese können Daten eines zuvor festgelegten Datentyps eingespielt und abgefragt werden. Der Datenstrom einer inertialen Messeinheit (IMU) kann, unabhängig vom Hersteller des Sensors, immer auf die inhärenten Messergebnisse zurückgeführt werden (siehe Abb. 1).

Eine ROS-fähige Anwendung, auch *Node* genannt, kann z. B. als Sensortreiber agieren. Intern verarbeitete Messergebnisse werden erfasst und als *Topic* vom

Datentyp `sensor_msgs/Imu` im Framework als *Message* (siehe Abb. 1) gepublished (bereitgestellt). Neben den eigentlichen Messwerten erhält jeder Datenpunkt zusätzlich einen Header, in dem auch ein Zeitstempel (*stamp*) sowie ein zugehöriger Koordinatenbezug (*frame\_id*) enthalten sind. Im Sinne einer objektorientierten Programmierung können so immer neue ROS-konforme Datentypen entstehen.

Ein weiterer *Node* kann auf einen Datenstrom aufsetzen (*subscriben*), methodische Verarbeitungen vornehmen und das Ergebnis wiederum für die weitere Verarbeitung zur Verfügung stellen (*publishen*). In der Struktur ergibt sich zwischen den *Nodes* ein modularer Aufbau. Mehrere *Nodes*, die gesammelt in einem definierten Aufgabenkontext vorliegen, werden in *Packages* zusammengefasst. *Packages* sind die höchste Verwaltungseinheit im ROS und werden daher, ähnlich wie eine Funktionsbibliothek, häufig in einem Git-Repository öffentlich zur Verfügung gestellt.

Durch den modularen Aufbau können *Packages* bzw. *Nodes* für dieselbe Aufgabe nebeneinander ausprogrammiert bzw. nachfolgend an verbesserten Versionen gearbeitet werden. Die Integrität des Aufbaus bleibt dabei erhalten, durch die Schnittstellen ändert sich die Struktur nicht. Dadurch können sowohl der Aufbau eines neuen Projekts, als auch in schneller Folge Prototypen entstehen.

Durch die Auswahl aufeinander abgestimmter *Packages* und deren *Nodes* können modular zusammengesetzt komplexe Aufgaben gelöst werden. In Abb. 2 ist exemplarisch der Aufbau eines Verfahrens zur Transformation einer Punkt wolke aufgezeigt. Anhand der Sensordaten einer IMU/GNSS-Lösung kann über einen Kalman-Filter mit hoher Frequenz ein Koordinatenbezug (*tf-frame*) im Raum ermittelt werden (Position und Orientierung). Darauf Bezug nehmend kann das Messergebnis eines Laserscanners georeferenziert werden.

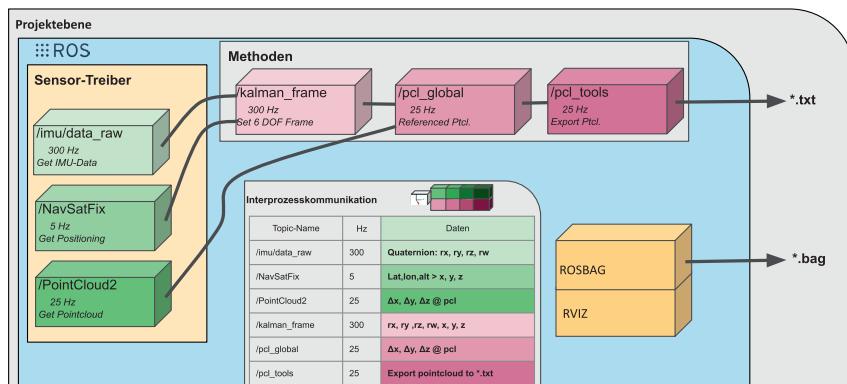


Abb. 2: Modularer Aufbau von *Nodes* (Knoten) und deren *Topics* (Kanten) zur Referenzierung von Punkt wolk en mittels GNSS/IMU-gestützter Lösung (vgl. Linzer et al. 2019)

## tf-frame

In einem MSS werden viele verschiedene Sensoren eingesetzt, die in ihrem lokalen Koordinatensystem Daten erfassen. Der räumliche Ursprung und die Orientierung der einzelnen lokalen Koordinatensysteme werden in ROS mit Hilfe von *tf-frames* einheitlich angegeben (Foote 2013). Einfache Befehle, die das *tf (transform) Package* bereitstellt, ermöglichen es dem Benutzer, Sensordaten zwischen beliebigen *tf-frames* zu transformieren. Alle benötigten Sensordaten lassen sich auf diese Weise in das gewünschte Koordinatensystem transformieren und können so gemeinsam verarbeitet werden. Der globale Bezug lässt sich dabei zum Beispiel über positions- und orientationserfassende Sensoren herstellen.

Die Spezifikation von *tf-frames* und die damit verbundene Möglichkeit, einfach zwischen ihnen zu transformieren, erleichtert allen Beteiligten die Arbeit mit MSS-Daten. Denn der einzelne Nutzer muss nicht alle Koordinatenrahmen des Systems und die Beziehungen zwischen ihnen kennen, sondern nur angeben, welche Sensordaten in welchem Koordinatensystem benötigt werden.

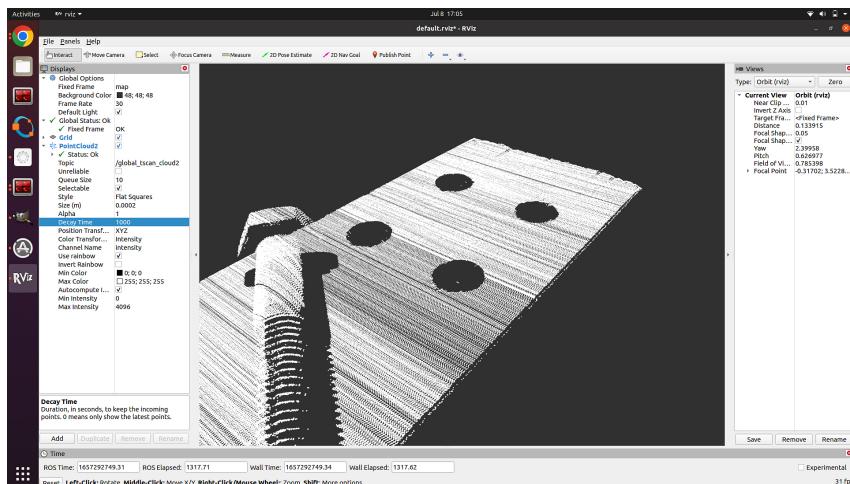
Viele weitere Funktionen, die ein umfassendes Framework ausmachen, sind in ROS bereits implementiert: *Services*, *Clients*, *Parameterserver*, *rviz*, *rosbags*, u. v. m. In einem Tutorial, das durch die Open Source Robotics Foundation öffentlich bereitgestellt wird, kann der Umgang mit ROS erlernt werden (ROS 2022).

## Rosbag

Ein *Rosbag* ist ein ROS-eigenes Archiv, in dem verschiedene *Messages* von beliebigen *Topics* aufgezeichnet und gebündelt verpackt werden können. Alle aufgenommenen *Messages* werden mit dem dazugehörigen Zeitstempel gespeichert und können mit entsprechenden Tools beliebig oft abgespielt werden. Bei einer Wiedergabe werden die gespeicherten Messages der verschiedenen *Topics* chronologisch veröffentlicht und stehen somit allen implementierten Algorithmen zur Verfügung. Somit ist es auch nach einer Messung mit einem MSS möglich, den Messablauf ohne großen Aufwand zu reproduzieren und die Daten anschließend in verschiedene Algorithmen einzuspeisen. Aufgrund ihres standardisierten Formats sind *Rosbags* auch für Außenstehende leicht abspielbar und deshalb für die Übertragung von aufgezeichneten Sensordaten sehr gut geeignet.

## rviz

Mithilfe des Visualisierungstool *rviz* (ROS Visualization) können verschiedene Sensordaten gemeinsam grafisch dargestellt werden. Standardmäßig bietet *rviz* dafür eine Vielzahl von Datentypen, die mit einfachen Befehlen visualisiert



**Abb. 3:** In rviz können ankommende *messages* bzw. verfügbare *topics* direkt visualisiert werden, in diesem Fall eine 3D-Punktwolke.

werden können. So lassen sich beispielsweise 3D-Modelle von Robotern, 3D-Punktwolken von verschiedenen Sensoren, Kamerabilder oder auch Trajektorien gemeinsam visualisieren (beispielhaft in Abb. 3). Durch rviz können also viele verschiedene Daten gebündelt visuell ausgewertet und analysiert werden. Die Darstellung der verschiedenen Datentypen lassen sich dabei durch eine Vielzahl an Einstellungsmöglichkeiten ganz einfach über die Benutzeroberfläche oder durch verschiedene Befehle anpassen. Sollte die gewünschte Einstellungs- option nicht verfügbar sein oder der anzuseigende Datentyp nicht standardmäßig unterstützt werden, besteht die Möglichkeit, eigene Plugins zu schreiben und diese in rviz zu integrieren (Pütz et al. 2019).

## Open-Source-Ansatz

Durch den Open-Source-Ansatz sind Sensortreiber und Analysemethoden nicht als Blackbox zu verstehen. Die Anforderungen an Anwendungen können zu einem großen Anteil von bereits bestehenden Projekten übernommen werden. Darüber hinaus besteht auch die Möglichkeit, in die Ausprogrammierung einzugreifen. Für die Robotik-Community wie auch für die Autoren aus der Geodäsie ist es mit Hilfe von ROS das Ziel, an einer gemeinsamen Grundlage für die komplexen Zusammenhänge im Bereich MSS zu arbeiten. Ob ein Gerät ROS unterstützt, ist demnach ein wichtiges Indiz dafür, wie einfach sich dieses ins MSS integrieren lässt. Dies gilt insbesondere für geodätische Messinstrumente.

### 3 ROS an der TU Wien

Der Forschungsbereich für Ingenieurgeodäsie an der TU Wien hat sich darauf verständigt, vorwiegend Messequipment einzusetzen, das mittels ROS betrieben werden kann. Dies gilt sowohl für dynamische Systeme als auch für statische Messeinrichtungen. Mitarbeitende und Studierende sind in der Lage, Prozessanweisungen zur Ansteuerung geodätischer Messtechnik und Roboter auch aus dem Bereich Open-Source zu formulieren und umzusetzen. In diesem Zusammenhang ist das Vermitteln der Konzepte auch Teil der Lehre und beinhaltet eine Einführung in Linux, Python/C++ und Git. Diese Leitlinie macht es notwendig, schon in der Beschaffung ROS als Kriterium zu beachten. Ergänzend wurde durch die Entwicklung eigener Packages die Ansteuerung von geodätischen Instrumenten wie Tachymetern, Laserscannern und Lasertrackern realisiert.



**Abb. 4:** Eine Auswahl der vorhandenen ROS-fähigen Systeme an der TU Wien, unter anderem von SICK, Clearpath, Universal Robot, RIEGL, Septentrio, Hexagon und Leica

Der im Forschungsbereich eingesetzte Clearpath-Husky ist ein mobiler Roboter, der ab Werk bereits mit ROS-Unterstützung ausgeliefert wird. Auf der etwa 1 Meter langen Plattform kann z. B. ein Tachymeter oder ein RIEGL VZ-400i Laserscanner für geodätische Messungen montiert werden (siehe Abb. 4). Vom Hersteller RIEGL wird für den 3D-Laserscanner ebenfalls ab Werk ein ROS-Package bereitgestellt. In Verbindung mit einer GNSS/IMU-Lösung (z. B. der Firma Septentrio) ist die örtliche Referenzierung im Außenbereich dynamisch möglich. Daneben kommt im Messlabor der TU Wien ein Roboterarm zum Einsatz, mit diesem werden u. a. IMU-Systeme kalibriert, Zeitsynchronisierungen bestimmt oder es dient als System zur Führung einer T-Scan in Kombination mit einem Lasertracker. Folgende ROS-Packages werden an der TU Wien zur Umsetzung angewendet bzw. dort vorangetrieben:

- **husky & husky\_robot:** entwickelt von Clearpath, zum Ansteuern des Husky-Roboters, u. a. zum Auslesen der Odometrie
- **leica\_lmf\_ros & igros\_emscon:** entwickelt von der TU Wien, zur Ansteuerung vom Leica AT960- oder LTD800-Lasertracker + T-Scan

- **ros-riegl-vz:** entwickelt von der Firma RIEGL, zur Ansteuerung eines RIEGL VZ-400i 3D-Laserscanners
- **rosig\_tps\_geocom:** gemeinsame Entwicklung TU Clausthal, LU Hannover, HCU und TU Wien zur Ansteuerung von Leica Tachymetern über geocom
- **septentrio\_gnss\_driver:** entwickelt von Septentrio, zur GNSS/IMU-gestützten Positionierung eines Systems im Außenbereich
- **sick\_scan:** entwickelt von SICK, zur Ansteuerung eines 2D-Laserscanners
- **Universal\_Robots\_ROS\_Driver:** Entwickelt von Universal Robots, zur Ansteuerung des UR5-Roboterarms

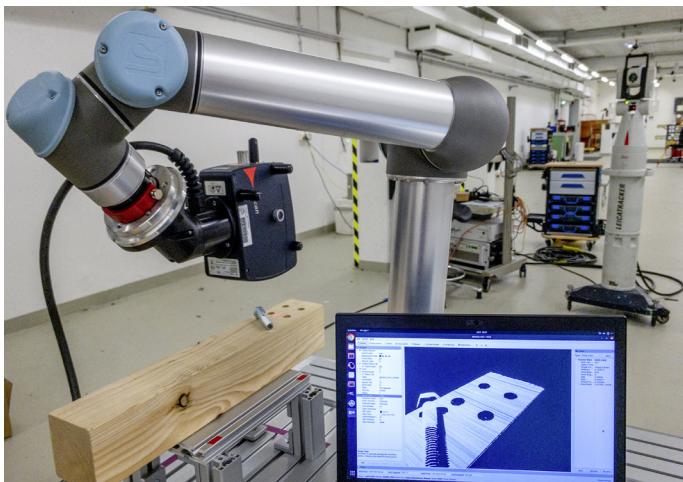
Im Rahmen der Lehre werden Raspberry Pis und virtuelle Maschinen eingesetzt, dies eröffnet den Studierenden den Zugang zur Entwicklungsumgebung. Bisher wurden drei Projektarbeiten umgesetzt, die den geodätischen Anspruch und die zugrundeliegende Informatik miteinander verbinden.

Mit der auf dem Roboterarm montierten T-Scan können Punktwolken erzeugt werden, die nicht wie üblich über den Lasertracker, sondern durch die Winkelstellung der Armbewegung selbst dynamisch referenziert werden. Eine besondere Herausforderung war hierbei die Bestimmung des Hebelarms (Ursprung des Messsystems zum Roboter-Koordinatensystem) und das Erzeugen eines gemeinsamen Zeitbezugs.

Im darauffolgenden Jahrgang wurde im Gebäude ein geodätisches Netz aus Zielzeichen aufgebaut und eingemessen. Auf dem Husky-Roboter wurde, wie bereits beschrieben, ein Tachymeter montiert. Nach der Initialisierung kann dieses durch einen bereits verfügbaren SLAM-Ansatz (package: *ros navigation amcl*) die Roboter-Pose fortwährend bestimmen und selbstständig verfahren. Im Stillstand wird diese Pose herangezogen, um sie als Näherung zur automatisierten Einmessung in das Messnetz zu verwenden. Die Berechnung der als *Ground-Truth* bezeichneten Pose kann daher mit geodätischer Genauigkeit erfolgen.

In einem weiteren Projekt wurde von Studierenden ein Kalman-Filter implementiert. Hierfür wurde auf dem Husky-Roboter ein 360°-Prisma montiert und von einem stationierten Tachymeter während der Fahrt getrackt. Das Filter wurde um zusätzliche Daten wie Odometrie und IMU erweitert, um die Genauigkeit und Zuverlässigkeit der dynamischen Pose zu erhöhen.

Zusätzlich konnten erfolgreich Abschlussarbeiten mit Hilfe von ROS umgesetzt werden. So wurde, aufbauend auf die zweite Übung, der RIEGL VZ-400i Laserscanner auf der Plattform montiert. Das dazugehörige ROS-Package unterstützt eine voxel-basierte Stationierungsmethode. Diese kann den zuvor erwähnten Tachymeterraufbau ersetzen. Über die erfassten Punktwolken kann mit hoher Genauigkeit sowohl die Umgebung erfasst, als auch die eigene Pose von Standpunkt zu Standpunkt mitgeführt werden (Ullrich und Fürst 2017). Durch Hinzunahme eines *Path-Planning-Nodes*, die den Roboter eigenständig



**Abb. 5:**  
Durch das entwickelte Package können auch Leica T-Scan-Daten in *messages* gepackt und als *topic* direkt ausgewertet werden.

verfahren lässt, konnte ein vollautomatischer *Stop&go* Scanning-Betrieb erreicht werden. Neben den dynamischen Systemen können mit ROS aber auch Monitoring-Projekte umgesetzt werden. Im Labor des Fachbereichs wurde ein Temperaturfeld eingerichtet, dass neben der Sensorimplementation auch die Datenhaltung organisiert (Rejchrt et al. 2019).

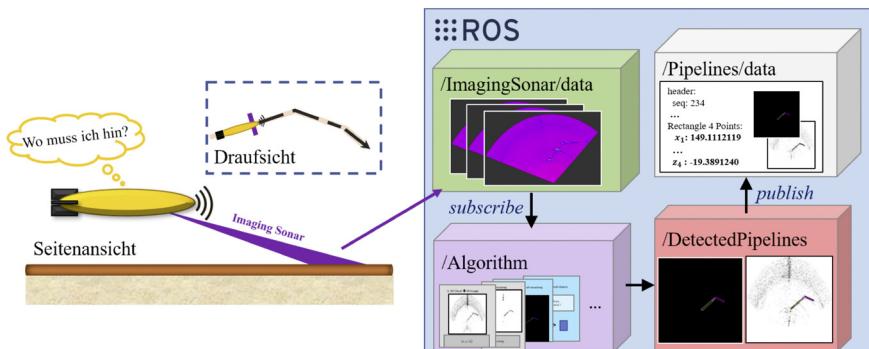
Auch im Aufbau von Messmethoden für Doktoratsstudien wird ROS eingesetzt. Die entwickelten Packages werden unter den wissenschaftlichen Mitarbeitern, aber auch mit anderen Universitäten ausgetauscht. Dies gilt insbesondere für die ROS-Treiber bezüglich der Lasertracker und Tachymeter. In einer Studie wurde der Roboterarm verwendet, um auf diesem ein Prisma auf einer Kreisbahn verfahren zu lassen. Durch die methodische Kalkulation konnte der Zeitoffset des messenden Tachymeters zum GPS-Zeitsystem auf 0,2 ms genau zurückgeführt werden (Thalmann und Neuner 2021). In einer weiteren Untersuchung werden die Messungen einer Leica T-Scan (siehe Abb. 5) mit denen eines terrestrischen Laserscanners gegenübergestellt, durch die Transformation der Systeme ineinander können absolute und systematische Distanzunterschiede vollautomatisch ermittelt werden (Linzer et al. 2019).

Die Grenzen von ROS liegen in den Anforderungen der Echtzeitfähigkeit oder den Datenmengen, die beim Laserscanning entstehen. Dabei handelt es sich jedoch um Problemstellungen, die auch außerhalb von ROS eine Herausforderung darstellen. Für den Forschungsbetrieb und die Weiterentwicklung von Systemen ist der Austausch von Open-Source-Packages eine wichtige Grundlage, um sich auf anspruchsvolle Problemstellungen konzentrieren zu können.

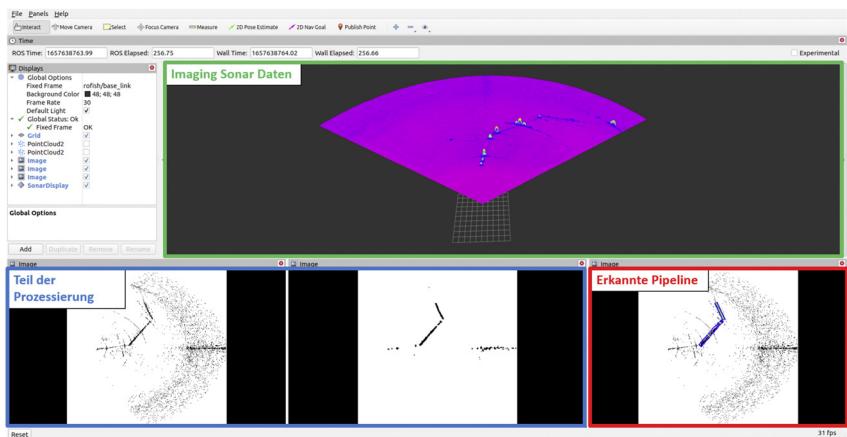
## 4 Entwicklung eines ROS-Nodes im Rahmen eines umfangreichen Verbundprojekts

Die Arbeitsgruppe Hydrographie der HafenCity Universität (HCU) Hamburg ist zusammen mit anderen Projektpartnern an dem Verbundprojekt CIAM (engl.: Comprehensive integrated and fully autonomous subsea monitoring) beteiligt. In diesem Projekt werden autonome Unterwasserfahrzeuge (AUVs) entwickelt, die in der Lage sind, selbstständig Inspektionen von Pipelines in der Tiefsee durchzuführen. Bei den geplanten AUVs handelt es sich um MSS, in denen eine Vielzahl an unterschiedlichen Sensoren eingesetzt werden. Um ein flexibles Bearbeiten von und mit den MSS für alle Projektpartner zu gewährleisten, werden die Systeme mit allen Sensoren in die ROS-Umgebung adaptiert. Durch die Integration in ROS wird ein Rahmen für die Entwicklung der verschiedenen Algorithmen geschaffen, was wiederum eine einfache Zusammenführung aller Arbeiten ermöglicht.

Einer von mehreren Schwerpunkten der HCU in dem großen Aufgabenspektrum ist die automatische Erkennung von Pipelines in bildgebenden Sonardaten (siehe Abb. 6). Weil der detektierte Pipelineverlauf die Route des AUV beeinflussen wird, ist eine Echtzeitdetektion der Pipeline notwendig, weshalb der entsprechende ROS-Knoten in C++ implementiert wird. Um den zugrundeliegenden Algorithmus zu entwickeln und zu testen, stellte der Projektpartner Rosen Testdaten in Form einer Rosbag-Datei zur Verfügung. Diese Datei wurde während einer Messfahrt durch dessen selbstgebaute Trägerplattform in einem Testbecken aufgezeichnet. In diesem Testbecken ist eine Pipeline versenkt, die von den installierten Sensoren erfolgreich erfasst wurde. Die Rosbag-Datei mit den aufgezeichneten Messages der Sensoren kann beliebig oft und dank des



**Abb. 6:** Schematische Darstellung einer Aufgabe der HCU im Rahmen des CIAM-Projekts und der daraus resultierenden Entwicklung eines ROS-Node zur Erkennung von Pipelines in bildgebenden Sonardaten



**Abb. 7:** Rviz-Visualisierung der bereitgestellten Daten, Teil der Zwischenergebnisse der Weiterverarbeitung und der abschließend ermittelten Pipeline

standardisierten Formaten einfach durch verschiedene Projektpartner in ROS abgespielt werden, sodass der Messdurchlauf immer wieder nachgestellt werden kann. Dies ermöglicht die Ausarbeitung und Überprüfung eines ROS-Nodes. Auf diese Weise wurde in Verbindung mit verschiedenen Bildverarbeitungs- und Mustererkennungsmethoden der Algorithmus zur Identifizierung von Pipelines in den bildgebenden Sonardaten implementiert.

Hilfreich bei der Validierung des ROS-Nodes ist, dass die einzelnen Zwischenergebnisse in *rviz* zusammen visualisiert werden können, während die Rosbag-Datei abgespielt wird (siehe Abb. 7). Somit ist es möglich, die Ergebnisse des Algorithmus, der die Pipeline in Echtzeit identifiziert, während der nachgestellten Messfahrt visuell zu überprüfen.

Eine Untersuchung anhand dieser Methode ergab, dass der ROS-Nodes für den bereitgestellten Testdatensatz vielversprechende Ergebnisse liefert: Die Pipeline wird in den Sonarbildern kontinuierlich und zuverlässig durch den entwickelten Algorithmus erkannt. Zur weiteren Validierung des ROS-Nodes wird die erste Rosbag-Datei gegen eine weitere ausgetauscht, die aus einer anderen, unabhängigen Messfahrt stammt. So kann der Algorithmus auf einfache Art und Weise ausgiebig überprüft werden. Sobald der Node darauf validiert ist, kann er ohne großen Aufwand in das ROS-Framework eines AUVs integriert und für die Verfolgung von Pipelines verwendet werden. Hierzu werden die Lage und die Position der identifizierten Pipeline durch den ROS-Node kontinuierlich gepublished und somit für weitere ROS-Nodes von anderen Projektpartnern zur Verfügung gestellt. Diese können die Werte subscriben und für Steuerung des AUVs weiterverarbeiten.

In diesem Gemeinschaftsprojekt hat sich der Einsatz von ROS für die Entwicklung eines MSS durch eine sehr große Zahl von Beteiligten als sehr sinnvoll erwiesen. Es werden die Rahmenbedingungen für die Entwicklung von Algorithmen geschaffen, so dass die abgeschlossenen Implementierungen leicht zusammengeführt werden können. Zudem lassen sich die entwickelten ROS-Packages unkompliziert in andere Projekte überführen und dort einsetzen. Daher bietet es sich an, diese in einer Versionsverwaltung z.B. über Git zu veröffentlichen oder dort selbst im großen Pool der ROS-Packages nach bereits entwickelten Implementierungen für die eigene Aufgabe zu suchen. Doch nicht nur Algorithmen sind leicht zu adaptieren, sondern auch die Sensordaten können dank des standardisierten Formats von Rosbags problemlos zwischen verschiedenen Akteuren ausgetauscht werden. ROS bietet darüber hinaus eine Vielzahl von Tools wie *rviz* oder *tf-frames*, mit denen die Entwicklung von MSS erheblich vereinfacht wird (siehe Abschnitt 2). Ausgehend von diesen Erfahrungen erscheint es sinnvoll, bei geodätischen Aufgaben, wie z.B. der Entwicklung eines MSS, verstärkt mit dem ROS-Framework zu arbeiten.

## 5 ROS-basierte MSS zur Erfassung von anthropogenen und natürlichen Objekten

Am Institute of Geo-Engineering (IGE) der Technischen Universität (TU) Clausthal wird im Geomatics Team das ROS in Lehre und Forschung im Kontext von MSS eingesetzt. Als Sensoren kommen hier 3D-Positions- und Navigationssensoren sowie bildgebende und scannende Sensoren zum Einsatz. Anwendungsfelder in der Lehre und Forschung liegen in der effizienten Erfassung von natürlichen und anthropogenen Objekten.

In der Lehre steht ROS im Modul „Multi Sensor Systems: Design, Calibration and Realization“ im Mittelpunkt. Die Studierenden haben hier in der Regel erstmalig Kontakt mit ROS. Das im Seminarcharakter aufgebaute Modul nutzt den modularen Aufbau von ROS für die Entwicklung von ROS-Nodes in kleinen Teams. Jedes Team ist hier für einen Sensor oder eine Methode für die Datenfusion und Auswertung verantwortlich. Durch seine standardisierten Schnittstellen und Datentypen erfolgt eine sukzessive Zusammenführung der im kleinen Team entwickelten ROS-Nodes zu einem gemeinsamen MSS mit einer gemeinsamen Visualisierung der Sensordaten sowie aus diesen abgeleitete Ergebnisse. Als Sensoren kommen hier vorwiegend consumer-grade Sensoren zur Positionierung und zur Objekterfassung Kameras und Laserscanner, ebenfalls aus dem Consumerbereich, zum Einsatz. Eine besondere Stärke von ROS zur sensorunabhängigen Entwicklung von ROS-Nodes, insbesondere im Bereich der Datenfusion und Auswertung, ist die Nutzung von Rosbag-Dateien, in denen

alle Topics und Messages der Sensoren abgespeichert und beliebig oft wieder abgespielt werden können. Dies ermöglicht gerade in der Teamarbeit im Rahmen der Lehre einen hohen Grad an Flexibilität und parallelen Entwicklungen bei gleichzeitig geringem physischen Sensoreinsatz.

Im Rahmen eines Forschungsprojektes wird am IGE im Geomatics Team ein ROS-basiertes MSS zur Erfassung von natürlichen Objekten im Agrarumfeld aufgebaut. Beim Aufbau des MSS geht es ausschließlich um die Sensorplattform, die auf einem beliebigem Träger im Raum bewegt wird, es kommt also keine (autonome) Aktorik zum Einsatz. In der aktuellen Realisierung erfolgt eine reine Datenerfassung und -fusion sowie Speicherung aller Daten in einem Rosbag. Die Auswertung der Daten erfolgt im post-processing. Das MSS bzw. die Sensorplattform besteht aus einer raum-zeitlich referenzierenden und einer objekterfassenden Komponente. Die raum-zeitlich referenzierende Komponente besteht aus zwei GNSS-Equipments sowie einer MEMS-basierten IMU. Die beiden GNSS-Equipments sind vom Typ ublox M8T sowie ublox ZED-F9P und werden über einen Splitter an einer gemeinsamen GNSS-Antenne vom Typ Tallysman TW3972 betrieben. Die MEMS-basierte IMU ist aktuell im Laserscanner vom Typ Ouster OS1 integriert. Weitere objekterfassende Sensoren sind zwei Kameras vom Typ Allied Vision Alvium 1800U-1236C. Grundsätzlich werden hier vom Hersteller bzw. aus der ROS-Community verfügbare Treiber für die zuvor genannten Sensoren verwendet. Als zentrale Steuer- und Speichereinheit kommt ein Nvidia Jetson Xavier zum Einsatz. Die ROS-Projektebene mit den jeweiligen Topics und deren Interaktion mit nachgelagerten Methoden ist in Abb. 8 skizziert. Eine besondere Herausforderung in einem MSS besteht in der Regel in der zeitlichen Synchronisation der einzelnen Sensor-ROS-Nodes. Hier wird die GPS-Zeit über einen NMEA-String und PPS des GNSS-Equipments genutzt und somit der Nvidia Jetson Xavier jeweils auf GPS-Zeit eingestellt; dieses stellt gleichzeitig die MSS-Zeitbasis dar. Der Laserscanner wird direkt über vorhandene GPIO-Pins mit GPS-Zeit versorgt, so dass die Topics der Punktwolke und der IMU-Daten bereits in GPS-Zeit vorliegen. Die beiden Kameras werden durch einen vom GNSS-Equipment generierten Puls getriggert, so dass hier der Zeitpunkt der Bildauslösung ebenfalls in GPS-Zeit vorliegt. Für eine 3D-Positionsbestimmung des MSS werden zwei parallele Wege beschritten. Zum einen werden GNSS-Beobachtungen für eine Auswertung im post-processing aufgezeichnet und zum anderen erfolgt eine RTK-Auswertung mittels on-board Lösung des ublox ZED-F9P oder alternativ mittels des Open-Source-Tools RTKLIB (<https://rtklib.com>) unter Nutzung von SAPOS-Referenzstationen. Die IMU-Daten werden für eine Identifikation von Bewegungssequenzen genutzt, so dass ein situationsabhängiges Datenaufzeichnen beispielsweise nur während der Bewegung realisiert werden kann. Während der Erfassung ist über vorab bestimmte Kalibrierparameter zwischen Kameras und Laserscanner eine Visualisierung der

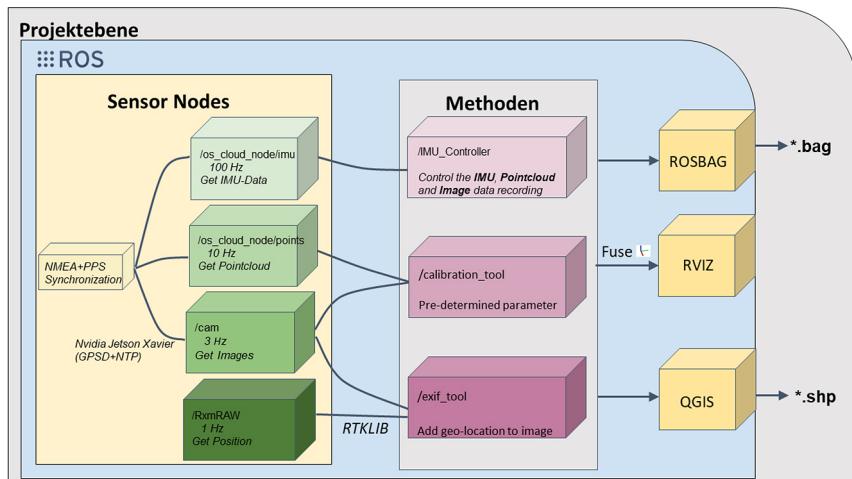


Abb. 8: Zusammenspiel der Sensor-Nodes und Methoden im ROS-basiertes MSS zur Erfassung von natürlichen Objekten im Agrarumfeld

aufgezeichneten Daten in Echtzeit als Kontrolle im Feld möglich. Die weitere Auswertung und Darstellung der Daten u. a. in QGIS erfolgt ausschließlich im post-processing unter Nutzung des aufgezeichneten Rosbag.

## 6 Fazit und Ausblick

Im Beitrag wurden komplexe Projekte und Anwendungsfälle gezeigt, deren Umsetzung mit Hilfe von ROS strukturiert erfolgen konnte und damit gegenüber einer eigenen Entwicklung zusätzlich einen Zeitvorteil mitbringt. Geodätische Messtechnik wird zunehmend komplexer, durch das Modularisieren der Aufgaben und dem Austausch untereinander können adaptiv MSS für jede Situation entwickelt werden. Der Einstieg ins ROS ist aufgrund der breiten Anwendbarkeit, auch über Programmiersprachen hinweg, und einer guten Dokumentation in kürzester Zeit zu bewältigen.

Im Ergebnis wurden bereits die Messungen eines 3D-Laserscanners mit den Stärken selbstfahrender Roboter (TU Wien) gekoppelt, die Entwicklung von autonomen Unterwasserfahrzeugen (AUVs) vorangetrieben (HCU) oder vielfältige Sensorik zur Erfassung von natürlichen Objekten im Agrarumfeld in einem MSS kombiniert (TU Clausthal). Die Relevanz von ROS wird ebenfalls anhand der Publikationen in diesem Feld deutlich, zudem wird an der HCU, der TU Clausthal sowie der TU Wien die Anzahl der Entwicklungen und Projekte weiter steigen. Dieser Aspekt betrifft nicht nur geodätische Anwender unter sich,

durch ROS und den Open-Source-Gedanken wird die Zusammenarbeit über Universitäten und Forschungsgruppen hinweg vereinfacht.

ROS wird stetig weiterentwickelt, mit ROS2 als Nachfolger wird es z. B. möglich, Echtzeitanwendungen mit höherer Qualität umzusetzen. Es ist zu erwarten, dass in Zukunft viele weitere Projekte dank ROS umgesetzt werden können; es ist ein Framework bzw. Rahmen, in dem der Nutzen für alle umso größer wird, je mehr MSS-Anwender sich beteiligen.

## Literatur

- Foote, T. (2013): tf: The transform library. Technologies for Practical Robot Applications (TePRA). International Conference on Technologies for Practical Robot Applications.
- Linzer, F., Barnefske, E., Sternberg, H. (2019): Robot Operating System zur Steuerung eines Modularen Mobile-Mapping-Systems – Aufbau, Validierung und Anwendung. (peer-reviewed). In: avn, Ausgabe 126 (1-2).
- Pütz, S., Wiemann, T., Hertzberg, J. (2019): Tools for Visualizing, Annotating and Storing Triangle Meshes in ROS and RViz. 2019 European Conference on Mobile Robots (ECMR), 1–6.
- Rejchrt, D., Thalmann, T., Ettlinger, A., Neuner, H. (2019): Robot Operating System – A Modular and Flexible Framework for Geodetic Multi-Sensor Systems. In: avn, Ausgabe 126 (6–7).
- RIEGL (2022): Bildquelle – RIEGL, [www.riegl.com](http://www.riegl.com), letzter Zugriff 07/2022 und Package für RIEGL VZ400i, <https://github.com/riegllms/ros-riegl-vz>, letzter Zugriff 07/22.
- ROS Wiki (2022): Open Source Robotics Foundation. <http://wiki.ros.org>, letzter Zugriff 07/2022.
- Thalmann, T., Neuner, H. (2021): Temporal calibration and synchronization of robotic total stations for kinematic multi-sensor-systems. In: Journal of Applied Geodesy, Vol. 15 (Issue 1), 13–30. DOI: [10.1515/jag-2019-0070](https://doi.org/10.1515/jag-2019-0070).
- Ullrich, A., Fürst, C. (2017): Vollautomatischer Ansatz für die Onboard-Datenregistrierung im Terrestrischen Laserscanning. In: DVW e. V. (Hrsg.): Terrestrisches Laserscanning 2017 (TLS 2017). DVW-Schriftenreihe, Band 88, Wißner-Verlag, Augsburg, 145–153.

## Kontakt

Finn Linzer, M.Sc.

Technische Universität Wien (TU Wien)

Wiedner Hauptstraße 8–10, 1040 Wien, Österreich

[finn.linzer@tuwien.ac.at](mailto:finn.linzer@tuwien.ac.at)

Niklas-Maximilian Schild, M.Sc.

HafenCity Universität Hamburg (HCU)

Henning-Voscherau-Platz 1, 20457 Hamburg

[niklas-maximilian.schild@hcu-hamburg.de](mailto:niklas-maximilian.schild@hcu-hamburg.de)

Prof. Dr.-Ing. Jens-André Paffenholz

Technische Universität Clausthal, Institute of Geo-Engineering

Erzstraße 18, 38678 Clausthal-Zellerfeld

[jens-andre.paffenholz@tu-clausthal.de](mailto:jens-andre.paffenholz@tu-clausthal.de)

# Multisensornavigation, Georeferenzierung und SLAM auf Bayes'scher Grundlage – Grundlagen und Systementwicklungen

Reiner Jäger

## 1 Einführung

Der Beitrag behandelt die Navigations- und deren Erweiterung zur SLAM-Zustandsschätzung auf der breiten Basis von Markov-Ketten und einer sich damit verbindenden allgemeinen statistischen Bayes'schen Zustandsbeschreibung. Diese bildet einen einheitlichen Ausgangspunkt für ganz unterschiedliche Methoden zur Schätzung des Navigations- sowie des um die „Map“  $\mathbf{m}^e$  (3D-Punktwolke) im erdfesten ( $e$ ) Rahmen erweiterten SLAM-Zustandsvektors  $\mathbf{y}_t$  (1a) bzw.  $\mathbf{y}'_t = (\mathbf{y}_t, \mathbf{m}^e)^T$  (1b) von Navigationsobjekten (b) oder Messsystemen als Objekte (b) ((b) von engl. Body) mittels verteilter GNSS-, MEMS- und optischer Sensorik.

Eine erste Kategorie von Systemen bzw. Anwendungen für die Schätzungen  $\mathbf{y}_t$  (1a) bzw.  $\mathbf{y}'_t = (\mathbf{y}_t, \mathbf{m}^e)^T$  (1b) sind die Navigation und Steuerung von Boden-, Wasser- und Luftfahrzeugen (u. a. autonomes Fahren und Fliegen) sowie die nahtlose Out- und Indoornavigation von Personen, z. B. mit multisensorischen Smartphones als Body (b). Die Navigations- und SLAM-Zustandsschätzung (1b) bildet auch die Grundlage zur GNSS/MEMS/Optik-basierten Navigation stationärer oder mobiler Robotiksysteme (z. B. Industrieroboter oder Baumaschinen) als zweite Kategorie von Bodies (b) und die sich damit verknüpfende Georeferenzierung der betreffenden Robotik-Werkzeuge (wie z. B. Gelenkarme) über die Denavit-Hartenberg-Gleichungen. Die dritte Kategorie von zu navigierenden Bodies (b) bilden Robotik-basierte (z. B. UAS, Fahrroboter) oder personengeführte GNSS/MEMS/Optik Mapping-Systeme zur Erfassung und Georeferenzierung von 3D-Modellen von Infrastrukturen und Gebäuden, z. B. im BIM-Bereich, über die optische Sensorsystem-Komponente (typischerweise derzeit Lidar, klassische optische Kamera, Time-of-Flight (ToF) Kamera). Für weitere Informationen zum Thema „Systeme“ siehe auch Kapitel 5.

Bei den o.g. Aufgaben der Navigation und Georeferenzierung ist zu unterscheiden, ob die optische Punktwolke  $\mathbf{m}^e$  („3D Map“) in einer erweiterten Navigationszustandsschätzung  $\mathbf{y}'_t = (\mathbf{y}_t, \mathbf{m}^e)^T$  (1b) als Zusatzparameter auftritt oder nicht. Im ersten Fall treten auch die Beobachtungsdaten der Optik im

Sensor- bzw. Plattformsystem Sensor bzw. Plattformbezug als Beobachtungsraum  $\mathbf{m}^{s,p}$  (3D-Laser- oder ToF-Punktwolke, 2D-Bildpixel) des Navigations- oder Messsystems direkt in der Beobachtungskomponente der Bayes'schen Zustandsbeschreibung und -schätzung auf. So erklärt sich im Fall der erweiterten Navigationszustandsbeschreibung (1b) der Begriff SLAM (Simultaneous Localization and Mapping). Die Erweiterung der Navigationszustandsschätzung zu SLAM  $\mathbf{y}'_t = (\mathbf{y}_t, \mathbf{m}^e)^T$  (1b) und das mit der Beobachtungsmenge  $\mathbf{m}^{s,p}$  zugleich vorliegende „Big Data“ Problem können vermieden werden, indem die Bayes'sche Zustandsbeschreibung und die darauf basierte Schätzung eines GNSS/MEMS/Optik-Systems nur mit dem Standardnavigationszustandsvektor  $\mathbf{y}_t$  (1a) erfolgen. In diesem Fall wird die Optik-Beobachtungskomponente  $\mathbf{m}^{s,p}$  entweder komplett fortgelassen oder – wie bei der Methode der visuellen Odometrie (VO) werden alternative Ersatzbeobachtungen aus  $\mathbf{m}^{s,p}$  generiert, die vom Typ her die Map  $\mathbf{m}^e$ -Parametrisierung umgehen. In beiden Fällen hat die Georeferenzierung der Map  $\mathbf{m}^{s,p}$  dann allein über die geschätzten Parameter  $\mathbf{y}_t$  (1a) zu erfolgen. Als Beispiele für solche auf  $\mathbf{y}_t$  (1a) basierende Objektgeoreferenzierungs-Systeme sind das im Rahmen des Projekts PREGON-X entwickelte Smartphone-LaserDisto-Aufnahmesystem für Einzelpunkte von  $\mathbf{m}^e$  PREGON-X (NAVKA-1, 2022) oder das GNSS/MEMS/Kamera-basierte Aufnahmesystem GS18i für die Bestimmung der vollständige 3D Map  $\mathbf{m}^e$  – per Bündelblockausgleichung mit bekannter äußerer Orientierung der Kamera (Schaufler et al. 2021).

Im Weiteren wird zunächst die im FuE-Projekt NAVKA ([www.navka.de](http://www.navka.de)) seit 2010 in verschiedenen FuE-Projekten vorangetriebene moderne GNSS/MEMS/Optik-Multisensor-Multiplattform Navigation, SLAM und Georeferenzierung mit verteilten Sensoren in allgemeiner sog. Leverarmverortung der Sensoren vorgestellt (Jäger et al. 2022).

Es folgt die Darstellung des Navigationszustandsvektors als ereignisbasierte Markov-Kette der auf einen Ausgangszustand folgenden Sensorbeobachtungen  $\mathbf{l}$  und gegebenenfalls auch von Steuerungsmaßnahmen  $\mathbf{u}$ . Diese Markov-Kette wird in einen alle parametrische und stochastische Information subsumierenden Bayes'schen Ansatz als Ausgangspunkt der Navigationszustandsschätzung überführt. Die Bayes'sche Ausgangsbasis erlaubt die Integration der auf physikalischen Grundannahmen zum Bewegungsmodell sowie auf diskrete Steuerungen basierten Transitionsgleichungen aufeinanderfolgender Navigationszustände über die Chapman-Kolmogorov-Gleichung. Einhergehend mit zwei Annahmen zu Markov-Prozessen 1. Ordnung wird die finale Bayesbasierte a-posteriori-Dichtefunktion zur Navigationszustandsschätzung aus obigen Komponenten dargestellt (Thrun et al. 2005, Hertzberg et al. 2012, Jäger 2018, Jäger et al. 2022).

Mit diesem Ausgangspunkt können dann alle bekannten Zustandsschätzungen hergeleitet werden. Dazu gehören das klassische L2-Norm Kalman-Filter, Robuste M-Schätzung basierte Kalman-Filter, das Partikelfilter, SLAM u. a. Die

Bayes'sche Grundlage liefert damit den gemeinsamen Nenner bzw. die Wurzel für die in verschiedenen Disziplinen (Robotik, Mechatronik, Luft- und Raumfahrt, Geodäsie, u.a.) und Anwendungen in unterschiedlichen Verzweigungen verfolgten mathematischen Modelle und Algorithmen zur Zustandsschätzung und Steuerung der o.g. Multisensor-Multiplattform-Navigationssysteme, ebenso wie autonome oder händisch geführte moderne multisensorische Messsysteme.

Es erscheint dem Autor daher wichtig zu betonen, dass die geodätische Ausgleichungsrechnung bzw. Parameterschätzung – nach Koch (2007) und nunmehr mit den o.g. modernen interdisziplinären Aufgaben (Thrun et al. 2005, Wendel 2011, Hertzberg et al. 2012, Jäger 2018) – und neuen Anforderungen in Geodäsie und Navigation in Gestalt innovativer komplexer Systeme auch im Berufsalltag (Jäger 2019, Zwiener 2019, Schaufler et al. 2021, Espinoza und Jäger 2022) einem Paradigmenwechsel unterzogen und auf einheitliche Bayes'sche Grundlage (7) gestellt werden sollte. Dazu gehört auch die Behandlung der Leverarm-behafteten Beobachtungsgleichungen (3a,3b) der GNSS/MEMS/Optik-Sensorik in der Lehre. Dieser Beitrag soll diesen Wandel in der Lehre, Forschung und im Berufsleben befördern. Im Rahmen dieses Beitrages muss es aufgrund der Seitenzahlbeschränkung bei der Herleitung des klassischen L2-Norm Kalman-Filters auf der Grundlage der Bayes-basierten Navigationszustandsbeschreibung und der Diskussion von zwei aktuellen Problemstellungen sowie der kurzen Vorstellung von zwei adäquaten Projekten bleiben. Für weitere Grundlagen wird u.a. auch auf Jäger et al. (2022) verwiesen.

## 2 Modellierung verteilter Sensoren und Markov-Ketten

### 2.1 Navigations- und SLAM-Zustandsvektor

Der multisensoriell (GNSS/MEMS/Optik) fortlaufend zu bestimmende zeitabhängige (t) Navigationszustandsvektor  $y_t$  lautet:

$$y_t = \left( x^e \ y^e \ z^e \ | \dot{x}^e \dot{y}^e \dot{z}^e \ | \ddot{x}^e \ddot{y}^e \ddot{z}^e \ | \ r^e \ p^e \ y^e \ | \omega_{eb,x}^b \ \omega_{eb,y}^b \ \omega_{eb,z}^b \ | \dot{\omega}_{eb,x}^b \ \dot{\omega}_{eb,y}^b \ \dot{\omega}_{eb,z}^b \right)^T \quad (1a)$$

Sollen die im Sensor bzw. Plattformbezug als Beobachtungsraum  $m^{sp}$  erfassten optischen Sensordaten (3D-Laserpunktewolke, 3D-ToF-Punktwolke, 2D-Bildpixel) als Informationen zur 3D Map des damit registrierten Objekts direkt im einheitlichen erdfesten (e) System parametrisiert werden, so ist  $y_t$  (1a) mit den Parametern  $m^e$  der 3D Map (der 3D-Koordinaten des Objekts) zu erweitern, und es entsteht der SLAM-Zustandsvektor  $y'_t$ . Dieser lautet dann:

$$y'_t = (y_t, m^e)^T \quad (1b)$$

Er umfasst im erdfesten Rahmen (e) die 18 zeitabhängigen 3D-Standardnavigationsparameter  $y_t$  der Position, Geschwindigkeit, Beschleunigung, Orientierung, Drehraten und Drehratenänderungen des Body (b) und die stationäre 3D Map  $m^e$  (erstinstanzlich die optische 3D-Punktwolke).

## 2.2 Verteilte GNSS-MEMS-Sensoren und Leverarm-Verortung

In der Praxis der Multisensor(s)-Multiplattform(p)-Navigation, wie sie im Rahmen des o. g. FuE-Projekts NAVKA ([www.navka.de](http://www.navka.de)) algorithmisch und softwaremäßig in Systementwicklungen konsequent umgesetzt wurde, sind die einzelnen Sensoren  $s_{ij}$  mit bis zu 11 sog. Sensor-Leverarmparametern im Leverarmvektor  $sl_{ij}$  auf dem zu navigierenden Body (b) zu „verorten“ (Abb. 1).

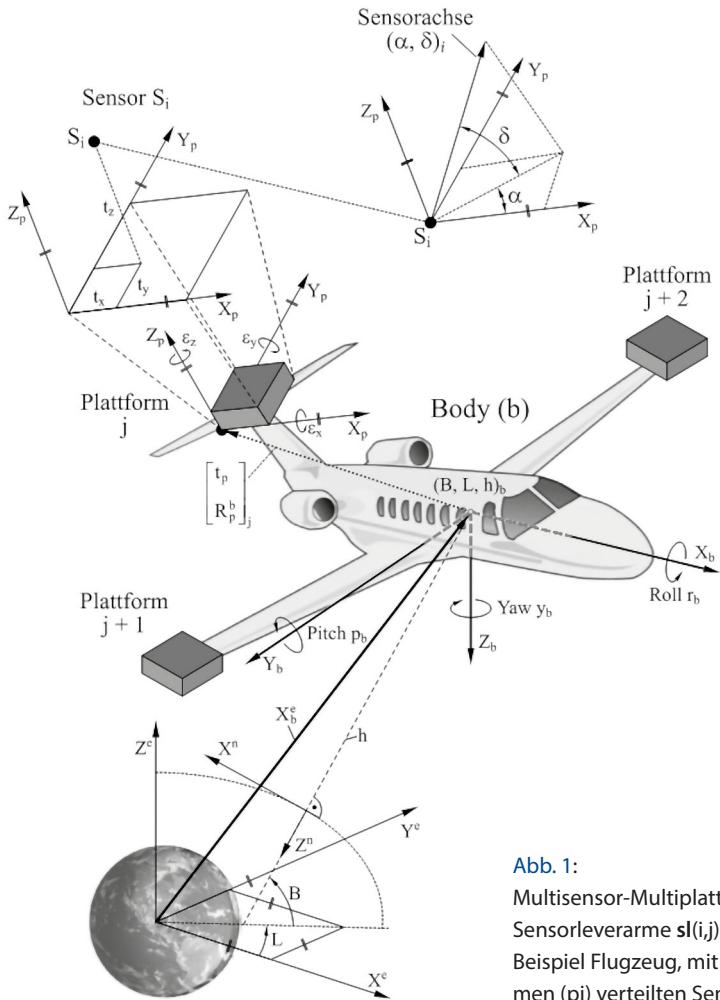
Dabei handelt es sich in  $sl_{ij}$  um die drei Parameter zum Translationsvektor  $t_{p_j}^b$  der j-ten Plattform  $p_j$  im Body-Frame (b), die drei Parameter der Rotationsmatrix  $R_{p_j}^b$  der j-ten Plattform  $p_j$  gegenüber dem Body-Frame (b), die drei Translationsparameter  $t_{s_{ij}}^{p_j}$  des i-ten Sensors  $s_{ij}$  gegenüber dem Koordinatenursprung der j-ten Plattform  $p_j$  sowie die beiden Parameter  $(\alpha, \delta)_{s_{ij}}$  zur Orientierung des i-ten Sensors  $s_{ij}$  auf der j-ten Plattform  $p_j$ . Ferner die Rotation  $R_{p_j}^b$  sowie die Translation  $t_{p_j}^b$  der j-ten Plattform gegenüber dem Body (b). Die insgesamt 11 Leverarmparameter  $sl_{ij}$  stellen sich wie folgt dar:

$$\text{Sensorposition: } \mathbf{x}_{s_{ij}}^e = \mathbf{x}_b^e + R_b^e(r, p, y) \cdot \left[ t_{p_j}^b + R_{p_j}^b \cdot t_{s_{ij}}^{p_j} \right] \quad (2a)$$

$$\text{Sensororientierung: } (\alpha, \delta)_{s_{ij}} \quad (2b)$$

Mit (2a) ist die zentrale Verortungsbeziehung zur Reparametrisierung des bei der Entwicklung der individuellen Sensorbeobachtungsgleichungen  $l_{ij}$  erstinstanzlich auftretenden Sensororts  $\mathbf{x}_{s_{ij}}^e$  durch die Parameter der Position  $\mathbf{x}_b^e$  und der Orientierung  $(r, p, y)$  des Body (b) als Elemente des Navigationszustandsvektors  $y_t$  (1a) wiedergegeben (siehe Abb. 1). Die Sensororientierung  $(\alpha, \delta)_{s_{ij}}$  (2b) legt die Messrichtung (sensitive Achse) des i-ten Sensors auf der j-ten Plattform  $S_{ij}$  fest.

Grundsätzlich hängen die zeitlich dynamischen Sensorbeobachtungen  $l_{ij}$ , damit sowohl vom dynamischen globalen Bodyzustandsvektor  $y_t$  (1a) als auch von den insgesamt 11 statischen Leverarmparametern  $sl_{ij}$  ab (Jäger et al. 2012, Jäger 2014, Jäger 2018, Jäger 2019, Jäger et al. 2022). Die einzelnen Sensorbeobachtungen können sowohl als skalare Größen (zu modellierende Einzelbeschleunigung oder Einzeldrehrate einer IMU) oder als vektorielle Beobachtungen (3D-Lasersannerpunkt) auftreten, daher wird mit



**Abb. 1:**  
Multisensor-Multiplattform-Design.  
Sensorleverarme  $sl(i,j)$  des Body (b),  
Beispiel Flugzeug, mit auf Plattfor-  
men ( $p_j$ ) verteilten Sensoren  $sij$

$$l(i,j)_t = l(y_t, sl(i,j))_t \quad (3a)$$

die allgemeinere Vektorform verwendet. Im Fall von SLAM ist die einzelne Beobachtung nur mit dem um die 3D Map  $\mathbf{m}$  erweiterten Parameterraum  $y'_t = (y_t, \mathbf{m}^e)^T$  (1b) darstellbar, und es gilt entsprechend:

$$l(i,j)_t = l(y_t, \mathbf{m}^e, sl(i,j))_t. \quad (3b)$$

Abgesehen von der speziellen Aufgabe der „Change-Detection“ (Änderungsfeststellung) trägt die Map  $m^e$  im erdfesten Rahmen (e) i. A. keinen Zeitstempel. Die nicht-linearen Verbesserungsgleichungen mit Leverarmen für eine Vielzahl von Sensoren finden sich in Jäger et al. (2012).

## 2.3 Markov-Ketten und Überführung in Bayes-Beziehungen

Als erster wesentlicher stochastischer Bestandteil der fortlaufenden Zustands schätzung von  $y_t$  (1a) dienen als Standardinformationsquelle die Sensorbeobachtungen (3a,b), die im Weiteren mit  $l_t$  zum Vektor aller Sensorbeobachtungen zum Zeitpunkt t zusammengefasst werden. Weitere hinzutretende stochastische Komponenten von Systemen sind die Steuerungsmaßnahmen  $u_t$ . Darunter subsumieren systemspezifische aktive interne oder externe Einflussgrößen, die formal mitgeführt, aber im Weiteren nicht ausgeführt werden.

Insgesamt bedingen die dem Ausgangszustand  $y_0$  – in zeitlich aufeinander folgender Verkettung – folgenden o. g. stochastischen Ereignisse  $e_{0:t}$

$$e_{0:t} = (l_0, l_1, \dots, l_{t-1}, l_t, u_0, u_1, \dots, u_{t-1}, u_t) = (l_{0:t}, u_{0:t}) \quad (4a)$$

den Systemzustand  $y_t$  (1a) bzw.  $y'_t$  (1b) zum Zeitpunkt t. Damit werden  $y_t$  (1a,b) in erster Instanz durch die Markov-Verkettung (4a) der dem stochastischen Ausgangszustand  $y_0$  folgenden stochastischen Ereignisse  $e_{0:t}$ , die den Zustandsvektor  $y_t$  festlegt. O. B. d. A. können sich die weiteren Betrachtungen auf die eigentlichen Navigationszustandsparameter  $y_t$  (1a) erstrecken, und die Erweiterung auf  $y'_t$  (1b) an späterer Stelle erfolgen. Es gilt ausgehend von (4a):

$$y_t = y_t(e_{0:t}, y_0) = y_t(l_{0:t}, u_{0:t}, y_0) = y_t(l_0, l_1, \dots, l_{t-1}, l_t, u_0, \dots, u_{t-1}, u_t, y_0). \quad (4b)$$

Nimmt man die Fehlerdichtefunktionen der stochastischen Ereignisse  $y_0$ ,  $l_{0:t}$  und  $u_{0:t}$  als gegeben an, so repräsentiert (4b) in stochastischer Betrachtungsweise mit

$$\text{bel}(y_t) = p(y_t | y_0, l_{0:t}, u_{0:t}) = p(y_t | y_0, l_{0:t}, l_t, u_{0:t}). \quad (4c)$$

die bedingte Dichte  $p(y_t | y_0, l_{0:t}, u_{0:t})$  – in der Literatur zur Robotik mit „bel“ als Belief  $\text{bel}(y_t)$ , deutsch „Überzeugungsdichte“ (Hertzberg et al. 2012) bezeichnet – des aktuellen Navigationszustandsvektors  $y_t$  unter der Bedingung, dass die stochastischen Ereignisse  $y_0$ ,  $l_{0:t}$  und  $u_{0:t}$  (4a) eingetreten sind. Die Invertierung der Ausgangsbezeichnung liefert mit dem Bayes-Theorem (Koch 2007, Thrun et al. 2005, Lambert 2018) für bedingte Dichten unmittelbar:

$$\text{bel}(\mathbf{y}_t) = p(\mathbf{l}_t | \mathbf{y}_t, \mathbf{y}_0, \mathbf{l}_{0:t-1}, \mathbf{u}_{0:t}) \cdot \frac{p(\mathbf{y}_t | \mathbf{y}_0, \mathbf{l}_{0:t-1}, \mathbf{u}_{0:t})}{p(\mathbf{l}_t | \mathbf{y}_0, \mathbf{l}_{0:t-1}, \mathbf{u}_{0:t})}. \quad (4d)$$

Mit der von dem zu schätzenden Systemzustand  $\mathbf{y}_t$  (1a) unabhängigen Dichtefunktion im Nenner von (4d) kann deren Kehrwert als Normierungsfaktor  $\eta = p(\mathbf{l}_t | \mathbf{y}_0, \mathbf{l}_{0:t-1}, \mathbf{u}_{0:t})^{-1}$  vorgezogen werden, und es resultiert:

$$\text{bel}(\mathbf{y}_t) = \eta \cdot p(\mathbf{l}_t | \mathbf{y}_t, \mathbf{y}_0, \mathbf{l}_{0:t-1}, \mathbf{u}_{0:t}) \cdot p(\mathbf{y}_t | \mathbf{y}_0, \mathbf{l}_{0:t-1}, \mathbf{u}_{0:t}). \quad (4e)$$

Mit einer ersten Markov-Annahme – der Postulation von (4e) als Markov-Kette 1. Ordnung bzgl.  $\mathbf{l}_t$  – wird festgelegt, dass die Sensorbeobachtungen  $\mathbf{l}_{(i,j)_t}$  (3a) zum Systemzustand zum Zeitpunkt  $t$  allein durch den aktuellen Bodyzustand  $\mathbf{y}_t$  (1a) und den zeitinvarianten bekannten Leverarmen  $\mathbf{sl}(i,j)$  der Sensoren (Abb. 1) zu parametrisieren sind. Damit reduziert sich die Kette der stochastischen Variablen in  $p(\mathbf{l}_t | \mathbf{y}_t, \mathbf{y}_0, \mathbf{l}_{0:t-1}, \mathbf{u}_{0:t})$  auf  $p(\mathbf{l}_t | \mathbf{y}_t, \mathbf{sl}(i,j))$ , und es gilt:

$$1. \text{ Markov-Annahme: } p(\mathbf{l}_t | \mathbf{y}_t, \mathbf{y}_0, \mathbf{l}_{0:t-1}, \mathbf{u}_{0:t}) = p(\mathbf{l}_t | \mathbf{y}_t, \mathbf{sl}(i,j)). \quad (5a)$$

Mit der 1. Markov-Annahme (5a) geht (4e) über in:

$$p(\mathbf{y}_t | \mathbf{y}_0, \mathbf{l}_{0:t}, \mathbf{u}_{0:t}) = \eta \cdot (p(\mathbf{l}_t | \mathbf{y}_t, \mathbf{sl}(i,j))) \cdot p(\mathbf{y}_t | \mathbf{y}_0, \mathbf{l}_{0:t-1}, \mathbf{u}_{0:t}). \quad (5b)$$

Damit eine externe Zustandsvorhersage informativ genutzt werden kann, wird in die bedingte Dichtefunktion  $p(\mathbf{y}_t | \mathbf{y}_0, \mathbf{l}_{0:t-1}, \mathbf{u}_{0:t})$  auf der rechten Seite von (9.4b) – über das sogenannte Chapman-Kolmogorov Integral (Thrun et al. 2006, Wendel 2011, Jäger 2018) – schließlich noch der vorausgehende Zustandsvektor  $\mathbf{y}_{t-1}$  integriert. Es resultiert:

$$\begin{aligned} \text{bel}(\mathbf{y}_t) &= p(\mathbf{y}_t | \mathbf{y}_0, \mathbf{l}_{0:t-1}, \mathbf{u}_{0:t}) \\ &= \int p(\mathbf{y}_t | \mathbf{y}_0, \mathbf{l}_{0:t-1}, \mathbf{u}_{0:t}, \mathbf{y}_{t-1}) \cdot p(\mathbf{y}_{t-1} | \mathbf{y}_0, \mathbf{l}_{0:t-1}, \mathbf{u}_{0:t}) \cdot d\mathbf{y}_{t-1}. \end{aligned} \quad (6a)$$

Weiter kann für die Dichte  $p(\mathbf{y}_t | \mathbf{y}_0, \mathbf{l}_{0:t-1}, \mathbf{u}_{0:t}, \mathbf{y}_{t-1})$  in (6a) die

$$2. \text{ Markov-Annahme: } p(\mathbf{y}_t | \mathbf{y}_0, \mathbf{l}_{0:t-1}, \mathbf{u}_{0:t}) = p(\mathbf{y}_t | \mathbf{y}_{t-1}, \mathbf{u}_t) \quad (6b)$$

getroffen werden, wonach der aktuelle Zustand nur von seinem Vorgänger  $\mathbf{y}_{t-1}$  und den in Schritt  $t$  stattfindenden Systemsteuerungen  $\mathbf{u}_t$  abhängt. Eine vollständig rekursive Modellbildung lässt sich schließlich generieren, indem im Kolmogorov-Chapman-Integral (6a) der Term

$$p(\mathbf{y}_{t-1} | \mathbf{y}_0, \mathbf{l}_{0:t-1}, \mathbf{u}_{0:t-1}) = \bar{p}(\mathbf{y}_{t-1}) = \text{bel}(\mathbf{y}_{t-1}) \quad (6c)$$

direkt als die aus (6a) resultierte Dichte  $\bar{p}(y_{t-1})$  bzw. des Belief  $bel(y_{t-1})$  der vorausgehenden Zustandsschätzung  $y_{t-1}$  (1a) bis zum Zeitschritt  $t-1$  identifiziert und bzgl. der aktuellen Zeit  $t$  in (6a) eingeführt werden. Wir erhalten:

$$\underbrace{p(y_t|y_0, l_{0:t}, u_{0:t})}_{bel(y_t)} = \eta \cdot \underbrace{p(l_t|y_t, sl(i,j))}_{\substack{\text{Dichtefkt. d. Beob.} \\ \text{Gauß-Markov-Modell}}} \cdot \underbrace{\int_{-\infty}^{+\infty} p(y_t|y_{t-1}, u_t) \cdot \bar{p}(y_{t-1}) dy_{t-1}}_{\substack{\text{bel}(y_{t-1}) \\ \overbrace{\text{bel}(y_t)}}}. \quad (7)$$

(Jäger 2018). Das mit  $\overline{bel}(y_t)$  in (7) abgekürzte Integral wird auch als Vorhersagedichte oder allgemein a-priori-Information bezeichnet. Das stochastische Vorhersagemodell  $p(y_t|y_{t-1}, u_t)$  bezeichnet man als Transitionsdichte.

### 3 Bayes-basierte Navigations- und SLAM-Zustandsschätzung

#### 3.1 Vorbetrachtungen

Auf der allgemeinen Bayes'schen Grundlage der dazu mit (7) festgelegten Überzeugungsdichte  $bel(y_t)$  von  $y_t$  (1a) lassen sich eine Vielzahl von Schätzertypen für den Navigationszustandsvektor  $y_t$  (1a) festlegen bzw. herleiten. Die Modellierung eines SLAM-basierten Zustandsvektors  $y'_t = (y_t, m^e)^T$  (1b) stellt sich als Erweiterung von  $y_t$  (1a) um die Parameter  $m^e$  der 3D-Map sowie der Terme  $p(l_t|y_t, sl(i,j))$ ,  $\overline{bel}(y_t)$  und  $p(y_t|y_0, l_{0:t}, u_{0:t}) = bel(y_t)$  in (7) dar.

Es bestehen – als weiteres und weitreichendes Alleinstellungsmerkmal – bzgl. der Bayes-Zustandsbeschreibung (7) keine Voraussetzungen an den Typ der beteiligten Dichtefunktionen der stochastischen Größen auf der rechten Seite von  $bel(y_t)$  (7). So sind auch Mischdichten zulässig, z. B. eine Gleichverteilung von  $y_0$  über einen größeren Ortsbereich ( $x, y, z$ ) sowie für die Orientierung ( $r, p, y$ ) eines Roboters, welcher zum Startzeitpunkt  $t_0$  einer geplanten Inbetriebnahme mit unbekannter Orientierung ( $r, p, y$ ) an unbekanntem Ort ( $x, y, z$ ) verweilt. In diesem Fall wäre, ausgehend von (7), ein sog. Partikelfilter (Wendel 2011) als zielführend herzuleiten (Jäger et al. 2022). Die allgemeine Bayes-basierte Zustandsbeschreibung (7) bildet somit den Ausgangspunkt einer Reihe von Zustandsschätzern (Thrun et al. 2005), von denen im Rahmen dieses Beitrags im Folgenden lediglich der Übergang von (7) auf die klassische Kleinstes-Quadrat (L2) Kalman-Filterung vorgestellt werden kann.

### 3.2 Bayes Zustandsbeschreibung und Klassisches Kalman-Filter

Wie in Metzger (2006) und in Thrun et al. (2005) gezeigt, resultiert bei normal-verteilten Komponenten  $p(\mathbf{y}_t | \mathbf{y}_{t-1}, \mathbf{u}_t)$  und  $\text{bel}(\mathbf{y}_{t-1}) = \bar{p}(\mathbf{y}_{t-1})$  im Ergebnis des Kolmogorov-Chapman Integrals (7) als a-priori-Information bzw. Vorhersagedichte  $\text{bel}(\tilde{\mathbf{y}}_t) = \mathbf{y}_{t-1}$  zum Zustandsvektor  $\mathbf{y}_t$  (1a) bzw.  $\mathbf{y}'_t = (\mathbf{y}_t, \mathbf{m}^e)^T$  (1b) beim SLAM ebenfalls wieder eine u-dimensionale Normalverteilung. Mit  $\mathbf{y}_t$  (1a) gilt die Dimension  $u = 18$ . Wir erhalten:

$$\overline{\text{bel}}(\mathbf{y}_t) = \frac{1}{(\sqrt{2\pi})^u \sqrt{\det(C_{y_{t-1}})}} \cdot e^{-\frac{1}{2}(\tilde{\mathbf{y}}_t - \mathbf{y}_{t-1})^T \cdot C_{y_{t-1}}^{-1} \cdot (\tilde{\mathbf{y}}_t - \mathbf{y}_{t-1})} \sim N(0, C_{y_{t-1}}) \quad (8a)$$

Nimmt man, begründet mit t dem zentralen Grenzwertsatz der Statistik, einen ebenfalls normalverteilten n-dimensionalen Sensorbeobachtungsvektor (3a) an, so resultiert als Belief  $\text{bel}(\mathbf{y}_t)$  (7) das Produkt

$$\begin{aligned} \text{bel}(\mathbf{y}_t) &= \eta \cdot \frac{1}{(\sqrt{2\pi})^n \cdot \sqrt{\det(C_{\epsilon,t})}} \cdot e^{-\frac{1}{2}(\tilde{\mathbf{I}}(\tilde{\mathbf{y}}_t) - \mathbf{I}_t)^T \cdot C_{\epsilon,t}^{-1} \cdot (\tilde{\mathbf{I}}(\tilde{\mathbf{y}}_t) - \mathbf{I}_t)} \\ &\cdot \frac{1}{(\sqrt{2\pi})^u \cdot \sqrt{\det(C_{y_{t-1}})}} \cdot e^{-\frac{1}{2}(\tilde{\mathbf{y}}_t - \mathbf{y}_{t-1})^T \cdot C_{y_{t-1}}^{-1} \cdot (\tilde{\mathbf{y}}_t - \mathbf{y}_{t-1})}. \end{aligned} \quad (8b)$$

Unter äquivalenter Umformung von (8b) und mit den Abkürzungen  $c_1$  und  $c_2$  für die fixen Terme erhalten wir aus (8b) eine  $(u+n)$ -dimensionale Normalverteilung, wiederum mit dem Erwartungswert 0, und es gilt:

$$\begin{aligned} \text{bel}(\mathbf{y}_t) &= \eta \cdot c_1 \cdot c_2 \cdot e^{-\frac{1}{2} \left( \tilde{\mathbf{I}}(\tilde{\mathbf{y}}_t) - \mathbf{I}_t \right)^T \cdot \begin{pmatrix} \mathbf{C}_{\epsilon,t} & 0 \\ 0 & \mathbf{C}_{y_{t-1}} \end{pmatrix}^{-1} \cdot \left( \tilde{\mathbf{I}}(\tilde{\mathbf{y}}_t) - \mathbf{I}_t \right)} \\ &\sim N\left(0, \begin{pmatrix} \mathbf{C}_{\epsilon,t} & 0 \\ 0 & \mathbf{C}_{y_{t-1}} \end{pmatrix}\right) \end{aligned} \quad (8c)$$

Mit der Normalverteilung (8c) begründet sich die Maximum-Likelihood-Schätzung (M-Schätzung) – mit  $\text{bel}(\mathbf{y}_t)$  (8c) zugleich als Likelihood-Funktion – als Optimalschätzung  $\hat{\mathbf{y}}_{t_M}$  für  $\tilde{\mathbf{y}}_t$ , und wir erhalten:

$$\hat{\mathbf{y}}_{t_M} = \underbrace{\arg\max_{\text{bel}(\mathbf{y}_t)} \{ p(\mathbf{I}_t | \mathbf{y}_t) \cdot \overline{\text{bel}}(\mathbf{y}_t) \}}_{\text{bel}(\mathbf{y}_t)} \text{ und damit} \quad (8d)$$

$$\hat{y}_{t_M} = \underset{\hat{y}_{t_M}}{\operatorname{argmax}} \left\{ \eta \cdot c_1 \cdot c_2 \cdot e^{-\frac{1}{2} \cdot \left( \tilde{I}_t(\tilde{y}_t) - I_t \right)^T \cdot \begin{pmatrix} C_{\epsilon,t} & 0 \\ 0 & C_{y_{t,t-1}} \end{pmatrix}^{-1} \cdot \left( \tilde{I}_t(\tilde{y}_t) - I_t \right)} \right\} \Big|_{\hat{y}_{t,M}} \quad (8e)$$

Mit  $\hat{y}_{t_M}$  wird die M-Schätzung von  $\tilde{y}_t$  bezeichnet. Mit dem negativen Exponenten der Exponentialfunktion (8e) ist die Forderung des Maximums äquivalent zur Forderung des Minimums des Exponenten und damit zur Kleinsten-Quadrat-Schätzung als die Maximum-Likelihood Lösung  $\hat{y}_{t_M}$  von (8d,8e). Die Kleinsten-Quadrat-Schätzung stellt sich dar als:

$$\hat{y}_{t_M} = \underset{\hat{y}_{t_M}}{\operatorname{argmin}} \left\{ \left( \tilde{I}_t(\tilde{y}_t) - I_t \right)^T \cdot \begin{pmatrix} C_{\epsilon,k} & 0 \\ 0 & C_{y_{t,t-1}} \end{pmatrix}^{-1} \left( \tilde{I}_t(\tilde{y}_t) - I_t \right) \right\} \Big|_{\hat{y}_{t,M}} \quad (8f)$$

und umfasst die stochastischen Beobachtungskomponenten der Sensorbeobachtungen  $I_t$  und der Vorhersage(beobachtung)  $y_{t,t-1}$  zum Zeitpunkt t. Aus (8f) und der Linearisierung der i. A. nicht-linearen Sensorbeobachtungsgleichungen  $I(i,j)_t = l(y_t, sl(i,j))_t$  (3a) – o. B. d. A. auch für  $I(i,j)_t = l(y_t, m, sl(i,j))_t$  (3b) – mit Näherungswerten  $y_{t,0}$  geht das Verbesserungsgleichungssystem

$$I_t + v_I = A_t(y_{t,0}, sl(i,j)) \cdot d\hat{y}_{t_M} + I_t(y_{t,0}) ; \quad C_{\epsilon,t} \quad (9a)$$

$$y_{t,t-1} + v_y = I \cdot d\hat{y}_{t_M} + y_{t,0} ; \quad C_{y_{t,t-1}} \quad (9b)$$

hervor. Die Kleinsten-Quadrat-Minimierung (8f) liefert mit (9a,9b) dann die Lösung

$$d\hat{y}_{t,M} = \left( C_{y_{t,t-1}}^{-1} + A_t^T C_{\epsilon,t}^{-1} A_t \right)^{-1} \left( A_t^T C_{\epsilon,t}^{-1} (I_t - I_t(y_{t,0})) + C_{y_{t,t-1}}^{-1} (y_{t,t-1} - y_{t,0}) \right) \quad (9c)$$

$$\hat{y}_{t,M} = y_{t,0} + d\hat{y}_{t,M} \quad (9d)$$

Wählt man o. B. d. A. als zugleich sehr gute Näherung mit  $y_{t,0} =: y_{t,t-1}$  die Vorhersage  $y_{t,t-1}$ , so geht die Maximum-Likelihood-Schätzung (9c,9d) über in

$$\hat{y}_t = y_{t,t-1} + \left( C_{y_{t,t-1}}^{-1} + A_t^T C_{\epsilon,t}^{-1} A_t \right)^{-1} \cdot A_t^T C_{\epsilon,t}^{-1} \cdot (I_t - I_t(y_{t,t-1})), \text{ mit} \quad (10a)$$

$$A_t = A_t(y_{t,t-1}, sl(i,j)) \quad (10b)$$

Die Lösung (10a,10b) der optimalen Maximum-Likelihood (M) Zustandsschätzung  $\hat{y}_t = \hat{y}_{t,M}$  von  $y_t$  (1a) bzw.  $y'_t$  (1b) im Fall einer insgesamt normalverteilten Überzeugungsdichte  $bel(y)$  (8b) ist – mit der Identifikation vom

$$\mathbf{K}_t = \left( \mathbf{C}_{y_{t,t-1}}^{-1} + \mathbf{A}_t^T \mathbf{C}_{\varepsilon,t}^{-1} \mathbf{A}_t \right)^{-1} \mathbf{A}_t^T \mathbf{C}_{\varepsilon,t}^{-1} \quad (10c)$$

als die Kalman-Matrix  $\mathbf{K}_t$  – als klassische Kleinste-Quadrate (L2-Norm) Kalman-Filterung identifiziert, und es gilt:

$$\hat{\mathbf{y}}_t = \mathbf{y}_{t,t-1} + \mathbf{K}_t \cdot (\mathbf{l}_t - \mathbf{l}_t(\mathbf{y}_{t,t-1})), \text{ mit} \quad (10d)$$

$$\mathbf{C}_{\hat{\mathbf{y}}_t} = \left( \mathbf{C}_{y_{t,t-1}}^{-1} + \mathbf{A}_t^T \mathbf{C}_{\varepsilon,t}^{-1} \mathbf{A}_t \right)^{-1} = (\mathbf{I} - \mathbf{K}_t \mathbf{A}_t) \cdot \mathbf{C}_{y_{t,t-1}}^{-1} \quad (10e)$$

In der Literatur findet sich mit der Herleitung der Kalman-Filterung auf anderen Wegen auch die zu  $\mathbf{K}_t$  (10c) identische Form

$$\mathbf{K}_t \equiv \mathbf{C}_{y_{t,t-1}}^{-1} \mathbf{A}_t^T \left( \mathbf{C}_{\varepsilon,t}^{-1} + \mathbf{A}_t \mathbf{C}_{y_{t,t-1}}^{-1} \mathbf{A}_t^T \right)^{-1}. \quad (10f)$$

Alternativ können – insbesondere robuste – Kalman-Filterungen zu (10d,10e,10f) entweder auf der Grundlage von (7) oder ausgehend von (9a,9b) als M-Schätzungen mit dem Übergang auf exponentielle Fehlerdichten mit beschränkter 1. Ableitung, anstelle der Normalverteilung, hergeleitet werden (Gonzalez und Jäger 2005, Zwiener 2019, Jäger et al. 2022).

## 4 Diskussion spezieller Probleme bei Systementwicklungen

### 4.1 Aktiver SLAM versus passive Georeferenzierung

Zur Erläuterung des Sachverhaltes des aktiven SLAM gegenüber einer passiven Georeferenzierung wird an dieser Stelle die vektorwertige 3D-Beobachtung  $\mathbf{l}(i,j)_t = \mathbf{l}(\mathbf{y}_t, \mathbf{m}^e, \mathbf{sl}(i,j))_t$  (3b) eines Laserscanning des Einzelpunkts  $\mathbf{m}_i$  betrachtet. Der 3D-Einzelpunkt  $\mathbf{m}_i$  repräsentiert im Kontext mit SLAM und Georeferenzierung als Beobachtung  $\mathbf{l}(i,j)_t = \mathbf{l}(\mathbf{y}_t, \mathbf{m}^e, \mathbf{sl}(i,j))_t =: \mathbf{x}_{t,\mathbf{m}_i}^p$  das zum Zeitpunkt  $t$  im System (p) der Laserscanner-Plattform (p) beobachtete Einzelement der Map  $\mathbf{m}^e$ . Die Einzelpunktbeobachtung  $\mathbf{l}_t = \mathbf{x}_{t,\mathbf{m}_i}^p$  kommt als 3D-Polarpunkt aus den Laserscanner-Rohdaten  $(s_{i,t}^p, z_{i,t}^p, \alpha_{i,t}^p)$ , d.h. der zum Zeitpunkt  $t$  im Plattformsystem beobachteten Strecke, Zenitdistanz und Richtung zustande als

$$\mathbf{l}_t = \mathbf{x}_{t,\mathbf{m}_i}^p = s_{i,t}^p \cdot \begin{pmatrix} \sin z_i \cdot \cos \alpha_i \\ \sin z_i \cdot \sin \alpha_i \\ \cos z_i \end{pmatrix}_t^p \quad (11a)$$

(Tessema et al. 2019). Nimmt man an, dass die Laserscannerplattform direkt auf den Body (z. B. UAS) montiert ist, so reduzieren sich die Leverarme  $\mathbf{sl}(i,j)$  für die Plattformbeobachtung  $\mathbf{l}_t = \mathbf{x}_{t,m_i}^p$  (11a) auf die insgesamt nur sechs Leverarmparameter in Gestalt der drei Translation  $\mathbf{t}_p^b$  und der drei Rotationsparameter  $\mathbf{R}_p^b$  der Laserscanner-Plattform (p) gegenüber dem Body (b). Die Laserscanner-Beobachtung  $\mathbf{l}_t = \mathbf{x}_{t,m_i}^p$  ist bei deren aktiver Verwendung zur Navigation dem Bereich SLAM zuzuordnen, da sie nur in der Form  $\mathbf{l}_t = \mathbf{l}(\mathbf{y}_t, \mathbf{m}^e, \mathbf{sl}(i,j))_t$  (3b), d. h. mit dem um die Map erweiterten Parametervektor  $\mathbf{y}'_t = (\mathbf{y}_t, \mathbf{m}^e)^T$  (1b) darstellbar ist. Das nichtlineare Gauß-Markov-Modell zur Dichtekomponente  $p(\mathbf{l}_t | \mathbf{y}_t, \mathbf{sl}(i,j))$  der Bayes-basierten Zustandsbeschreibung (7) bzw. im speziellen Fall  $\mathbf{l}_t$  (9a) lauten damit schließlich

$$\mathbf{l}_t = \mathbf{x}_{t,m_i}^p = \mathbf{R}_p^{bT} \cdot \left[ \mathbf{R}_b^e(r, p, y)_t \cdot \left( \mathbf{x}_{m_i}^e - \mathbf{x}_{b,t}^e \right) - \mathbf{t}_p^b \right]. \quad (11b)$$

Als Parameter des 18-parametrischen Navigationszustandsvektors  $\mathbf{y}_t$  (1a) treten in (11b) über die zeitabhängige Attitudematrix  $\mathbf{R}_b^e(r, p, y)_t$  (Jäger et al. 2022) die drei Orientierungsparameter Roll ( $r$ ), Pitch ( $p$ ) und Yaw ( $y$ ) sowie mit  $\mathbf{x}_{b,t}^e$  die ebenfalls dreidimensionale Position des Body (b) auf.

Zur Umgehung des mit dem tiefgekoppelten SLAM (11b) entstehenden Big-Data Problems sowie weiterer Probleme, wie z. B. die Berücksichtigung von Schleifenschlüssen bei wiederkehrenden Punkten  $\mathbf{m}_i$  (Hertzberg et al. 2012, Thrun et al. 2005) in der Echtzeitmodellierung, kann mit

$$\mathbf{x}_{t,m_i}^e = \mathbf{x}_{b,t}^e + \mathbf{R}_b^e(r, p, y)_t \cdot \left( \mathbf{t}_p^b + \mathbf{R}_p^b \cdot \mathbf{x}_{t,m_i}^p \right) \quad (11c)$$

eine lediglich passive Georeferenzierung der 3D-Punktwolke über den einheitlichen Zeitstempel  $t$  erfolgen. Nachteiliger Weise gehen die Punktwolkenbeobachtungen  $\mathbf{x}_{t,m_i}^p$  über die passive Georeferenzierung (11c) im Gegensatz zu SLAM (11b) nicht informativ in die Zustandsschätzung ein. Sie tragen damit auch nicht zur Bestimmung der prinzipiell georeferenzierenden Parametern  $\mathbf{y}_t$  (1a) bei. Bei der Verwendung von Kameras kann jedoch anstelle tief gekoppeltem SLAM  $\mathbf{y}'_t$  (1b) die Methode der Visuellen Odometrie (VO) zur Anwendung kommen. Bei dieser „halbaktiven“ Methode zur informativen Nutzung der Optikkomponente von GNSS/MEMS/Optik-Systemen in Form der 2D-Kamera-Bildkoordinaten  $\mathbf{m}_i$  auf informativ tieferer Ebene als der damit hinterlegte Positions- und Orientierungsbezug  $\mathbf{m}_i$ , nämlich in Form deren über  $\mathbf{m}_i$  gebildeten 1. Ableitungen, werden bei VO über die Leverarme der betreffenden Mono- oder Stereo-Kamera, in quasi Echtzeit, direkte Beobachtungen für den Parametersubraum Geschwindigkeit und Orientierung  $(\dot{\mathbf{x}}^e \dot{\mathbf{y}}^e \dot{\mathbf{z}}^e | \omega_{eb,x}^b \omega_{eb,y}^b \omega_{eb,z}^b)$  von  $\mathbf{y}_t$  (1a) ermittelt (Jäger 2019, Jäger et al. 2022).

## 4.2 Synchronisation und Zeitstempeltransfer

Den aktuellen Systementwicklungen von GNSS/MEMS/Optik-Sensorplattformen zur Navigation, für SLAM und Georeferenzierung im Labor für GNSS und Navigation liegt der Zeitsynchronisations-Standard IEEE 1588 aller Sensordaten zugrunde. Die zur Zustandsschätzung, ausgehend von (7) oder mit (10a), ein-treffenden Beobachtungen  $\mathbf{l}_{t_i}$  tragen damit zwar hochgenaue aber dennoch individuelle Zeitstempel  $\mathbf{l}_{t_i}$ . Zur gemeinsamen Sensorfusion bzw. der Schätzung von  $\mathbf{y}_t$  (1a) und  $\mathbf{y}'_t$  (1b) zum Zeitpunkt  $t$  können die einzelnen Beobachtungen  $\mathbf{l}_{t_i}$  nach

$$\mathbf{l}_t = \mathbf{l}_{t_i \pm \Delta t} = \mathbf{l}_{t_i} + \Delta \mathbf{l}_{t_i, \Delta t}, \text{ mit } \Delta \mathbf{l}_{t_i, \Delta t} = \left( \frac{\partial \mathbf{l}(\mathbf{y}_t, \mathbf{m}^e, \mathbf{sl}(i,j))}{\partial t} \right)_{t_i} \cdot (\pm \Delta t), \quad (12a,b)$$

d. h. einer nach  $\Delta \mathbf{l}_{t_i, \Delta t}$  (12b) rechnerischen individuellen Korrektur, einen fusionsgerechten Zeitstempeltransfer hin zu  $\mathbf{l}_t = \mathbf{l}_{t_i \pm \Delta t}$  mit dem gemeinsamen Fusionszeitstempel  $t$  erfahren. Mit (12b) werden zeitliche Ableitungen von  $\mathbf{y}_t$  (1a) adressiert (Jäger et al. 2022).

## 5 Aktuelle GNSS/MEMS/Optik-Systemrealisierungen im Labor für GNSS und Navigation

Aktuelle Realisierungen von GNSS/MEMS/Optik-Systemen zur Navigation, autonomem out- und indoor Flug, SLAM und Georeferenzierung erfolgen in den laufenden FuE-Projekten HOBA (IAF-1 2022) und MITESENS (IAF-2 2022) des Labors für GNSS und Navigation der Hochschule Karlsruhe (<http://goca.info/Labor.GNSS.und.Navigation/index.php>). Für weitere Informationen wird auch auf [www.navka.de](http://www.navka.de) verwiesen.

Die FuE im Projekt HOBA mit MTS ([www.mts-online.de](http://www.mts-online.de)) als Kooperationspartner umfassen eine an die Aushubmaschine angebrachte Sensorbox, in einer an die Maschinendaten angekoppelten und einer autarken Variante, beide mit dem Ziel der 3D-Georeferenzierung des Aushubs im BIM-gerechten globalen ITRF/ETRF89-Bezug in Verbindung mit der Erfassung und Berechnung eines 3D-Voxelvolumenmodells des Aushubs  $\mathbf{m}^e$ , der Voxel-weisen Klassifizierung der Bodenarten über bildbasierte KI/ML-Algorithmen sowie die Rückrechnung der klassifizierten und georeferenzierten 2D-Einzelbilder auf das 3D-Voxelmodell der Baugrube.

Im bundesweiten, durch das Bundesministerium für Landwirtschaft und Ernährung finanzierten Verbundprojekt MITESENS, umfassen die FuE im

Labor für GNSS und Navigation die Hard- und Softwareentwicklungen zum AUS-Sensorboard, zur UAS Flugsteuerung (FC) samt Ground Control Software und diversen FuE zur Photogrammetrie, insgesamt mit dem Ziel der Spinnmilbenerkennung mittels eines Indoor UAS als universelle mobile Trägerplattform (Espinoza und Jäger 2022). Die intelligente FC für den autonomen UAS Indoorflug des MITESENS UAS mit Hinderniserkennung und -umfliegung in Gewächshäusern basiert auf SLAM mit der algorithmischen Fusion der UAS-Sensordaten von RGB-Kameras, Laserscanner, GNSS, Inertialsensorik, Inklinometer und Barometer. Als Ergebnis der Sensordatenfusion resultiert der o. g. hochgenaue Navigationszustandsvektor  $y_t$  bzw.  $y'_t$ . Der Navigationszustandsvektor  $y_t$  und die sich damit verknüpfende hochgenaue IEEE 1588 Zeitsynchronisation aller Sensoren, inklusive der 2D-Bilddaten der zur Milbendetektion auf dem UAS befindlichen Multispektralkamera, sind nicht nur der Schlüssel für die Navigations- und Steuerungskomponente der zu entwickelnden FC, sondern auch die zentralen Zustandsgrößen zur Rückrechnung der klassifizierten 2D-Bilder  $m_i$  mit genauem Zeitstempel und äußerer Orientierung auf den Pflanzenbestand (3D-Voxel-Modell  $m^c$ ).

## Literatur

- Espinoza, F., Jäger, R. (2022): UAS-System MiteSens – Spinnmilbenbefall im Unterglasanbau frühzeitig erkennen. In: Zeitschrift Landinfo 01/2022. [www.openagrar.de/receive/zimport\\_mods\\_00002652](http://www.openagrar.de/receive/zimport_mods_00002652).
- Gonzalez, F., Jäger, R. (2005): GNSS/GPS/LPS based Online Control and Alarm System (GOCA) – Mathematical Models and Technical Realisation of a System for Natural and Geotechnical Deformation Monitoring and Hazard Prevention. IAG Series on Geodesy Symposia: Springer.
- Hertzberg, J., Lingemann, K., Nüchter, A. (2012): Mobile Roboter. Springer Vieweg, Heidelberg.
- IAF-1 (2022): [www.h-ka.de/iaf/hoba](http://www.h-ka.de/iaf/hoba), letzter Zugriff 07/2022.
- IAF-2 (2022): [www.h-ka.de/iaf/mitesens](http://www.h-ka.de/iaf/mitesens), letzter Zugriff 07/2022.
- Jäger, R. (2014): Navigation mit verteilten GNSS/MEMS Sensoren – Mathematische Modelle, Algorithmen und Anwendungspotenziale. Horizonte (43). ISSN 1432-0174. 7–10.
- Jäger, R. (2018): Multisensornavigation auf Bayes'scher Grundlage – Stand, Anwendungen und Entwicklungen. In: Schriftenreihe des Studiengangs Geodäsie und Geoinformatik, Vol. 2018–1. 123–130.
- Jäger, R. (2019): Multisensorische 3D-Mappingsysteme für BIM – SLAM basierte Navigation und Steuerung, Systemrealisierung MSM und Profil künftiger Entwicklungen. Buchbeitrag zur Internationalen Geodätischen Woche 2019, Obergurgl, Österreich. Wichmann Verlag. 286–293.

- Jäger, R., Diekert, J., Hoscislawski A., Zwiener, J. (2012): SIMA – Raw Data Simulation Software for the Development and Validation of Algorithms for GNSS and MEMS based Multi-Sensor Navigation Platforms. Proceedings of the FIG Working Week. May 6–10, 2012, Rome, Italy.
- Jäger, R., Müller, T., Saler, H. (2022): Klassische und robuste Ausgleichungsverfahren. Ein Leitfaden für Ausbildung und Praxis von Geodäten und Geoinformatikern. 2. Auflage. Wichmann Verlag.
- Koch, K.-R. (2007): Introduction to Bayesian Statistics. Springer, Berlin und Heidelberg.
- Lambert, B. (2018): A Student's Guide to Bayesian Statistics. Sage Publishing.
- Metzger, J. (2006): Optimierung des Akquisitions- und Tracking Verhaltens zentraler und modularer Terrainnavigationssysteme. Dissertation, Universität Karlsruhe, ITE.
- NAVKA-1 (2022): Projekt PREGON-X. [www.navka.de/index.php/de/weitere-projekte/abgeschlossene-projekte/fue-projekte-produkte-2](http://www.navka.de/index.php/de/weitere-projekte/abgeschlossene-projekte/fue-projekte-produkte-2), letzter Zugriff 07/2022.
- Schaufler, S., Luo, X., Richter, B. (2021): Multi-Sensorsystem für hochpräzise, georeferenzierte visuelle Punktbestimmung. 21. Internationale Geodätische Woche Obergurgl, Österreich.
- Tessema, L. S., Jäger, R., Stilla, U. (2019): A Mathematical Sensor Model for Indoor use of a Multis-Beam Rotating 3D Lidar. In: Int. Arch. Photogrammetry Remote Sens. Spatial Inf. Sci., XLII-2/W16, 227–234.
- Thrun, S., Burgard, W., Fox, D. (2005): Probabilistic Robots. The MTT Press, Cambridge, Massachusetts, London.
- Wendel, J. (2011): Integrierte Navigationssysteme. Oldenburg Verlag, München und Wien. 2. Auflage.
- Zwiener, J. (2019): Robuste Zustandsschätzung zur Navigation und Regelung autonomer und bemannter Multikopter mit verteilten Sensoren. Dissertation, TU Darmstadt. ISBN 978-3-935631-43-3. DOI: [10.25534/tuprints-00011668](https://tuprints.ulb.tu-darmstadt.de/00011668).

## Kontakt

Prof. Dr.-Ing. Reiner Jäger

Hochschule Karlsruhe – University of Applied Sciences. Institut für Angewandte Forschung (IA) und Fakultät für Informationsmanagement und Medien (IMM), Labor für GNSS und Navigation

Moltkestrasse 30, 76133 Karlsruhe

[reiner.jaeger@web.de](mailto:reiner.jaeger@web.de)



## **Session 2: Multisensortechologie in Geosensornetzwerken und Infrastruktur**



# Klassische und bildbasierte Tachymetrie als Teilnetze multisensoraler untertägiger Überwachung des geomechanischen Gebirgsverhaltens

Focke Jarecki

## 1 Einführung

In größerem Maßstab setzen die Markscheidereien der Bundesgesellschaft für Endlagerung mbH (BGE) klassische, automatisierte und bildbasierte Tachymetrie zu Bauwerks- bzw. Gebirgsüberwachungszwecken im Rahmen der Umrüstung der Schachtanlage Konrad in Salzgitter zum Endlager für schwach- und mittelradioaktive Abfälle ein. Insbesondere am Schacht Konrad 2, durch den die Abfallgebinde nach der Inbetriebnahme nach unter Tage gebracht werden sollen, sind umfangreiche Auffahrungs- und Erweiterungsarbeiten zur Schaffung eines neuen Infrastrukturbereichs auf der 2. Sohle in etwa 850 m Teufe (bei etwa -750 m NHN) durchgeführt worden. Hier muss Raum für den Umgang mit den Abfallbehältern, insbesondere für das Umladen vom vertikalen Transport im Schacht auf die horizontale Förderung in die Einlagerungskammern geschaffen werden. Dazu wird ein Umladeplatz, das bergbaulich so genannte Füllort, in ungewohnten Dimensionen (13 m Auffahrturdurchmesser über insgesamt ca. 70 m Länge inklusive der Schachtdurchdringung) neu aufgefahren. Außerdem werden hier, im späteren atomrechtlichen Kontrollbereich, Werkstätten und weitere Infrastruktureinrichtungen getrennt vom konventionellen Grubengebäude benötigt, da ein Freimessen der benötigten Einrichtungen für Wartungszwecke nicht wirtschaftlich darstellbar ist. Aus dem gleichen Grunde sollen die Grubenräume dieses Bereichs für die Betriebszeit zur Vermeidung von Ausbruchmaterial und sonstigem Bauschutt, der zur Verbringung aus dem Kontrollbereich ebenfalls freiemessen werden müssten, wortungsfrei hergestellt werden. Daher benötigen sie einen qualifizierten Ausbau, der mindestens die während der avisierten 40 Jahre Betriebszeit auftretenden Gebirgskräfte sicher ableitet. Um diese Gebirgskräfte konkret abschätzen zu können, wurde für die Auffahrungen und Sanierungsarbeiten ein umfangreiches geotechnisches Messprogramm aufgesetzt, das vor allem der Kalibrierung der Parameter des grundlegenden numerischen Gebirgsmodells dient, um letztendlich korrekte Schnittkräfte für die korrekte Dimensionierung des tragenden Ausbaus

der Grubenräume abzuleiten. Aus dem Gebirgsmodell können weitere Informationen wie beispielsweise Konvergenzprognosen (als Konvergenz bezeichnet man die Verformungsreaktion der geschaffenen Hohlräume auf den Gebirgsdruck, vergleichbar mit Setzungseffekten bei Bauwerken über Tage) abgeleitet werden. Teilweise erfolgt die Kalibrierung dann invers über diese leicht messbaren, abgeleiteten Werte, zum Teil sind die entsprechenden Messwerte und Prognosen auch direkte Steuerungsparameter – so baut man eine feste Betonschale vorzugsweise nach Abklingen der hauptsächlichen Konvergenzen in Reaktion auf die Hohlräumerstellung ein. Dieser Zeitpunkt lässt sich direkt aus Konvergenzmessungen bzw. den Bewegungsraten beobachtbarer Gebirgspunkte, also an den Stößen (Wänden) der Grubenräume bestimmen. Neben direkten Konvergenzmessungen auf freiliegenden Messtrecken in den neuen Grubenräumen umfasst das Messprogramm vor allem Mehrfachextensometer, die mit mehreren Ankerpunkten die Entspannung des Gebirges bis in 40 m Tiefe von den neuen Hohlräumen über die Erfassung der Dehnung der entsprechenden Abschnitte der Messeinrichtung bestimmen. Extensometer, Konvergenzmessstrecken und dreidimensional bestimmbarer Stoßpunkte sind in der Regel in gemeinsamen Querschnitten angeordnet. Meist gelingt tatsächlich die Kollokation, so dass alle Verfahren auf denselben charakteristischen Punkt des Gebirges messen.

## 2 Multisensorale untertägige Überwachung

Die Einführung scheint bereits auf die verschiedenen verwendeten Sensoren hinzu deuten:

Neben unterschiedlichen tachymetrischen Verfahren sind hier insbesondere die in Bohrungen im Gebirge fest verbauten Mehrfachextensometer zu nennen, bei denen es sich in diesem Fall um Glasfiber-Stangenextensometer handelt. Hier werden die Verschiebungsmesswerte direkt mit kapazitiven Wegaufnehmern bestimmt (es existieren unterschiedliche Bauformen und Messprinzipien, angewendet werden etwa auch magnetische Lagesensoren, anwendbar sind sicherlich auch faseroptische Systeme). Mit mehreren Stangenlängen und damit Wegaufnehmern sowie den zur Kompensation von Temperaturoausdehnungseffekten in den verschiedenen Verankerungstiefen zusätzlich installierten Temperaturgebern stellt das Extensometer bereits ein eigenes Multisensorsystem (MSS) dar.

Etwas einfacher sind meist die Einrichtungen zur direkten Konvergenzmessung geartet. Klassisch werden Konvergenzstrecken mit einem kalibrierten Konvergenzmessband gemessen. Dieses wird zur Messung an speziellen Bolzen (im Falle der Schachtanlage Konrad in Ringösen) der eine Konvergenzstrecke bildenden, in einer spezifizierten Tiefe im Gebirge verankerten Konvergenzpunkte

angebracht. So kann eine hochgenaue Streckenmessung durchgeführt werden, mit dem Ziel (differentiell) Streckenänderungen und Änderungsraten abzuleiten. Das Messband wird mit bestimmter (gemessener) Federkraft mit dem sogenannten Konvergenzmessgerät gespannt und die (Rest)-Streckenablesung mittels (digitaler) Messuhr durchgeführt. Durch die Federkraftmessung könnte auch bei dieser manuellen Methode der Konvergenzstreckenmessung von mehreren Sensoren in einem System gesprochen werden. Allerdings wird hier, abgesehen von der Anbringung von Kalibrierparametern, lediglich ein eindimensional gerichteter Messwert direkt erzeugt.

Bleiben als dritte Gruppe die unterschiedlichen verwendeten tachymetrischen Verfahren. Allein die klassische Tachymetrie als Kombination von Strecken- und Richtungsmessung stellt ein Multisensorsystem dar. Abgeleitet vom Theodoliten (selbst streng ein Multisensorsystem für Vertikalwinkel- und Horizontalrichtungsmessung) löst bereits (oder besonders) bei klassischen, *mechanischen* Tachymetern der Instrumentenbau die erste Grundfragestellung aller Multisensoranwendungen: Die Zusammenführung der Sensorenbezugssysteme in einem Instrumentenbezugssystem. Im eigentlichen, modernen Sinne kann man dann spätestens seit der Integration beider (bzw. aller dreier) Elemente mit elektronischen Abgriffen und der Weiterverarbeitung der polaren Messelemente z. B. zu kartesischen Koordinaten im Instrumentenrechner von einem Multisensorsystem sprechen. Spätestens mit der Automatisierung und der Fernsteuerbarkeit von elektronischen Tachymetern wird damit die zweite Grundfragestellung aller Multisensoranwendungen zum offensichtlichen Thema: die Zeitsynchronisation.

Mit dem Schritt, die Anzielung entsprechender Messpunkte über das per CMOS-Videochip abgegriffene Fernrohrbild extern automatisch durchführen zu lassen, haben die Markscheidereien der BGE gemeinsam mit den Firmen Glötzl GmbH und Remolution Software GmbH auf Grundlage der Leica Multi-station TM50 wiederum ein offensichtliches MSS geschaffen (Paffenholz et al. 2018), vermutlich als Zwischenschritt auf dem Wege zur integrierten Auswertung des Fernrohr-Videobilds. Auch hier ist die Kollokation der Messelemente instrumentenbaulich gelöst bzw. eingegrenzt, das Zusammenspiel der unterschiedlichen Erfassungs-, Auswerte- und Steuerprozesse auf der Zeitschiene aber eine anwendungsabhängige Fehlerursache (Becker et al. 2020).

Dieser Beitrag gibt den Anlass, die unterschiedlichen Messsysteme mit besonderem Fokus auf den unterschiedlichen tachymetrischen Systemen und auf ihre Besonderheiten als eigene MSS zu untersuchen, gleichzeitig aber zu beleuchten, wie die Messwerte oder die abgeleiteten Ergebnisse in einem gemeinsamen MSS zur Bauwerksüberwachung zusammengeführt werden können. Die Idee eines solches Sensornetzwerks inklusive der korrekten Verarbeitung der entsprechenden, verschiedenartigen Daten, rückt die Fragestellung sogar hin

zu einer Betrachtungsweise im Kontext der verteilten Datensammlung und des Internet of Things.

Ob, wie und warum bei den bisherigen BGE-Überwachungsprojekten dieser Art eine Zusammenführung in der Auswertung gelingen kann, ist nur vor dem Hintergrund der bisherigen Auswertestrategien für die einzelnen MSS im Sinne von Teilnetzen der multisensoralen untertägigen Überwachung beantwortbar. Das jeweils größte Teilnetz, das gleichzeitig die Verbindung zwischen den örtlich verteilten eindimensionalen Messstrecken schafft, wird jeweils tachymetrisch gemessen und bildet im Zweifelsfall durch die Kombination mehrerer Standpunkte ein eigenes MSS. Gleichzeitig stellt sich der Auswerteprozess der tachymetrischen Messungen als am bei weitem aufwendigsten dar. Deswegen wird auf die auswertetechnische Herangehensweise für die tachymetrischen Messungen, sowohl hinsichtlich der Videotachymetrie als eigenes MSS, als auch hinsichtlich der Netzmessung und Deformationsanalyse, hier noch einmal gesondert eingegangen.

## 2.1 Videotachymetrie

In den tunnelartigen horizontalen Grubenbauen wiederholen sich Ausbau- und Überwachungselemente in symmetrischer Anordnung. Gemeinsam mit der langgezogenen Geometrie ergeben sich in Blickrichtung fest installierter Überwachungsinstrumente damit geringe relative Winkelinkremente zwischen den einzelnen Überwachungspunkten. Der Einsatz der Videotachymetrie wird in diesem Zusammenhang von Paffenholz et al. (2018) und Becker et al. (2020) wie folgt dargestellt.

Um der limitierten Trennschärfe bei Verwendung der etablierten ATR-Technologie (Ehrhart und Lienhart 2016) und der damit einhergehenden Punktverwechslungsgefahr Rechnung zu tragen, werden die Punktsignalisierungen dabei mittels kosteneffizienter passiver Videozielzeichen realisiert. Unter der Maßgabe, eine hohe Robustheit, insbesondere gegenüber temporären Verdeckungen des Zielzeichens, bei gleichbleibender Zuverlässigkeit und variierenden Zielweiten bis 50 m zu gewährleisten, wurde ein geeignetes Zielzeichen auf der Grundlage eines Standard-Kipphalter mit einer runden Zieltafel von 60 mm Durchmesser entwickelt, das mit vier teilenden Geraden in acht symmetrische, gelb und schwarz eingefärbte Teilbereiche separiert ist (Omidalizarandi et al. 2018). Das Zielzeichenzentrum wird durch den Schnittpunkt aller Geraden repräsentiert.

Die Bestimmung der polaren Messelemente (Horizontalrichtung (Hz), Vertikalwinkel (V) und Schrägstrecke (SD)) erfolgt programmgestützt mittels bildbasierter Zielzeichenerkennung (Omidalizarandi et al. 2018). Hierbei wird der

Geradenschnittpunkt im Zentrum des Zielzeichens detektiert und für die Nachführung der Teilkreise verwendet.

Ausgehend von im Messprogramm hinterlegten Anfahrwerten für die Tachymeter werden die Videozielzeichen der Überwachungspunkte mit der Fernrohrkamera aufgenommen. Hierbei wird bereits eine erste reflektorlose Entfernungsmessung durchgeführt, um die Kamera optimal zu fokussieren. Das aufgenommene Messbild, in Grauwerte konvertiert, wird auf dem Steuerrechner mit dem Line Segment Detektor (LSD)-Algorithmus analysiert, mit welchem benachbarte und parallelverlaufende Kanten separiert und zu zusammenhängenden Linien verbunden werden. Das relevante Zielzeichenzentrum wird wiederum aus dem Geradenschnitt aller detektierten Linien berechnet. Die detektierten Pixelkoordinaten des Zielzeichenzentrums liegen damit im Bildkoordinatensystem vor. Unter Nutzung der aus der Werkskalibrierung bekannten Kalibrierparameter ist eine Überführung in das Instrumentenkoordinatensystem möglich. Mit den so bestimmten Winkelinkrementen werden die Teilkreise nachgeführt. Daran schließt sich eine weitere berührungslose Entfernungsmessung an, in deren Rahmen die polaren Messgrößen bestimmt werden. Neben den Einflüssen des Instrumentenbaus auf die Kollokation der Messsysteme, insbesondere auf das Zusammenfallen der optischen Achse der Kamera und des Fernrohrs mit der Zielachse, spielt an dieser Stelle wiederum das Zeitschema der Messdatenerfassung eine Rolle: Korrekterweise muss mit den Teilkreisabgriffen bei der Bilderstellung gearbeitet werden, an die die genauen Korrekturwerte aus der bildbasierten Zielzeichenerkennung angebracht werden. Ein Teilkreisabgriff nach dem Nachführen des Instruments als Anzielung für die abschließende Streckenmessung ist mit den Einstellgenauigkeiten der Schrittmotoren als ggf. systematischer, weil gerichteter Fehler behaftet. Dieser Effekt tritt bei der herkömmlichen ATR, die als iterativ arbeitender Regelkreis ausgeprägt ist, nicht oder in sehr viel geringerem Maße auf. Eine Weiterentwicklung des Videotachymetrieverfahrens in Richtung einer iterativen Anwendung ist prinzipiell möglich, scheitert insbesondere bei externer Durchführung der Zielzeichenerkennung an der ausreichend schnellen Übertragung der Bilddaten für eine wiederholte Analyse. Mit den bei der praktischen Anwendung erreichten Übertragungsgeschwindigkeiten lassen sich keine ausreichend effektiven iterativen Nachstellregelkreise realisieren, die erreichten Genauigkeiten für die berechneten Ablagen im sub-mm-Bereich für die hier in Frage stehenden Zielweiten unter 100 m (Becker et al. 2020) bestätigen aber den hier beschriebenen Ansatz mit Anbringung der Ablagen aus der Bildmessung an die ursprünglichen Teilkreisabgriffe.

## 2.2 Tachymetrische Netzausgleichung und Epochenvergleich

Wegen der Aufnahmegerometrie – teilweise musste der Neuausbau des Schachts im Teufbetrieb von oben überwacht werden – ist ein Teil der Tachymeter bei der konkreten Überwachungsmaßnahme im Infrastrukturbereich Schacht Konrad 2 über Kopf installiert (Jarecki et al. 2018). Die Ausführung der Aufhängevorrichtung hat zur Folge, dass die Instrumente zum einen nicht hinreichend horizontiert werden können, und zum anderen der Einsatz des integrierten Flüssigkeitskompensators zur Überwachung und Ausgleichung der Stehachsneigung nicht möglich ist. Die Stehachse des Instrumentes kann daher nicht als parallel zur (lokalen) Lotrichtung angenommen werden. Die Stehachsschiefen und die Instrumentenverdrehung müssen daher bei der Modellbildung der gemeinsamen Auswertung mehrerer Stand- bzw. Hängepunkte berücksichtigt werden. Entsprechend der Darstellung (Lösler et al. 2018) wird hier, im Gegensatz zu klassischen Ansätzen der industriellen Messtechnik, die meist auf einen Bezug zum Schwerefeld verzichtet und zudem koordinatenbasiert arbeitet (und damit, wie oben beschrieben, das Tachymeter als integriertes Messsystem modelliert und dessen eigene Eigenschaft als MSS negiert bzw. im stochastischen Modell abbildet), ein Auswertekonzept auf der Basis der originären Beobachtungen verwendet, welches Stehachsrestneigungen des Instrumentes in-situ berücksichtigt. Durch die Integration des Konzeptes des allgemeinen Data-Snooping lassen sich etwaige Modellstörungen aufdecken. Unter Modellstörungen werden hierbei sowohl Abweichungen in den Beobachtungen verstanden, die beispielsweise aus Fehlmessungen resultieren, als auch Veränderungen in den als stabil angenommenen Referenzpunkten. Diese Modellbildung wird auch als integrierte hybride Netzausgleichung bezeichnet, da sie eine direkte Kombination von Messsystemen wie z. B. Nivellement, Tachymetrie oder GNSS streng ermöglicht (Jäger et al. 2017). Während in der integrierten Netzausgleichung die originären Beobachtungen zu bewerten sind, erfolgt die koordinatenbasierte Ausgleichung auf der Basis abgeleiteter Größen. Eine signifikante Modellstörung in einer Polarkomponente, z. B. der Schrägstrecke, führt im integrierten Ansatz zur direkten Lokalisierung und ermöglicht ein gezieltes Eingreifen beispielsweise den Ausschluss dieser Beobachtung von der weiteren Auswertung. Die Idee der integrierten hybriden Netzausgleichung mit erweiterter Modellbildung liefert gleichzeitig einen Ansatz zur Integration der beschriebenen Messsysteme zu einem gemeinsamen MSS zur Überwachung des geomechanischen Gebirgsverhaltens. Dass bei der Auswertung eine Lokalisierung von Störungen auf Messwertebene möglich wäre, also mit direktem Bezug zu oder sogar in ein beteiligtes Messsystem hinein, stellt für diese Anwendung einen klaren Pluspunkt des Ansatzes dar.

Bei der reinen Tachymetrie werden Schrägstrecke, Richtung und Zenitwinkel aufgestellt, weiter der Darstellung von Lösler et al. (2018) folgend, ergeben sich im lokalen astronomischen System

$$s_{ij} = \sqrt{\Delta v^2 + \Delta u^2 + \Delta w^2}, \quad (1)$$

$$t_{ij} = \text{atan}_2 \frac{\Delta v}{\Delta u} - o, \quad (2)$$

$$\nu_{ij} = \text{atan}_2 \frac{\sqrt{\Delta v^2 + \Delta u^2}}{\Delta w}, \quad (3)$$

für Schrägstrecke, Richtung und Zenitwinkel. Hierin ist  $o$  die Orientierungsunbekannte, die die Drehung um die  $z$ -Achse einer räumlichen Koordinatentransformation beschreibt, die noch nicht berücksichtigt ist, nachdem die unterschiedlichen Orientierungen der Stehachsen aufgrund von Lotabweichungen für Stand- bzw. Zielpunkt jeweils durch Rotationssequenzen abgebildet worden sind. Beide Rotationssequenzen beschreiben hierbei eine kombinierte Drehung um die  $x$ - und  $y$ -Achse

$$R = \begin{pmatrix} 1 & 0 & 0 \\ 0 & \cos \zeta_x & -\sin \zeta_x \\ 0 & \sin \zeta_x & \cos \zeta_x \end{pmatrix} \begin{pmatrix} \cos \zeta_y & 0 & \sin \zeta_y \\ 0 & 1 & 0 \\ -\sin \zeta_y & 0 & \cos \zeta_y \end{pmatrix}, \quad (4)$$

worin  $\zeta_x$  bzw.  $\zeta_y$  die zugehörigen Drehwinkel darstellen (z. B. Jäger et al. 2017).

Da die originären Beobachtungen als unabhängige Funktionen der unbekannten Parameter darstellbar sind, erfolgt die Netzausgleichung nach der Methode der kleinsten Verbesserungsquadratsumme im Gauß-Markov-Modell.

Beobachtungsgleichungen, die die Orientierung der eindimensional gerichteten Messelemente der Extensometer und Konvergenzstrecken berücksichtigen, lassen sich analog zur Schrägstrecke durchaus aufstellen. Bereits diese Erweiterung ermöglicht die Auswertung des Datenbestands für eine gemeinsame Messepochen. Die Epochenzuordnung, also die Lösung der Fragestellung der Zeitsynchronisation, muss allerdings vorliegen. Zudem zielen die Konvergenz- und Extensometermessungen als differentielle Messsysteme stärker auf die Bestimmung von Streckenänderungen, also Dehnungen. Diese können ebenfalls im Schritt des Epochenvergleichs modelliert werden.

Liegen von einem Überwachungsnetz, in dem keine Punktveränderungen stattgefunden haben, die Messungen  $\mathbf{l}_1$  und  $\mathbf{l}_2$  von zwei Epochen vor, so lautet das gemeinsame Ausgleichungsmodell

$$\begin{bmatrix} \mathbf{A}_{R,1} & \mathbf{A}_{Z,1} & 0 \\ \mathbf{A}_{R,2} & 0 & \mathbf{A}_{Z,2} \end{bmatrix} \begin{bmatrix} \hat{\mathbf{x}}_R \\ \hat{\mathbf{x}}_{Z,1} \\ \hat{\mathbf{x}}_{Z,2} \end{bmatrix} = \begin{bmatrix} \mathbf{l}_1 \\ \mathbf{l}_2 \end{bmatrix} + \begin{bmatrix} \mathbf{v}_1 \\ \mathbf{v}_2 \end{bmatrix}. \quad (5)$$

Hierin sind  $\mathbf{A}$  und  $\mathbf{x}$  so vorsortiert, dass epochenübergreifende Parameter wie z. B. Referenzpunkte am Anfang und epochenspezifische Parameter wie z. B. Orientierungsunbekannten der Richtungssätze, am Ende zu finden sind. Die Schätzung der Modellparameter, das Identifizieren von inkonsistenten Beobachtungen und die Stabilitätsanalyse der Referenzpunkte erfolgen somit geschlossen im selben Ausgleichungsmodell (vgl. Lösler et al. 2017).

Punkte, die a priori als instabil klassifiziert wurden, wie die Objektpunkte, liegen in Gl. (5) epochengetrennt in  $\mathbf{A}_z$  bzw.  $\mathbf{x}_z$  vor. Die resultierenden Verschiebungsvektoren dieser Punkte zwischen beiden Epochen ergeben sich somit direkt aus

$$\hat{\nabla} = \mathbf{F} \begin{bmatrix} \hat{\mathbf{x}}_{Z,1} \\ \hat{\mathbf{x}}_{Z,2} \end{bmatrix}, \quad (6)$$

mit der Koeffizientenmatrix  $\mathbf{F} = \begin{bmatrix} 0 & -\mathbf{I}_1 & 0 & \dots & 0 & \mathbf{I}_2 & 0 \end{bmatrix}$ , die aus Nullmatrizen besteht und lediglich an den Stellen der korrespondierenden Objektpunkte in der ersten bzw. zweiten Epoche mit Einheitsmatrizen besetzt ist. Durch Anwendung des allgemeinen Varianz-Kovarianz-Fortpflanzungsgesetzes ergibt sich die Kofaktormatrix  $\mathbf{Q}_{\hat{\nabla}\hat{\nabla}}$ . Durch einen Austausch von  $\mathbf{F}$  in Gl (6) können auch weitere Deformationsmuster wie beispielsweise Blockbewegungen oder Strains analysiert werden (vgl. Lösler et al. 2017, Lehmann und Lösler 2017).

### 3 Zusammenfassung und Ausblick

Bei der geotechnischen Überwachung von Auffahrungsarbeiten im Endlagerbergbau setzt die BGE verschiedene ortsgebundene Messsysteme in gemeinsamen Messlokalisationen ein. Dabei sind sowohl unterschiedlich geartete Sensoren zu Messsystemen kombiniert, deren Messergebnisse getrennt voneinander ausgewertet und analysiert werden können und die so jeweils ein Multisensorsystem bilden. Gleichzeitig werden im Falle der tachymetrischen Punktüberwachung in Netzen mit mehreren Instrumentenstandpunkten bereits mehrere solcher Messeinrichtungen als übergreifendes Multisensorsystem ausgewertet.

Der dabei gewählte Ansatz eignet sich grundsätzlich bereits zur Integration von weiteren Messeinrichtungen, hierzu muss die Modellbildung streng erweitert werden. Ebenso wäre eine gemeinsame Auswertung mit direkten Filtermethoden wie dem Kalman-Filter oder der Kollokation nach kleinsten Quadraten denkbar, die mit ihren Interpolationsschritten Ergebnisse an den geomechanisch relevanten „Stellen“ erzeugen könnten. Ebenso ist der Einsatz „lernender“ filterartiger Algorithmen wie künstlicher neuronaler Netze denkbar, wenn aus dem gesammelten Beobachtungsmaterial geeignete Trainingsdaten für die geomechanisch interessanten Effekte erzeugt werden können.

## Literatur

- Becker, A., Weißmann, R., Herklotz, F., Jarecki, F., Nagel, C., Paffenholz, J.-A. (2020): Untertägige Überwachung des geomechanischen Gebirgsverhaltens mittels bildbasierter Zielzeichendetektion. In: Wunderlich, T. (Hrsg.): Ingenieurvermessung '20: Beiträge zum 19. Internationalen Ingenieurvermessungskurs München, 2020. München.
- Ehrhart, M., Lienhart, W. (2016): Accurate Measurements with Image-Assisted Total Stations and Their Prerequisites. In: Journal of Surveying Engineering, Aug. 2016. DOI: [10.1061/\(ASCE\)SU.1943-5428.0000208](https://doi.org/10.1061/(ASCE)SU.1943-5428.0000208).
- Jäger, R., Gorokhova, L., Messmer, E. (2017): Modell- und Sensorintegration zum integrierten 3D-Geomonitoring in moderner Datenkommunikationsstruktur mit Anwendung auf den Stuttgarter Fernsehturm. In: Lienhart, W. (Hrsg.): Ingenieurvermessung 17: Beiträge zum 18. Internationalen Ingenieurvermessungskurs Graz, Berlin/Offenbach, 239–252.
- Jäger, R., Müller, T., Saler, H., Schwäble, R. (2005): Klassische und robuste Ausgleichsverfahren – Ein Leitfaden für Ausbildung und Praxis von Geodäten und Geoinformatikern. 1. Auflage, Heidelberg.
- Jarecki, F., Eschelbach, C., Lösler, M., Busse, V. (2018): Tachymetrische Verformungsbeobachtung bei Teufarbeiten: Instrumentierung, Automatisierung und Auswertung. In: 19. Geokinematischer Tag, Schriftenreihe des Instituts für Markscheidewesen und Geodäsie, Technische Universität Bergakademie Freiberg. Freiberg.
- Lehmann, R., Lösler, M. (2017): Congruence analysis of geodetic networks – hypothesis tests versus model selection by information criteria. In: Journal of Applied Geodesy, 11, 4, 271–283. DOI: [10.1515/jag-2016-0049](https://doi.org/10.1515/jag-2016-0049).
- Lösler, M., Eschelbach, C., Haas, R. (2017): Kongruenzanalyse auf der Basis originärer Beobachtungen. In: zfv – Zeitschrift für Geodäsie, Geoinformation und Landmanagement, Heft 1/2017, 142. Jg., 41–52. DOI: [10.12902/zfv-0147-2016](https://doi.org/10.12902/zfv-0147-2016).
- Lösler, M., Eschelbach, C., Jarecki, F. (2018): Auswerte- und Analysestrategie für automatisierte untertägige Überwachungsmessungen. In: 19. Geokinematischer Tag, Schriftenreihe des Instituts für Markscheidewesen und Geodäsie, Technische Universität Bergakademie Freiberg. Freiberg.

Omidalizarandi, M., Paffenholz, J.-A., Neumann, I. (2018): Automatic and accurate passive target centroid detection for applications in engineering geodesy. In: Survey Review, 51, 1–16.

Paffenholz, J.-A., Becker, A., Omidalizarandi, M., Busse, V. (2018): Untertägige Verformungsüberwachung diskreter Ankerköpfe mittels Videotachymetrie. In: Busch, W. (Hrsg.): GeoMonitoring 2018. Clausthal-Zellerfeld.

### Kontakt

Dr.-Ing. Focke Jarecki  
Bundesgesellschaft für Endlagerung mbH (BGE)  
TEK-GI.1 – Markscheidewesen, Abt. Geoinformation  
Eschenstraße 55, 31224 Peine  
[focke.jarecki@bge.de](mailto:focke.jarecki@bge.de)

# Geosensornetzwerke mit IoT-Technologie und KI-Auswertungen zur Überwachung großer Böschungssysteme

Erik Heinz

## 1 Einleitung

Der Strombedarf in Deutschland wird zurzeit durch einen Mix aus unterschiedlichen Energiequellen gedeckt. So entfielen im Jahr 2021 von der im Inland produzierten und ins Netz eingespeisten Strommenge rund 42 % auf erneuerbare Energieträger, während die verbleibenden 58 % aus konventioneller Erzeugung stammten (Statistisches Bundesamt 2022). Aktuell werden etwa 12 % des deutschen Strombedarfs durch die Braunkohle aus dem rheinischen Revier gedeckt, in dem die RWE Power AG die Tagebaue Garzweiler, Hambach und Inden betreibt. Durch den Ausbau der grünen Erzeugungskapazitäten im RWE Konzern und den vereinbarten Kohleausstieg befindet sich das gesamte Revier derzeit in einer großen Umstrukturierung. So werden bis zum Jahr 2038 die Kohlegewinnung in den Tagebauen sowie die daran angegliederten Kraftwerke und Veredelungsbetriebe sukzessive stillgelegt.

Obwohl das System Braunkohle schrumpft, ist es weiterhin erforderlich, den laufenden Tagebaubetrieb sicher durchzuführen. Um dies zu gewährleisten, ist die RWE Power AG im rheinischen Revier mit vielfältigen Aufgaben im Bereich Geomonitoring betraut. Im Zusammenspiel verschiedener Fachdisziplinen nehmen dabei das Markscheidewesen und die Geodäsie eine wichtige Rolle ein. So besteht eine zentrale Aufgabe darin, die Standsicherheit und Verformung der Randböschungssysteme in den Tagebauen zu überwachen (BVOBr 2001). Darüber hinaus fallen Aufgaben bei der Analyse des Verformungsverhaltens im Gewinnungs- und Kippenbereich an. Mit Ausdehnungen von mehreren Kilometern und Höhenunterschieden von z. T. mehreren hundert Metern sind die Überwachungsbereiche sehr umfangreich (siehe Abb. 1 links).

Auch nach Beendigung der Kohlegewinnung ist im Rahmen der Wiedernutzbarmachung der Tagebaue, aus denen für die Folgenutzung große Seen entstehen sollen, ein Geomonitoring der Böschungsbereiche notwendig (siehe Abb. 1 rechts). Bereits heute liefert das bestehende Geomonitoring wichtige Entscheidungsgrundlagen für die Planung und Herstellung der Seeböschungen sowie für die Errichtung von baulichen Anlagen in diesen Bereichen. Bisherige

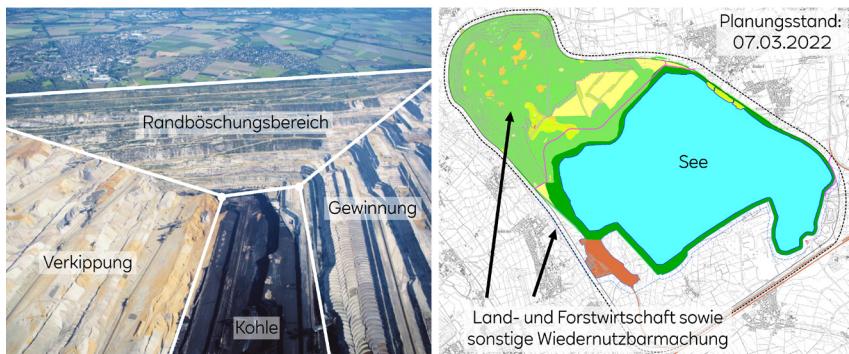


Abb. 1: Beispiel Tagebau Hambach: Der Randböschungsbereich wird im laufenden Betrieb hinsichtlich seiner Standsicherheit und seines Verformungsverhaltens dauerhaft überwacht (links). Auch zukünftig ist für die Wiedernutzbarmachung in Form eines Sees ein Geomonitoring erforderlich (rechts).

Erfahrungen werden zudem verwendet, um neue bzw. angepasste Monitoringkonzepte für die spätere Überwachung der Seeböschungen während der Seebefüllung zu entwickeln. Dem Markscheidewesen und der Geodäsie bei der RWE Power AG fallen also auch zukünftig bedeutende Aufgaben zu.

Dieser Beitrag konzentriert sich im Folgenden auf die Überwachung der Standsicherheit und Verformung der Randböschungssysteme in den Tagebauen des rheinischen Reviers im laufenden Betrieb (siehe auch Guder und Dahmen 2016, Eling 2020 oder Heinz et al. 2021). Hierzu kommen Tachymetersysteme zum Einsatz, die mithilfe elektrooptischer Distanzmessungen zu einem dichten Netz an Beobachtungspunkten eine zeitlich und räumlich hochauflöste Überwachung der Böschungen ermöglichen (siehe Abschnitt 2.1). Zur genaueren Erfassung der meteorologischen Einflüsse auf die Distanzmessungen und besseren Interpretation der Messdaten wird zurzeit am Aufbau eines Netzes von zusätzlichen Meteorologiesensoren gearbeitet, die über die IoT-Übertrag 技术 LoRaWAN (Internet of Things, Long Range Wide Area Network) in das Monitoring integriert werden sollen (siehe Abschnitt 2.2). Als weitere Informationsquellen stehen zudem räumlich verteilte Pegelmessstationen in unterschiedlichen Horizonten zur Verfügung. Darüber hinaus finden Angaben über die Geologie sowie Einsätze von Groß- und Hilfsgeräten Eingang in das Geomonitoring (siehe Abschnitt 2.3). Zusammengefasst ergibt sich für die Böschungsüberwachung durch die kombinierte Auswertung verschiedener Messgrößen und Informationsquellen ein Multisensorsystem.

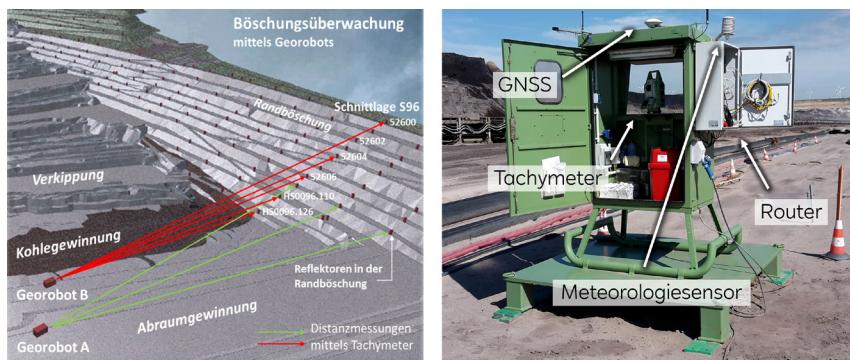
Prinzipiell ermöglicht es der zur Verfügung stehende Datenschatz, tiefergehende Einblicke in das Bewegungsverhalten der Böschungen zu erhalten, das Verformungsverhalten zu beschreiben und zu interpretieren, d.h. Bewegungen

auf mögliche Ursachen zurückzuführen, und so die Qualität des Geomonitorings weiter zu steigern. Um aus der großen Datenmenge die wesentlichen Informationen herauszulösen und auch in kürzester Zeit zu fundierten Aussagen zu gelangen, ist eine Digitalisierung und Automatisierung der Datenanalyse zunehmend alternativlos. Neben klassischen Methoden aus Statistik, Ausgleichsrechnung oder Zeitreihenanalyse ist zur automatisierten Interpretation und Erkennung von Zusammenhängen innerhalb von Daten in den letzten Jahren der zunehmende Einsatz künstlicher Intelligenz (KI) zu beobachten. Ein Schwerpunkt des Beitrags liegt in diesem Kontext auf der Anwendung von LSTM-Netzen (Long Short Term Memory) zur Vorhersage und Analyse von Zeitreihen (siehe Abschnitt 3). Im schrumpfenden System Braunkohle ist im Spannungsfeld zwischen bergbehördlichen Vorgaben, betrieblichen Ansprüchen, erhöhtem Kostendruck und Fachkräftemangel eine Steigerung der Effizienz zwingend erforderlich. Digitalisierung und Automatisierung sind somit auch aus wirtschaftlicher Sicht geboten. Basierend auf den Ausführungen schließt der Beitrag mit einem Fazit und einem Ausblick (siehe Abschnitt 4).

## 2 Überwachung großer Böschungssysteme

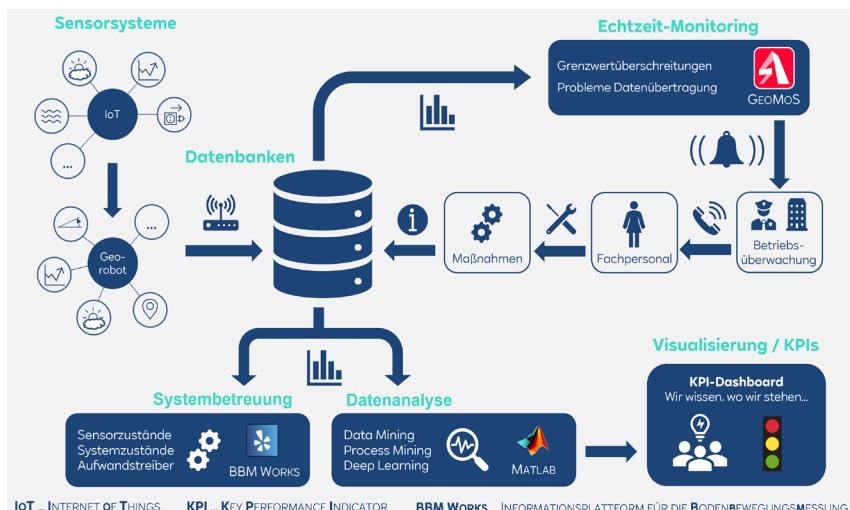
### 2.1 Erfassung von Bodenbewegungen mithilfe von Georobots

Eine wichtige Aufgabe des Geomonitorings der RWE Power AG besteht darin, die Standsicherheit und Verformung der Randböschungen in den Tagebauen zu überwachen. Das Monitoring erfolgt mithilfe von automatisiert messenden Georobotsystemen (siehe Abb. 2). Die Kernkomponente besteht aus einem servogesteuerten Tachymeter, welches reflektorgestützt elektrooptische Distanzmessungen zu Messpunkten durchführt, die in Falllinie der Böschung profilartig angeordnet sind. Die Profile orientieren sich an den geologischen Schnittlagen der gebirgsmechanischen Standsicherheitsuntersuchungen. Über den Schnitt der gemessenen Distanz mit der Profillinie wird die so genannte Längsverschiebung berechnet, die als eindimensionale Zielgröße die horizontale Punktverschiebung gegenüber der Urmessung anzeigt. Zur Überwachung der Stabilität des Standpunktes sind die Georobots mit einem GNSS-Sensor (Global Navigation Satellite System) ausgerüstet, welcher eine hochgenaue basislinienbasierte Positionsbestimmung ermöglicht. Die meteorologische Korrektur der Distanzmessungen erfolgt über Wettersensoren am Standpunkt. In den Tagebauen Hambach, Garzweiler und Inden sind zurzeit zwölf Georobots im Einsatz, die acht Böschungssysteme überwachen und dabei mehr als 650 Messpunkte beobachten. Auf diese Weise werden täglich über 40.000 Einzelpunktmessungen produziert.



**Abb. 2:** Messprinzip und Aufbau eines Georobots zur Überwachung der Randböschungsbereiche in den Tagebauen. In der Regel werden für die Böschungen jeweils zwei redundante Systeme eingesetzt (hier: Georobot A und B).

Die Messdaten werden mittels Mobilfunk an Datenbanken weitergeleitet und stehen anschließend für die Auswertung zur Verfügung (siehe Abb. 3). Für die automatisierte Echtzeitüberwachung von Grenzwertüberschreitungen an den Messpunkten wird die Software Leica GeoMoS eingesetzt. Werden bestimmte Grenzwerte bzgl. der Bewegung überschritten, löst die GeoMoS Software automatisch einen Alarm aus, der an einen 24/7-Bereitschaftsdienst weitergeleitet wird, der ggf. notwendige Maßnahmen ergreift. Die Datenbanken sind auch



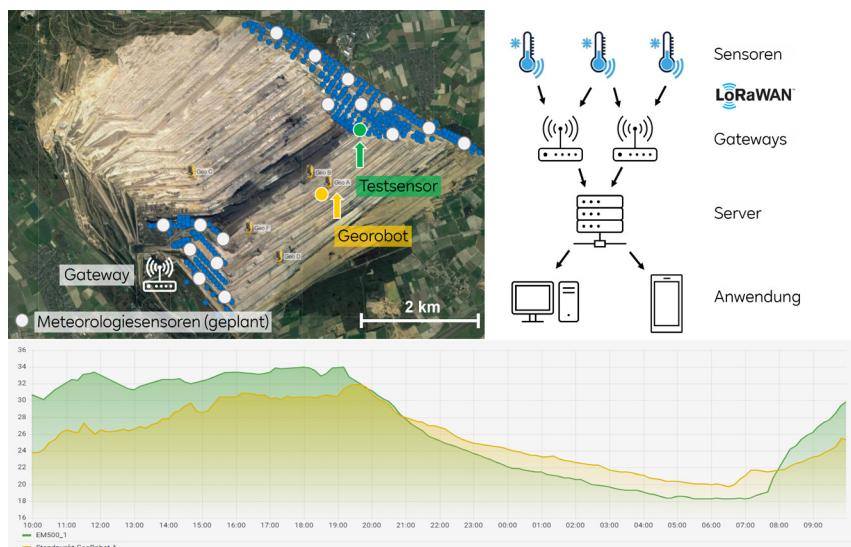
**Abb. 3:** Datenfluss und Auswertungen beim Geomonitoring der Böschungssysteme in den Tagebauen der RWE Power AG

Grundlage für die Systembetreuung. So werden die Daten zur Visualisierung der aktuellen Sensor- und Systemzustände sowie zur Identifikation von Aufwands treibern in Form von Dashboards genutzt. Außerdem lassen sich mithilfe der Daten tiefergehende Analysen durchführen (siehe Abschnitt 3).

## 2.2 Aufbau weiterer Sensornetzwerke mit IoT-Technologie

Um die Qualität des Geomonitorings weiter zu steigern, wird zurzeit am Aufbau ergänzender Sensornetzwerke gearbeitet. Im Fokus steht dabei ein Netz von zusätzlichen Wetterstationen, um die meteorologischen Einflüsse auf die Distanzmessungen noch besser korrigieren zu können und die Interpretation der Messdaten zu erleichtern. Zurzeit ist im Tagebau Hambach ein Testsensor installiert, dessen Daten bereits für die Auswertung zur Verfügung stehen (siehe Abb. 4). Eine beispielhafte Auswertung mithilfe eines KI-basierten LSTM-Netzes zeigt den Mehrwert, den diese Daten versprechen (siehe Abschnitt 3).

Bei der Umsetzung sollen Sensoren aus dem Bereich IoT zum Einsatz kommen, die ihre Daten regelmäßig über ein LoRaWAN-Netz übertragen und in den Datenstrom der Georobots einspeisen. Mittels LoRaWAN können kleine Datenpakete per Funk über Entfernen von mehreren Kilometern besonders



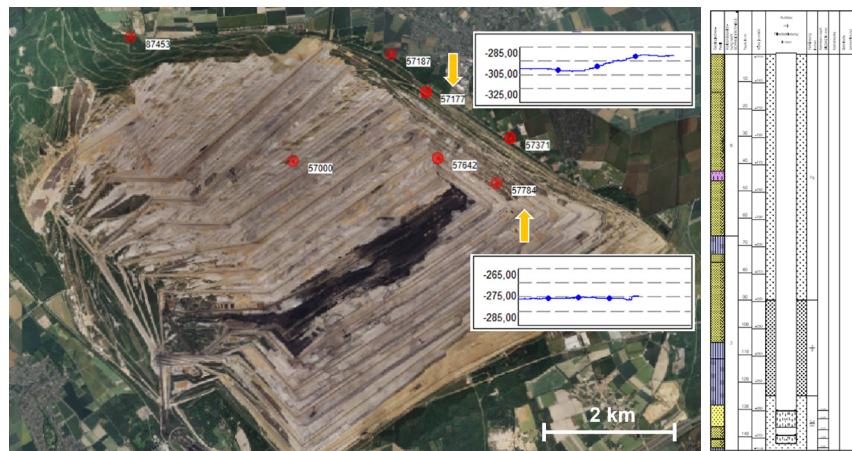
**Abb. 4:** Geplanter Aufbau eines Netzes von zusätzlichen Meteorologiesensoren mithilfe der IoT-Technologie LoRaWAN (oben). Vergleich der Temperaturwerte am Standpunkt des Georobots und an einer Teststation (unten).

energiesparend übertragen werden. Der Aufbau des LoRaWAN-Netzes ist mit vergleichsweise geringem Aufwand möglich (Seuß et al. 2022). Prinzipiell soll das Sensornetzwerk skalierbar bleiben, sodass die Sensoren je nach Bedarf beliebig ausgetauscht und erweitert werden können. So sind zum Beispiel zukünftig auch GNSS-Sensoren oder Beschleunigungssensoren zur Detektion von Bewegungen und Vibrationen denkbar.

## 2.3 Pegelmessstationen und weitere Informationsquellen

Als weitere Informationsquelle für das Geomonitoring wurden für den Tagebau Hambach Pegelmessstellen in das Geomonitoring integriert. Die Pegelmessstellen sind räumlich verteilt und decken unterschiedliche Horizonte in unterschiedlichen Teufen ab (siehe Abb. 5). Der Wasserstand innerhalb der Böschung kann einen Einfluss auf das Verformungsverhalten der Böschung haben. Insofern lassen sich mögliche Zusammenhänge zwischen den Pegelständen und den Messungen der Georobots herstellen. Auf diese Weise kann ein Verformungsverhalten nicht nur geometrisch beschrieben, sondern auch interpretiert werden.

Weitere Informationen, die bei der Bewertung der Beobachtungsdaten relevant sein können, sind Angaben zur Geologie oder beispielsweise mechanische Veränderungen im Umfeld der Beobachtungspunkte, z. B. durch die Entnahme oder den Eintrag von Massen durch Schaufelradbagger oder Absetzer.



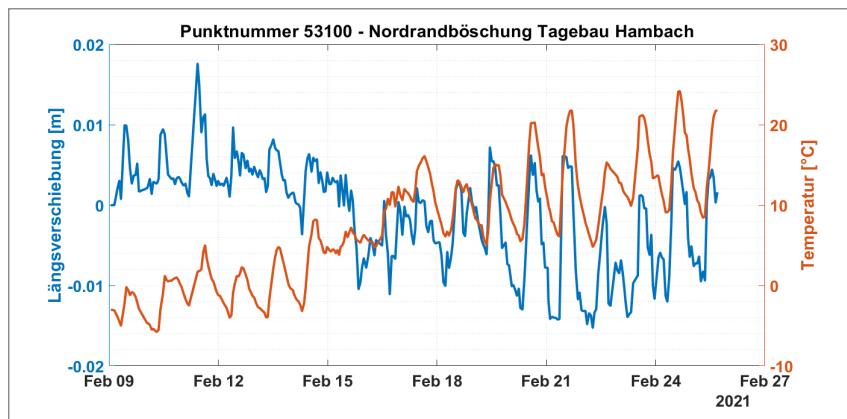
**Abb. 5:** Übersicht von ausgewählten, in das Geomonitoring integrierten Pegelmessstationen im Tagebau Hambach

### 3 Auswertemethoden

Der in Abschnitt 2 beschriebene Datenschatz lässt sich nutzen, um das Verformungsverhalten der Böschungssysteme detailliert zu erfassen, zu verstehen und ggf. auch zu prognostizieren. Dazu bedarf es jedoch der richtigen Vorgehensweise bei der Auswertung der Daten. In der Vergangenheit erfolgte die tiefergehende Analyse und Interpretation in Bezug auf Anomalien und erhöhte Bewegungsraten in der Regel auf manuelle Weise. Durch langjährige Erfahrung und unter Einbeziehung verschiedener Einflussgrößen kann das Fachpersonal eine fundierte Bewertung der jeweiligen Situation vornehmen und daraus die richtigen Schlüsse ziehen. Vor dem Hintergrund der heute anfallenden Massendaten stößt diese Vorgehensweise jedoch zunehmend an ihre Grenzen. Ferner unterliegt die manuelle Datenanalyse einer subjektiven Bewertung, der Informationen verborgen bleiben können, insbesondere dann, wenn es sich wie im vorliegenden Fall um ein komplexes Zusammenspiel unterschiedlicher Einflussgrößen handelt. Erst durch den Einsatz spezieller Werkzeuge aus dem Bereich der Statistik, Ausgleichsrechnung und Zeitreihenanalyse (Heunecke et al. 2013) lassen sich die in den Daten enthaltenen Informationen schnell, objektiv und möglichst vollständig extrahieren. Das Portfolio erprobter Auswertetechniken wird seit einigen Jahren durch Methoden aus dem Bereich KI ergänzt, die vollkommen neue Möglichkeiten bieten. Das Geomonitoring der RWE Power AG setzt diesbezüglich auf eine Mischung aus klassischen und innovativen Methodiken, die in der selbstentwickelten, Matlab-basierten Auswertesoftware BBManalyse gebündelt werden (BBM = Bodenbewegungsmessung). Für einen Einblick in bereits implementierte, klassische Auswertestrategien sei auf vorangegangene Publikationen verwiesen (siehe Eling 2020 und Heinz et al. 2021). Im Folgenden wird auf die neuesten Entwicklungen im Bereich KI eingegangen.

Die bisherigen Verfahrensweisen zur Überwachung von Bewegungen in den Tagebauböschungen basieren darauf, die Messwerte in Hinblick auf Grenzwertüberschreitungen bzw. ein kontinuierliches Bewegungsverhalten zu überprüfen (siehe Eling 2020 und Heinz et al. 2021). Limitierend daran ist, dass die Ursachen bzw. Einflussgrößen einer Bewegung nicht automatisch berücksichtigt werden. Ob bei einer Grenzwertüberschreitung nur eine Messabweichung oder tatsächlich eine Bewegung vorliegt, wird in der Regel erst durch den geschulten Blick des Fachpersonals – häufig unter Einbeziehung weiterer Einflussgrößen – beantwortet.

Das Beispiel aus Abb. 6, welches die bereits um meteorologische Einflüsse korrigierte Längsverschiebung eines Messpunktes der gemessenen Temperatur am Georobot-Standpunkt gegenüberstellt, verdeutlicht dies. In der Auswertung lassen sich die meteorologischen Einflüsse auf die Distanzmessung über die bekannten Modelle korrigieren (siehe z. B. Joeckel et al. 2008). In Abb. 6 erkennt



**Abb. 6:** Aufgrund der nicht vollständig kompensierten meteorologischen Einflüsse auf die Distanzmessungen weist der Punkt scheinbare Bewegungen auf, die bei einer einfachen Grenzwertbetrachtung zu Fehlalarmen führen können.

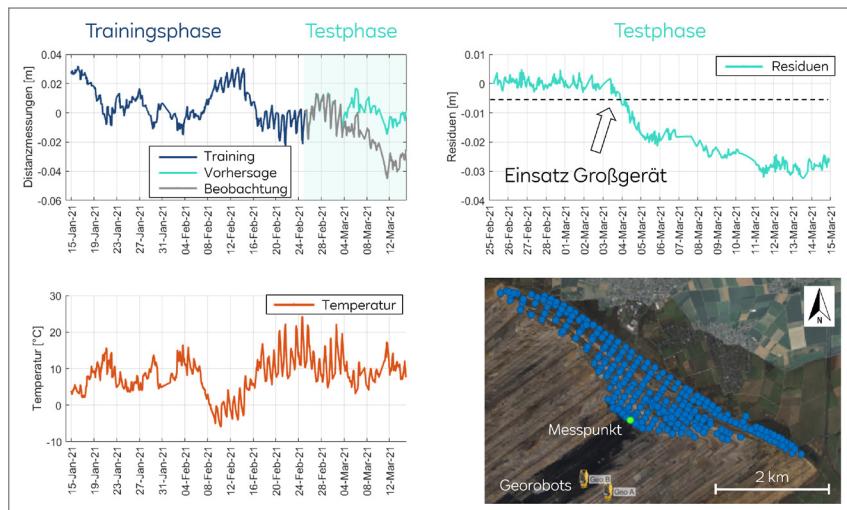
man allerdings, dass die Modelle bei großen Distanz- und Höhenunterschieden und alleiniger Bestimmung der meteorologischen Parameter am Standpunkt limitiert sind (siehe auch Friedli et al. 2019). Das geschulte Fachpersonal erkennt beim Blick auf Abb. 6 schnell, dass die täglichen Schwankungen der Längsverschiebung auf nicht kompensierte meteorologische Einflüsse zurückzuführen sind. Solche Effekte führen jedoch häufig zu Fehlalarmen, erhöhtem Aufwand und einer erschwerteten Dateninterpretation bei der manuellen Sichtung. Das Ziel der Auswertung sollte es daher sein, die Erfahrungen des Fachpersonals unmittelbar in die Auswertung zu integrieren. Einen guten Ansatzpunkt bietet hier die moderne KI, da die ihr zugrundeliegenden Konzepte einer Maschine die Erfahrungen eines Menschen beibringen können.

Bei der RWE Power AG werden in diesem Kontext so genannte LSTM-Netze (Long-Short-Term-Memory) erprobt, die sich gut dazu eignen, um in Zeitreihen Anomalien von erwartbarem Verhalten zu trennen (Malhotra et al. 2015). Die Idee besteht darin, das übliche Verhalten eines Punktes unter Berücksichtigung der Eingangsgrößen zu lernen und wiederkehrende Muster in den Zeitreihen als unkritisch bzw. erwartbar zu erkennen. Den LSTM-Netzen werden dazu Trainingsdaten übergeben, die das übliche Verhalten eines Punktes widerspiegeln. Die Trainingsdaten umfassen Zeitreihen der Ausgangsgrößen (z. B. Distanzmessungen) und dazu synchronisierte Zeitreihen der Eingangsgrößen (z. B. Temperatur, Luftdruck und Pegelmessungen). Anhand der Trainingsdaten lernt das LSTM-Netz zu prädizieren, welcher Wert für die Ausgangsgröße basierend auf den aktuellen Eingangsgrößen und den Erfahrungen der Vergangenheit als nächstes zu erwarten ist. Dieser prädizierte Wert wird dann mit der

tatsächlichen Messung verglichen. Stimmen die beiden Werte überein, kann das Verhalten des Punktes als erwartbar angesehen werden. Im Falle von signifikanten Abweichungen zwischen Prädiktion und Beobachtung ist das Verhalten des Punktes anhand der bisherigen Erfahrungen und den Eingangsgrößen nicht erklärbare. Dann ist anzunehmen, dass sich der Punkt aufgrund unberücksichtigter Einflüsse tatsächlich bewegt oder es bisher nicht berücksichtigte systematische Effekte gibt, die die Messung beeinflussen. In jedem Fall muss in einem zweiten Schritt eine Bewertung der Abweichung erfolgen.

Diesbezüglich zeigt Abb. 7 exemplarisch das Ergebnis für einen Messpunkt, für den über ein LSTM-Netz mit den Eingangsgrößen Temperatur, Luftdruck und Geometrie der Messanordnung eine Vorhersage für die Distanzmessung durchgeführt wurde. Es sei angemerkt, dass als Ausgangsgröße die meteorologisch unkorrigierten Distanzmessungen genutzt wurden. Als Grundlage dienten Zeitreihen mit einer Länge von zwei Monaten, die in 70 % Trainingsdaten und 30 % Testdaten aufgeteilt wurden. Im Zuge der Testphase führt das LSTM-Netz auf Basis der Eingangsgrößen eine Vorhersage für die Distanzmessungen durch und gleicht diese mit den tatsächlichen Messungen ab.

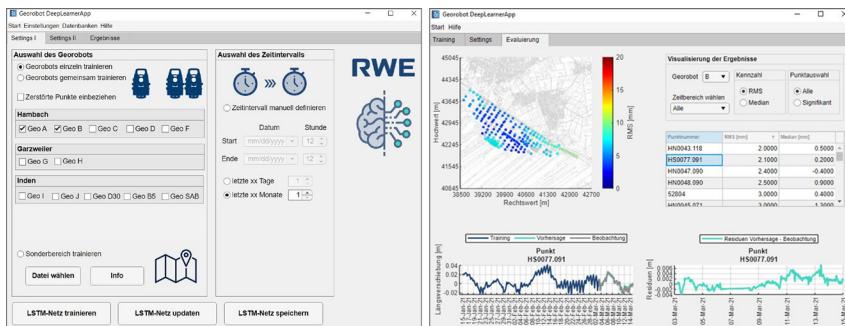
In Abb. 7 ist zu erkennen, dass die Vorhersage innerhalb der ersten Tage der Testphase bis auf wenige Millimeter mit der Messung übereinstimmt (bis etwa zum 03.03.2021). Danach weicht die Vorhersage allerdings von der Messung ab. Die Abweichung fällt zeitlich mit einem Großgeräteeinsatz zusammen, bei



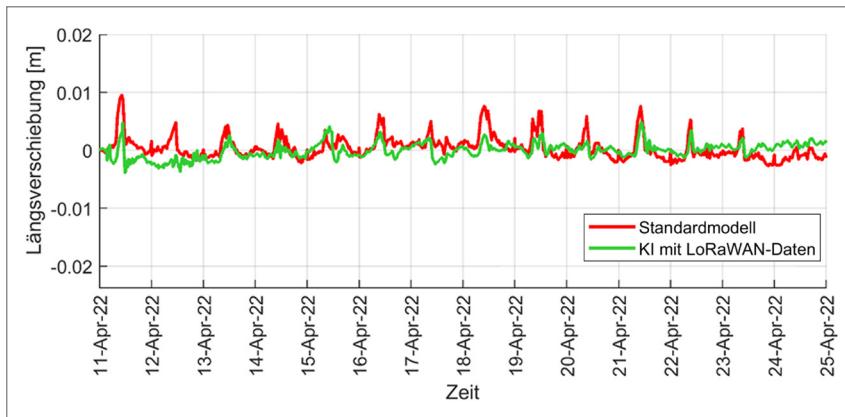
**Abb. 7:** Vorhersage von Distanzmessungen anhand von Temperatur, Luftdruck und Geometrie für einen Punkt, der infolge eines Großgeräteeinsatzes in der Nähe des Punktes zwischenzeitlich eine leichte Bewegung aufweist.

dem ein Schaufelradbagger in unmittelbarer Nähe zum Messpunkt Massen entnommen hat. Infolgedessen wurde eine leichte Punktbewegung festgestellt, die nach dem Großgeräteeinsatz erwartungsgemäß wieder abklingt (siehe Abb. 7, Zeitreihe oben rechts). Auf Basis der Eingangsgrößen Temperatur, Luftdruck und Geometrie wäre eigentlich der grün prognostizierte Verlauf zu erwarten gewesen (siehe Abb. 7, Zeitreihe oben links). Die Abweichung zwischen Messung und Vorhersage zeigt hier eine Punktbewegung an, die über die Residuen frühzeitig detektiert und mit den Auswirkungen des Großgeräteeinsatzes begründet werden kann. Die gezeigten Resultate stellen Tests dar und sind nicht uneingeschränkt verallgemeinerbar. Zukünftig muss analysiert werden, wie leistungsstark die LSTM-Netze sind und welche Vorhersagequalität erreichbar ist.

Momentan wird am Aufbau einer Software gearbeitet, die es Anwendern ermöglichen soll, Vorhersagen für ganze Böschungssysteme durchzuführen. Der erste Entwurf der Benutzeroberfläche ist in Abb. 8 visualisiert. Die Anwendung befindet sich aktuell noch in der Entwicklungsphase und wird bisher nur z. T. im Tagesgeschäft und parallel zum konventionellen Vorgehen eingesetzt. Die in Abschnitt 2 beschriebenen zusätzlichen Eingangsgrößen, wie z. B. die Meteorologiedaten aus dem LoRaWAN-Netz oder die Pegelmessungen, werden von vorneherein in die Software integriert. Beispielhaft wird in Abb. 9 der Mehrwert der zusätzlichen Wetterdaten in Kombination mit der KI-basierten Auswertung illustriert. Rot dargestellt ist die berechnete Längsverschiebung unter Anwendung der meteorologischen Standardmodelle. Grün dargestellt ist eine KI-basierte Auswertung unter zusätzlicher Verwendung der LoRaWAN-Daten. An vielen Stellen ist eine Glättung der Zeitreihe zu erkennen. Diese Glättung funktioniert jedoch nicht immer. An einigen Stellen ist sogar eine – wenn auch geringfügige – Verschlechterung zu erkennen. Zukünftig gilt es zu analysieren,



**Abb. 8:** Benutzeroberfläche der selbstentwickelten Software BBManalyse zur KI-basierten Auswertung der Daten des Geomonitorings mittels LSTM-Netzen. Links: Einstellungsmöglichkeiten durch den Anwender. Rechts: Darstellung der errechneten Abweichungen zwischen Prädiktion und Messung.



**Abb. 9:** Glättung der Zeitreihe eines Messpunktes durch Nutzung von zusätzlichen Wetterdaten aus dem LoRaWAN-Netzwerk innerhalb einer KI-basierten Auswertung in einem LSTM-Netz

wie die Ergebnisse für diese Fälle verbessert werden können. Insgesamt ist festzuhalten, dass die angestrebte Praxisreife noch nicht erreicht ist.

## 4 Fazit und Ausblick

In diesem Beitrag wurden aktuelle Entwicklungen im Bereich des Geomonitorings großer Böschungssysteme bei der RWE Power AG vorgestellt. Die Ausführungen weisen darauf hin, dass die Nutzung neuartiger Werkzeuge wie KI und IoT einen Mehrwert für das Geomonitoring bietet. Allerdings ist anzumerken, dass die genannten Technologien nicht als Allheilmittel zu verstehen sind. Dies zeigt sich unter anderem darin, dass die KI-basierten Ansätze derzeit noch nicht immer zum gewünschten Ergebnis führen und auch Verschlechterungen im Vergleich zu klassischen Herangehensweisen auftreten können. Insofern findet aktuell ein Prozess statt, in dem wir lernen, diese innovativen Techniken für unsere Zwecke einzusetzen. In Hinblick auf die Zukunft ist vor dem Hintergrund zunehmend anfallender Massendaten eine weitere Digitalisierung und Automatisierung der Auswerteverfahren – unter anderem durch Nutzung von Technologien aus den Bereichen KI und IoT – aus Sicht des Autors der richtige Weg. Bezogen auf die RWE Power AG wird mit Blick auf die einleitenden Darstellungen in Abschnitt 1 die Überwachung großer Böschungsbereiche auch nach Beendigung des Bergbaus im Kontext der Wiedernutzbarmachung der Tagebaue eine Aufgabe bleiben. Die Nutzung neuer, innovativer Methoden wird auch dabei von Vorteil sein.

## Literatur

- BVOBr (2001): Bergverordnung für Braunkohlenbergwerke (BVOBr). [http://esb.bezreg-arnsberg.nrw.de/a\\_1/a\\_1\\_015/a\\_1\\_015\\_002/index.html](http://esb.bezreg-arnsberg.nrw.de/a_1/a_1_015/a_1_015_002/index.html), letzter Zugriff 07/2022.
- Eling, C. (2020): Automatisiertes Deformationsmonitoring sensibler Objekte im rheinischen Revier: Ein Überblick in aktuelle Herausforderungen, verwendete Sensorik sowie implementierte Auswerte- und Analyseprozesse. In: Markscheidewesen 127(1), 19–23.
- Friedli, E., Presl, R., Wieser, A. (2019): Influence of atmospheric refraction on terrestrial laser scanning at long range. In: 4th Joint International Symposium on Deformation Monitoring (JISDM), 15–17 May 2019, Athens, Greece.
- Guder, W., Dahmen, D. (2016): Böschungsüberwachung im Rheinischen Braunkohlenrevier – Betriebliche Umsetzung bergbehördlicher Vorgaben. In: Niemeier, W., Riedel, B. (Hrsg.): Tagungsband GeoMonitoring 2016, 3.–4. März 2016, Braunschweig, Deutschland, 183–192.
- Heinz, E., Eling, C., Kittlaus, J. (2021): Digitalisierung des Geomonitorings im Markscheidewesen. In: Tagungsband Umwelt, Energie und Rohstoffe 2021 & 21. Geokinetischer Tag, 5.–7. Mai 2021, Freiberg, Deutschland, 35–52. (Tagung online durchgeführt).
- Heunecke, O., Kuhlmann, H., Welsch, W., Eichhorn, A., Neuner, H. (2013): Auswertung geodätischer Überwachungsmessungen. In: Möser, M., Müller, G., Schlemmer, H. (Hrsg.): Handbuch Ingenieurgeodäsie. 2., neu bearbeitete und erweiterte Auflage, Wichmann, Heidelberg.
- Joeckel, R., Stober, M., Huep, W. (2008): Elektronische Entfernungs- und Richtungsmessung und ihre Integration in aktuelle Positionierungsverfahren. 5., neu bearbeitete und erweiterte Auflage, Wichmann, Heidelberg.
- Malhotra, P., Vig, L., Shroff, G., Agarwal, P. (2015): Long Short Term Memory Networks for Anomaly Detection in Time Series. In: European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning, 22–24 April 2015, Bruges, Belgium, 89–94.
- Seuß, R., Lucas, C., Seifert, M., Weber, M., Baier, C., Eckhardt, J., Becker, A. (2022): Echtzeit-GIS – Echt jetzt? In: zfv – Zeitschrift für Geodäsie, Geoinformation und Landmanagement, Heft 3/2022, 147. Jg., DVW-Nachrichten, N-46/N-47.
- Statistisches Bundesamt (2022): Im Inland produzierte und ins Netz eingespeiste Strommenge. [www.destatis.de/DE/Presse/Pressemitteilungen/2022/03/PD22\\_116\\_43312.html](http://www.destatis.de/DE/Presse/Pressemitteilungen/2022/03/PD22_116_43312.html), letzter Zugriff 07/2022.

## Kontakt

Dr.-Ing. Erik Heinz  
RWE Power AG, Abteilung Monitoring & Analysen  
Zum Gut Bohlendorf, 50126 Bergheim  
[erik.heinz@rwe.com](mailto:erik.heinz@rwe.com)

# Vorarbeiten zur Entwicklung eines Gleisfehlerdetektionssystems mit Regelzügen und Low-Cost-Sensorik

Otto Lerke | Sebastian Bahamon-Blanco | Martin Metzner |  
Ullrich Martin | Volker Schiewer

## 1 Einleitung

Bei diesem Beitrag handelt es sich um einen technischen Bericht über die Vorarbeiten zu einem Gleisfehlerdetektionssystem, das auf Regelzügen unter Nutzung von Low-Cost-Sensorik zum Einsatz kommen soll. Das übergeordnete Ziel der Untersuchung ist die spätere Detektion und Lokalisierung von Unregelmäßigkeiten einer Gleistrasse, die aufgrund von Unstetigkeiten auf der Schiene oder bei Änderungen der Steifigkeit des Untergrundes vorkommen.

Aktuell werden zur Überwachung des Gleiszustands vorrangig speziell ausgerüstete Messzüge eingesetzt. Solche Diagnosesysteme sind z. B. RAILaB (Allweil 2014) oder LIMEZ (Wirth 2008). Das RAILab-System besteht aus multifunktional ausgerüsteten Fahrzeugen, die Fahrwegmessungen durchführen. Die Aufgaben des RAILab-Systems sind Geometriemessungen, Schienenprüfungen, Oberleitungsfunktionsprüfungen, fahrtechnische Prüfungen, Erfassung des Schienenvorschleißes sowie Lichtraumprofilmessungen (Allweil 2014). Dabei kommen für die Bestimmung der relevanten Messgrößen unterschiedliche Messverfahren, wie Lasersensoren, Ultraschallsensoren, Wirbelstromprüfungen, Kamera- und Videotechnik für optische Prüfungen sowie dynamische Kräftemessungen am Fahrzeug und Schienenoberflächenmessungen zum Einsatz. Die sensorische Ausstattung beinhaltet ein Videomesssystem, einen 2D-Fächerscanner, einen 2D-Rotationsscanner, ein Odometer, eine Inertiale Messeinheit (IMU) und einem Sensor für das globale Positionierungssystem (GNSS). Die Ortung wird mit den Daten des integrierten Odometers und der IMU in Verbindung mit einem GNSS-Empfänger durchgeführt (Allweil 2014). Der in Wirth (2008) beschriebene Messzug LIMEZ III wurde für die Erfassung und Lokalisierung von Lichtraumengstellen konzipiert. Dabei tastet ein Profillaserscanner die Umgebung ab. Zur Ergänzung der Profilmessung ist der Zug mit einem Videomesssystem für nachträgliche Messungen im Stereomodell und zusätzlichen Farbkameras für die Dokumentation ausgestattet. Ein Schienenprofilscanner ergänzt das Messsystem. Für die Lokalisierung und Trajektorienbestimmung sind

ein GNSS-System sowie ein INS installiert. In der Nachbearbeitung können so Positionsgenauigkeiten von 0,1 m erreicht werden (Wirth 2008).

Der Einsatz solcher Gleismesszüge ist jedoch sehr kostenintensiv und beeinträchtigt den Regelbetrieb. Ein weiterer Nachteil ist, dass nur sehr wenige Messzüge existieren, so dass deren Disposition zeitlichen Beschränkungen unterliegt. Abhilfe können portable Systeme schaffen, wie das Siemens-System (Siemens 2018). Diese Lösung sieht vor, das Messsystem auf Regelzügen zu installieren. Jedoch ist dabei ein Eingriff in die Zugtechnik notwendig, um z. B. Odometer anzubringen. Die bahneigene DB Netz AG greift ein Konzept auf, bei dem die Sensorik aus zwei GPS, einer IMU sowie einem Beschleunigungsmesser besteht. Im Gegensatz zu den zuvor vorgestellten Systemen ist ein Eingriff in die Zugtechnik bei diesem Konzept nicht erforderlich (Bahamon und Martin 2020). Das Fraunhofer Institut für Physikalische Messtechnik (IPM) entwickelt unter dem Begriff „Predictive Measurement“ optische Systeme zur Erfassung von diversen Gleistrassenobjekten und -parametern für den Regelbetrieb (IPM 2020). Diese ermöglichen z. B. neben der Messung von Lichtraumprofilen und der Erfassung von Fahrdrahtabnutzungen oder Tunnelzuständen auch die Detektion der Gleisgeometrie. Die Erfassung der relativen Gleisgeometrie sowie des Gleiszustandes erfolgt mit einem, speziell für diese Anwendung entwickelten, Laserscanner (Rail Track Scanner).

Eine ganz wesentliche Herausforderung aller erwähnten Konzepte besteht in der Lokalisierung bzw. der Zuordnung der für den Gleiszustand relevanten erfassten Messsignale zu einem Ort. Bei den oben gelisteten Systemen handelt es sich um so genannte Multisensorsysteme. Multisensorsysteme kommen bereits in unterschiedlichsten Anwendungen, wie z. B. beim Mobile Mapping oder beim autonomen Fahren zum Einsatz. Für die Ortung werden dabei in der Regel INS/GNSS-Kombinationen angewendet (Jäger und Zwiener 2016), die in Verbindung mit diversen Fusionsalgorithmen (Mirabadi et al. 1996) eine Positionsbestimmung erlauben. Einige Fusionsalgorithmen nutzen zusätzlich Informationen aus digitalen Karten, um durch das Aufstellen von Bedingungen Verbesserungen bei der Positionsbestimmung zu erreichen (Böhringer 2008, Li et al. 2009).

Neben der Erfassung der Messdaten aus den beschriebenen Systemen, ist die Datenauswertung der entscheidende Baustein um Aussagen über den Gleiszustand treffen zu können. Unterschiedliche Forschungsansätze existieren bereits, die verschiedene Arten von Gleisfehlern in einem Fahrweg-Fahrzeugmodell im Maßstab 1:87 erfolgreich erkennen (Bahamon und Martin 2020, Rapp und Martin 2018).

Wie bereits zu Beginn geschrieben, beschreibt dieser Beitrag die Vorarbeiten zur Entwicklung eines Systems zur kontinuierlichen Gleisüberwachung und Erkennung von Gleisfehlern sowie den entwickelten sensorischen Messaufbau für einen realen, im Regelbetrieb fahrenden, Personenzug. Die Methodik zur

Gleisfehlerdetektion nach Bahamon und Martin (2020) und Rapp und Martin (2018) soll dabei auf ein reales Szenario übertragen werden. Der für diese Untersuchung verwendete Zug ist ein 40 Tonnen schweres Stadler Regio-Shuttle RS1. Dieser Zug erreicht auf der exemplarischen Messstrecke eine Höchstgeschwindigkeit von 70 km/h. Als sensorische Ausstattung kommen analoge Low-Cost-Beschleunigungsmesser zur Generierung relevanter Gleisinformationen und ein Multiband-Low-Cost-GNSS-Empfänger für die Positionsbestimmung zum Einsatz. Die Beschleunigungsmesser sind zulassungsfrei am Drehgestell montiert. Der GNSS-Empfänger ist auf Grund betriebstechnischer Beschränkungen im Fahrgastrauum, in der Nähe eines Fensters, angebracht. Die Daten werden mit Hilfe eines Echtzeitcomputers erfasst und synchronisiert. Der Vorteil der eingesetzte Low-Cost-Sensorik ist, dass diese preiswert und uneingeschränkt verfügbar ist. Ein Eingriff in die Zugtechnik ist für die Installation nicht notwendig.

## 2 Grundlagen der Vorgehensweise

Verschiedene Arten von Gleisfehlern können in einem Fahrweg-Fahrzeugmodell im Labor im Maßstab 1:87 (siehe Abb. 1) erfolgreich erkannt werden.

Rapp et al. 2019



**Abb. 1:**  
Fahrweg-Fahr-  
zeugmodell

Das Fahrweg-Fahrzeugmodell ist ein 4,04 m langes Oval, in dem verschiedene Arten von Fehlern eingerichtet sind (vgl. Abb. 2). Die Messfahrten beginnen am markierten Startpunkt und werden im Uhrzeigersinn durchgeführt. Nach einer Durchfahrt wird das Fahrzeugmodell angehalten.

Jede Unstetigkeit bzw. jedes Fehlerelement erzeugt ein bestimmtes Vertikalbeschleunigungsmuster mit einer einhergehenden, charakteristischen Änderung der Wellenlänge, wie aus der von Esveld (1986) vorgeschlagenen Klassifizierung von Gleisfehlern hervorgeht. Im Gegensatz dazu bleibt die Wellenlänge auf Schienenabschnitten ohne Fehler unverändert.

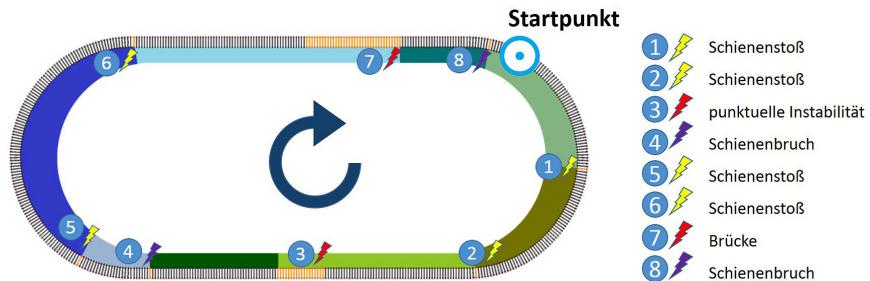


Abb. 2: Diskontinuitäten und Gleisfahler des Fahrweg-Fahrzeugmodells

Rapp et al. (2019) stellten eine Methode zur Erkennung von Gleisfehlern des Fahrweg-Fahrzeugmodells mittels Kreuzkorrelation vor. Die entsprechenden Referenzmuster, dargestellt in Abb. 3, wurden am Fahrweg-Fahrzeugmodell generiert, indem mehrere Beschleunigungssignale gemittelt wurden. Die einzelnen zu korrelierenden Beschleunigungssignale werden generiert und gemessen, wenn das Fahrzeug des Fahrweg-Fahrzeugmodells den jeweiligen Gleisfehler überquert.

Die Größe des Korrelationskoeffizienten gibt Aufschluss darüber, ob ein spezifischer Gleisfehler im Fahrzeug-Fahrwegmodell einem entsprechenden Muster zugeordnet werden kann. Der Korrelationskoeffizient beschreibt dabei die Ähnlichkeit zwischen der gemessenen Beschleunigung und dem generierten Referenzmuster. Je größer der Korrelationskoeffizient, desto größer ist die Übereinstimmung zwischen der gemessenen Vertikalbeschleunigung und dem

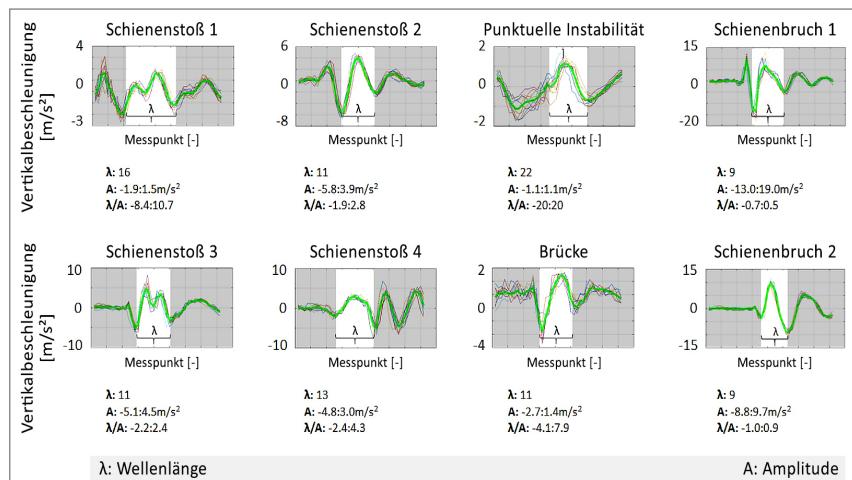


Abb. 3: Gleisfehler-Referenzmuster des Fahrweg-Fahrzeugmodells

Referenzmuster (Rapp et al. 2019). In zurückliegenden Untersuchungen konnte gezeigt werden, dass der eine Diskontinuität charakterisierende Steifigkeitswechsel im Fahrweg-Fahrzeugmodell identifiziert werden kann.

Das im vorhergehenden Abschnitt vorgestellte Verfahren soll nun als Ausgangsmethode zur Identifizierung einiger realer Bahnanlagen dienen. Dabei wird auf das gleiche Prinzip zurückgegriffen, wonach die vertikalen Bewegungen des realen Zuges entlang der Strecke durch Bahnanlagen wie z. B. Brücken, Straßenkreuzungen oder Weichen beeinflusst werden. Genau wie im Fahrweg-Fahrzeugmodell sollen die Kreuzkorrelationskoeffizienten zwischen einem Referenzmuster und dem während der Messfahrten generierten Vertikalbeschleunigungssignal ermittelt werden. Das Referenzmuster einer beliebigen Diskontinuität wurde, ähnlich Abschnitt 3.2.1, mit verschiedenen Überfahrten und anschließender Mittelung erzeugt (Abb. 4).

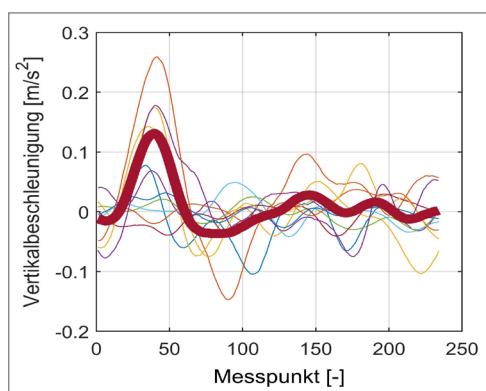


Abb. 4: Reales Referenzmuster einer Diskontinuität

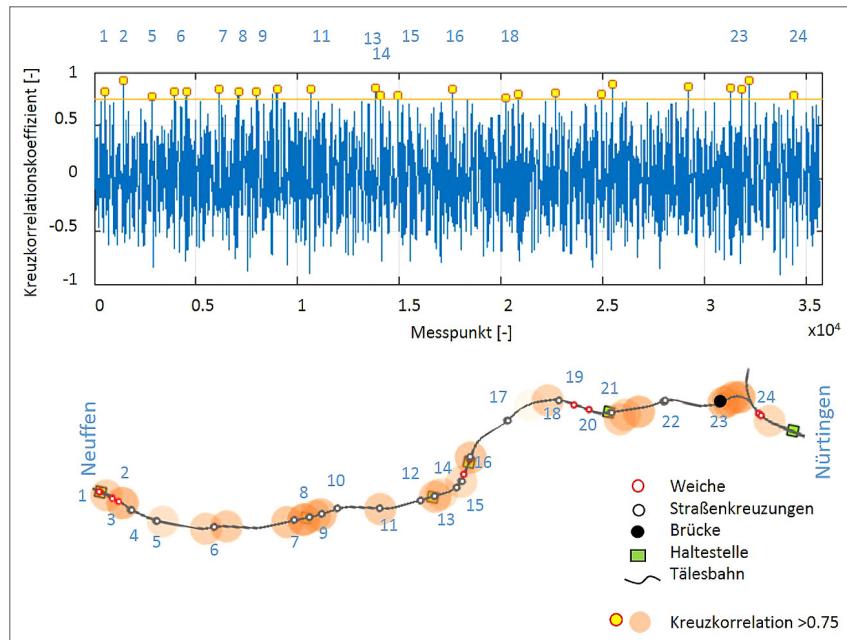
Dieses eine Referenzmuster wird nun dazu verwendet, unterschiedliche Diskontinuitäten zu detektieren. Anhand des Musters erkennt man in diesem Fall jedoch nur grundsätzlich Diskontinuitäten, ohne ein Trassenelement zu identifizieren. Das bedeutet, dass die Methode bisher Fehler oder Streckenelemente zwar erkennen, jedoch nicht klassifizieren kann.

Dieses eine Referenzmuster wird nun dazu verwendet, unterschiedliche Diskontinuitäten zu detektieren. Anhand des Musters erkennt man in diesem Fall jedoch nur grundsätzlich Diskontinuitäten, ohne ein Trassenelement zu identifizieren. Das bedeutet, dass die Methode bisher Fehler oder Streckenelemente zwar erkennen, jedoch nicht klassifizieren kann.

### 3 Ergebnisse

Die Messungen wurden in Zusammenarbeit mit dem Betreiber in einem Real-labor, einem Zug der Württembergischen Eisenbahn-Gesellschaft mbH (WEG), auf der Strecke „Tälesbahn“ zwischen den Städten Neuffen und Nürtingen durchgeführt. Der größte Teil der untersuchten Strecke ist im Eigentum der WEG (ca. 9,6 km), ein kleiner Abschnitt (ca. 206 m) ist im Eigentum der DB Netz AG. Die Strecke ist somit insgesamt ca. 9,81 km lang und hat eine Höhendifferenz von ca. 100 m.

Zur Bestimmung der Detektionsschwelle, ab der die Kreuzkorrelationskoeffizienten Diskontinuitäten auf der Strecke identifizieren, wurden quantitative Analysen durchgeführt, anhand derer der Schwellwert festgelegt werden konnte.



**Abb. 5:** Erkennung von Diskontinuitäten entlang der Tälesbahn durch vertikale Beschleunigungen, die von einem einachsigen Beschleunigungsmesser gemessen wurden.

Durch die Kenntnis der Positionen der Diskontinuitäten auf der Strecke konnte jeder Diskontinuität der entsprechend ermittelte Koeffizientenwert zugeordnet werden. Dies erfolgte für elf durchgeführte Fahrten. Abb. 5 zeigt ein Beispiel für die Erkennung der Diskontinuitäten auf der Route. In der Abbildung werden oben die Kreuzkorrelationskoeffizienten gezeigt. Insgesamt wurden für jede Diskontinuität über elf Fahrten gerechnet. Die Koeffizienten weisen unterschiedliche Werte auf. Letztendlich wird nur ein Schwellwert bereitgestellt, mit dem diese Diskontinuitäten identifiziert werden können. Aus der Menge der Durchschnittswerte wurde 0,74 als Schwellwert festgelegt. Alle Werte größer oder gleich 0,74 wurden in Abb. 5 in orange hervorgehoben und repräsentieren die Detektionen. Die gelbe Linie stellt dabei den Schwellwert der Koeffizienten dar, ab dem davon auszugehen ist, dass eine Diskontinuität vorliegt. Abb. 5 zeigt unten eine grobe Skizze der Trasse mit ihren jeweiligen Weichen, Straßenkreuzungen und Brücken. Die orangefarbenen Kreise zeigen die Werte des Kreuzkorrelationskoeffizienten an, die über dem definierten Schwellwert liegen. Mit dieser Methode konnten 16 der 24 analysierten Diskontinuitäten erkannt werden.

Für die Ortung mittels GNSS lag die Verfügbarkeit bei der Befahrung der Strecke bei 100 %. Die erreichte Genauigkeit der GNSS-Messungen relativ zur

Streckenkilometrierungskarte, dargestellt über die errechneten Abstände zwischen den Wegmarken der Karte und den zu den Wegmarken zugeordneten, gemessenen GNSS-Positionen, liegen zwischen maximal 4,65 m und minimal 0,04 m. Der Mittelwert liegt bei 1,71 m, der RMS bei 1,10 m. Werte unter 0,5 m haben nur einen Anteil von ca. 12 % an der Gesamtstrecke. Bei der Betrachtung der vom Hersteller angegebenen Genauigkeit von 2,5 m ist festzustellen, dass diese auf ca. 74 % der Strecke eingehalten worden ist. Werte über 4 m haben einen Anteil von ca. 6 % an der Gesamtstrecke. Hier handelt es sich um Gebiete mit streckenangrenzender Vegetation und Bahnhöfen, so dass Abschattungen offensichtlich eine Rolle spielen. Stellt man diesen Wert den Anforderungen von 0,5 m Ortungsgenauigkeit gegenüber, so sind diese auf 88 % der Strecke nicht eingehalten worden. Die Einflüsse der Antennenposition im Fahrgastraum auf die Ortungsgenauigkeit sind dabei grundsätzlich nicht bekannt.

## 4 Fazit und Ausblick

Der Beitrag präsentiert ein erstes Konzept zum Aufbau eines Gleisfehlerdetektionssystems, das zukünftig auf Regelzügen unter Nutzung von Low-Cost-Sensorik zum Einsatz kommen soll. Das Konzept sieht vor, Methoden aus den Themengebieten Signalverarbeitung und Ortung so zu kombinieren, dass dem Anwender ein möglichst effizientes Detektions- und Ortungsverfahren zur Verfügung gestellt werden kann.

### 4.1 Erkennung von Diskontinuitäten und Gleisfehlern

Es wurde gezeigt, dass im momentanen Ausbauzustand das System noch nicht in der Lage ist, vollständige Detektionen von Streckenelementen der Gleisinfrastruktur oder Gleisfehler zu gewährleisten. Ebenfalls ist eine eindeutige Klassifikation der detektierten Diskontinuitäten nicht möglich. Es konnte jedoch gezeigt werden, dass einige ausgewählte und zuvor lokalisierte Streckenelemente detektiert werden konnten. Die Erkennungsrate liegt dabei bei ca. 67 %.

Die Anwendung der Kreuzkorrelationsmethode ist grundsätzlich, sowohl für die Messungen am Fahrweg-Fahrzeugmodell wie auch für die Regelzugmessungen in der Realität, möglich. Jedoch bleibt die Erzeugung von eindeutigen Referenzmustern und die Festlegung von eindeutigen Detektionsschwellen zum jetzigen Zeitpunkt ein offener, noch zu lösender Aspekt.

Für das zukünftige Detektions- und Lokalisierungssystem von Gleisfehlern sind alternative Methoden wie z. B. Wavelet-Analysen oder Algorithmen der künstlichen Intelligenz zu wählen. Diese Methoden konzentrieren sich nicht auf

die Berechnung von Korrelationskoeffizienten, sondern auf die Zuweisung einer Gleisfehlerkategorie zu jedem Messpunkt. Für die Anwendung der alternativen Verfahren sollen in Zukunft automatische Klassifikationen der Diskontinuitäten auf Rohsignalebene, in Kombination mit einer präzisen Positionsbestimmung, möglich werden. Des Weiteren ist es beabsichtigt, eine Datenbank zu erstellen, die unterschiedlichen Arten von Gleisfehlern sowie typische Infrastrukturpunkte (Steifigkeitswechsel an Brücken und Bahnübergängen, fahrdynamische Unstetigkeitsstellen an Weichenherzstücken und am Weichenanfang usw.) enthält. Auf dieser Grundlage kann ein dynamisches Datensystem entwickelt werden, das Veränderung des Gleiszustands im zeitlichen Verlauf erkennbar macht. Eine Erweiterung der Schadensmuster sowie eine Verbesserung der Auswertemethode um die Betrachtung des Frequenzbereichs und Ansätze der neuronalen Netze befinden sich in der Entwicklung.

## 4.2 Ortung und Map-Matching

Im Bereich der Ortung konnten die Vorgaben an die Positionsgenauigkeit von 0,5 m relativ zur Streckenkilometrierungskarte über große Teile von ca. 88 % der Strecke nicht eingehalten werden. Im Hinblick darauf ist eine Steigerung der Ortungsgenauigkeit von größter Notwendigkeit. Dafür, aber auch zur erweiterten Nutzung des Systems auf alternativen Strecken, ist der Einsatz eines Multisensorsystems geplant. Die Erweiterung des jetzt vorhandenen GNSS-basierten Messsystems um optische Odometrie (Korrelationsgeschwindigkeitsmesser) und Gyroskope kann in Gebieten mit niedriger GNSS-Genauigkeit helfen, die Ortungsgenauigkeit zu verbessern. Darüber hinaus können GNSS-Störungen oder Ausfällen durch eine Koppelnavigationslösung überbrückt werden. Solche Bereiche können z.B. hohe Böschungen, Tunneldurchfahrten und Brückenunterfahrten sein. Mit dem Einsatz eines Multisensorsystems ist auch die Konzeption eines entsprechenden Datenfusionsalgorithmus, wie z.B. Erweitertes Kalman-Filter (EKF) oder Unscented Kalman-Filter (UKF) unter Nutzung digitaler Streckenkarten sowie der Berücksichtigung von Kartenelementen, wie z.B. Haltestellen als Bedingungen geplant. Zuletzt ist die Nutzung des globalen GNSS pps-Signals zur zeitlichen Synchronisation aller Sensoren erstrebenswert.

## Danksagung

Die Autoren danken der Württembergischen Eisenbahn-Gesellschaft mbH (WEG) für die gegebene Möglichkeit, Messungen am realen Zug durchzuführen sowie den WEG Mitarbeitern für ihre Unterstützung bei der Installation der Sensoren und der Durchführung der Messfahrten.

## Anmerkung

Der vollständige Beitrag wurde 2021 in der zfv – Zeitschrift für Geodäsie, Geoinformation und Landmanagement, Jahrgang 146, Heft 3, veröffentlicht und ist unter DOI [10.12902/zfv-0339-2021](https://doi.org/10.12902/zfv-0339-2021) oder [www.geodaeis.info](http://www.geodaeis.info) frei verfügbar. Dieser erweiterte Abstract folgt dem Originalbeitrag zum Teil Wort-für-Wort.

## Literatur des vollständigen Beitrags

- Allweil, M. (2014): Fahrwegmessung bei der DB Netz AG. Vortrag im Rahmen der Veranstaltung DMG Bezirksgruppe Mitte, 06.03.2014, Berlin. [http://www.dmg-berlin.info/page/downloads/vortrag\\_allweil.pdf](http://www.dmg-berlin.info/page/downloads/vortrag_allweil.pdf), letzter Zugriff 07/2020.
- Bahamon, S., Martin, U. (2020): Erkennung von punktuellen Unstetigkeitsstellen am Fahrweg am Beispiel eines Fahrzeug-Fahrwegmodells – Ansatz mit Methodik der künstlichen Intelligenz (EPIB 1.1). Beitrag Abschlussworkshop EPIB, Februar 2020 in Stuttgart.
- Bahamon, S., Rapp, S., Rupp, C., Liu, J., Martin, U. (2019): Recognition of track defects through measured acceleration P1 & P2. Proceedings 7th International Conference of EACEF (European Asian Civil Engineering Forum), 30.09.–02.10.2019 in Stuttgart.
- BMJV-Bundesministeriums der Justiz und für Verbraucherschutz (1967): Eisenbahn-Bau- und Betriebsordnung (EBO), Zuletzt geändert durch Art. 2 V v. 5.4.2019 I 479. [www.gesetze-im-internet.de/ebo/EBO.pdf](http://www.gesetze-im-internet.de/ebo/EBO.pdf), letzter Zugriff 07/2020.
- Böhringer, F. (2008): Gleisselektive Ortung von Schienenfahrzeugen mit bordautonomer Sensorik. Schriffreie Institut für Mess- und Regelungstechnik Universität Karlsruhe (TH). ISBN: 978-3-86644-196-5.
- Catania, P., Comparetti, A., Febo, P., Morello, G., Orlando, S., Roma, E., Vallone, M. (2020): Positioning Accuracy Comparison of GNSS Receivers Used for Mapping and Guidance of Agricultural Machines. In: Agronomy 2020, 10, 924. DOI: [10.3390/agronomy10070924](https://doi.org/10.3390/agronomy10070924).
- Eisseller, B., Teubner, A., Zucker, P. (2005): Indoor-GPS: Ist der Satellitenempfang in Gebäuden möglich? In: zfv – Zeitschrift für Geodäsie, Geoinformation und Landmanagement, Heft 4/2005, 130. Jg., 226–234.
- Esveld, C. (1986.): Measuring and rectifying rail roughness and bad welds. 3rd Int. Heavy Haul Railways Conf., Paper BIB-52, Vancouver.
- Heßelbarth, A. (2009): GNSS-Auswertung mittels Precise Point Positioning (PPP). In: zfv – Zeitschrift für Geodäsie, Geoinformation und Landmanagement, Heft 5/2009, 134. Jg., 278–286.
- IPM (2020): „Predictive Maintenance“: Optische Überwachung von Infrastruktur und Zügen. Augensichere Laserscanner und ultraschnelle Kamerasysteme für die effiziente Erfassung im Regelbetrieb. [www.ipm.fraunhofer.de/de/gf/objekterfassung-laserscanning/anw/bahnmesstechnik.html](http://www.ipm.fraunhofer.de/de/gf/objekterfassung-laserscanning/anw/bahnmesstechnik.html), letzter Zugriff 07/2020.
- Jäger, R., Zwiener, J. (2016): Flugdynamik, Multisensor-Navigation und Steuerung skalierbarer Out-/Indoor-Multicopter UAV. In: DVW e. V. (Hrsg.): UAV 2016 – Vermessung mit unbemannten Flugsystemen). DVW-Schriftenreihe, Band 82, Wißner-Verlag, Augsburg, 53–81.
- Li, K., Tan, H.-S., Hedrick, J. K. (2009): Map-Aided GPS/INS Localization Using a Low-Order Constrained Unscented Kalman Filter. Joint 48th IEEE Conference on Decision and Control and 28th Chinese Control Conference Shanghai, P.R. China, December, 2009.

- Menius, R., Matthews, V. (2017): Bahnbau und Bahninfrastruktur: Ein Leitfaden zu bahnbezogenen Infrastrukturthemen. 9. Auflage, Springer Verlag. ISBN 978-3-658-17177-3.
- Mirabadi, A., Mort, N., Schmid, F. (1996): Application of Sensor Fusion to Railway. Proceedings of the 1996 IEEE/SICE/RSJ International Conference on Multisensor Fusion and Integration for Intelligent Systems. December 8–11, 1996, Washington, D.C., U.S.A.
- National Instruments (2019): NI LabVIEW for CompactRIO Developer's Guide. [www.ni.com/de-de/shop/compactrio/compactrio-developers-guide.html](http://www.ni.com/de-de/shop/compactrio/compactrio-developers-guide.html), letzter Zugriff 10/2019.
- National Instruments (2020): Getting Started with CompactRIO and LabVIEW. [http://pignol.univ-tln.fr/DUT\\_GEI/E&R\\_API\\_S4/Ressources/GettingStarted-Compact-Rio.pdf](http://pignol.univ-tln.fr/DUT_GEI/E&R_API_S4/Ressources/GettingStarted-Compact-Rio.pdf), letzter Zugriff 07/2020.
- PCB Piezotronics (2019): Datasheet PCB Synotech Accelerometer. [www.pcb.com/products?m=M603C01](http://www.pcb.com/products?m=M603C01), letzter Zugriff 08/2020.
- Raghavender Rao, Y., Prathapani, N., Nagabhooshanam, E. (2014): Application of normalized cross correlation to image registration. In: International Journal of Research in Engineering and Technology. Vol. 03. 12–16. DOI: [10.15623/ijret.2014.0317003](https://doi.org/10.15623/ijret.2014.0317003).
- Rapp, S., Martin, U. (2018): Erkennung von punktuellen Unstetigkeitsstellen am Fahrweg am Beispiel eines Fahrzeug-Fahrwegmodells – Ansatz zur Modellbildung (EPIB 1.1). Beitrag Auftakt-workshop EPIB, März 2018 in München.
- Rapp, S., Martin, U., Strähle, M., Scheffbuch, M. (2019): Track-vehicle scale model for evaluating local track defects detection methods. Transportation Geotechnics (2019), Volume 19. ISSN: 2214-3912.
- Siemens (2018): Railigent – die Lösung für intelligentes Asset-Management. [www.mobility.siemens.com/global/de/portfolio/schiene/services/digital-services/railigent.html](http://www.mobility.siemens.com/global/de/portfolio/schiene/services/digital-services/railigent.html), letzter Zugriff 07/2020.
- Ublox (2020): LEA-6 u-blox 6 GPS Modules Data Sheet. [www.u-blox.com/sites/default/files/products/documents/LEA-6\\_DataSheet\\_%28UBX-14044797%29.pdf](http://www.u-blox.com/sites/default/files/products/documents/LEA-6_DataSheet_%28UBX-14044797%29.pdf), letzter Zugriff 07/2020.
- Vossloh (2020): Immer bereit für die Strecke: Asset Management, Schieneninspektion, Data Processing, Training und Consulting. [www.vossloh.com/01\\_product\\_finder/VRS/Asset-Management/VOS\\_AM\\_DE-Final.pdf](http://www.vossloh.com/01_product_finder/VRS/Asset-Management/VOS_AM_DE-Final.pdf), letzter Zugriff 07/2020.
- Wanninger, L. (2011): Qualitätssicherung bei GNSS-Diensten. In: zfv – Zeitschrift für Geodäsie, Geoinformation und Landmanagement, Heft 1/2011, 136. Jg., 8–17.
- Wirth, H. (2008): Der neue Lichtraummesszug LIMEZ III der Deutschen Bahn AG. In: zfv – Zeitschrift für Geodäsie, Geoinformation und Landmanagement, Heft 3/2008, 133. Jg., 180–186.

## Kontakt

Volker Schwieger | Otto Lerke | Martin Metzner  
Universität Stuttgart, Institut für Ingenieurgeodäsie  
Geschwister-Scholl-Straße 14D, 70174 Stuttgart  
[volker.schwieger@iigs.uni-stuttgart.de](mailto:volker.schwieger@iigs.uni-stuttgart.de)

Ullrich Martin | Sebastian Bahamon-Blanco  
Universität Stuttgart, Institut für Eisenbahn- und Verkehrswesen  
Pfaffenwaldring 7, 70569 Stuttgart  
[ullrich.martin@iev.uni-stuttgart.de](mailto:ullrich.martin@iev.uni-stuttgart.de)

# Einsatz kommerzieller, mobiler Laser-scanning-Systeme für die Überwachung der Verkehrsinfrastruktur: Herausforderungen, Lösungsansätze und Praxisbeispiele

Slaven Kalenjuk | Werner Lienhart

## 1 Einleitung

Der Errichtung und Erhaltung der Verkehrsinfrastruktur für den Güter- und Personenverkehr ist sowohl aus wirtschaftlicher als auch aus sozialer Sicht hohe Bedeutung beizumessen. In einem Bericht der Weltbank (The World Bank 2021) wird betont, dass „Investitionen in eine verlässliche und resiliente Infrastruktur notwendig sind, um wirtschaftlichen Wohlstand und einen hohen Lebensstandard zu gewährleisten“.

In der Praxis stellen steigende Verkehrslasten und Extremwetterereignisse die Bauwerkserhalter vor große Herausforderungen. Eine Vielzahl an Infrastrukturobjekten (z. B. Brücken, Tunnel, Stützbauwerke, etc.) muss gemäß nationaler Richtlinien laufend überwacht, geprüft und inspiziert werden (in Österreich z. B. RVS Richtlinien). Die letztendliche Zustandsbewertung basiert auf handnahe, visuelle Inspektionen durch geschulte Prüfingenieur:innen. Aus Kostengründen werden geodätische Überwachungsmessungen erst dann in den baulichen Erhaltungsprozess integriert, wenn das Bauwerk bereits einen kritischen Zustand erreicht hat.

Der Verbruch einer Stützmauer auf der Brennerautobahn A13 in der Nähe der Mautstation Schönberg im Jahr 2012 (siehe Abb. 1) offenbarte die Unzulänglichkeiten aktueller Methoden zur Zustandsbewertung. Als Konsequenz wurden viele Bauwerke nochmals genauer untersucht und ein interdisziplinäres Forschungsprojekt zur *Sicherheitsbewertung bestehender Stützbauwerke* initiiert. Ein Arbeitspaket widmete sich der Aufgabenstellung, schadhafte, straßenseitige Bauwerke durch Einsatz von mobilem Laserscanning aufzuspüren. Die Bauwerkserhalter zeigten sich überzeugt vom Potenzial der Methode, weshalb sie derzeit ein nachfolgendes Forschungsprojekt unterstützen, um den großflächigen Einsatz zu erproben.

Dieser Beitrag gibt einen Einblick in die Rolle des mobilen Laserscannings zur Zustandsbewertung bzw. -überwachung der Verkehrsinfrastruktur. Dabei wird dezidiert auf den Einsatz kommerziell erhältlicher Systeme eingegangen.

Deutsche Presse-Agentur 2012



Häflinger 2021

Abb. 1: Versagen einer Spornmauer auf der Brennerautobahn (links) und Korrosionsschäden im Bereich der Arbeitsfuge bei einer Winkelstützmauer (rechts)

Die Autoren berichtet über Erfahrungen mit Dienstleistern aus Forschung und Industrie und präsentieren Erkenntnisse mit Hinblick auf die Auswahl geeigneter Systeme, deren Betrieb und der Auswertung am Beispiel der Überwachung von Stützbauwerken im Infrastrukturnetz Österreichs.

## 2 Instandhaltung und Überwachung von Stützbauwerken

### 2.1 Definition, Funktionsweise und Versagensmechanismen

Stützbauwerke bestehen aus massiven Baustoffen und dienen der Sicherung von steilen Hangböschungen und zur Herstellung horizontaler Flächen in Hanglagen (Adam et al. 2007). Insbesondere im alpinen Bereich sind sie somit fixer Bestandteil der Verkehrsinfrastruktur. Im Netz der österreichischen Autobahngesellschaft ASFiNAG existieren mehr als 1500 Stützbauwerke und die österreichischen Bundesbahnen betreuen ca. 10.000 Objekte (Rebhan 2019). Hinzukommen noch zigtausende Objekte in der Erhaltung der Bundesländer (z. B. Nöhrer et al. 2019) und Gemeinden.

Stützbauwerke können grob anhand ihrer Stützwirkung unterschieden werden. Die horizontalen Erddrucklasten können durch das Eigengewicht (Gewichtsstützmauern), durch Erdauflast (Winkelstützmauern) oder Aktivierung des Erdkörpers durch z. B. Verpressanker aufgenommen werden (Adam et al. 2007).

Mit der Funktionsart der Stützbauwerke unterscheiden sich auch die Versagensmechanismen und die daraus resultierenden Schadensbilder. Bewehrungskorrosion im Bereich der Arbeitsfuge bei Winkelstützmauern kann z. B. eine Biegung bzw. Neigungsänderung des Wandschenkels zur Folge haben (Rebhan et al. 2020). Versagen von einzelnen Ankern kann bei vollflächigen Mauern zu

Lastumlagerungen und damit zu kleinräumigen Verformungen führen. Bei Elementwänden ohne Querkraftverdübelung können die individuellen Elemente Starrkörperbewegungen aufweisen.

## 2.2 Aktuelle Methoden zur Verformungsmessung

Im obigen Abschnitt wurde bewusst darauf abgezielt, dass Schadensbilder auftreten können aber nicht zwangsläufig müssen. Denn ein Anker kann vollständig ausfallen, ohne dass es äußerliche Anzeichen eines Schadens gibt. Aus diesem Grund sind Verformungsmessungen als Sonderprüfung nur dann sinnvoll, wenn duktile Bauwerksverhalten erwartet wird. Im Gegensatz dazu steht das Beispiel auf der Brennerautobahn. Die Spornmauer hat plötzlich versagt – es kam zu einem spröden Wandverbruch. Mit anderen Worten: Schäden müssen sich ankündigen und Verformungen messbar sein, damit Verformungsmessungen als belastbare Grundlage für die Zustandsbeurteilung verwendet werden können.

Für die Erfassung von Verformungen kommen derzeit in der Regel tachymetrische Messungen zum Einsatz. Vermarktete Bireflex-Targets auf der Betonoberfläche werden polar vermessen und die Lage dieser über mehrere Epochen hinweg überwacht. Üblicherweise sind die Ziele in Profilen angeordnet ([Abb. 2](#) rechts), um aus der Lageveränderung zwischen Zielen in unterschiedlichen Höhenlagen auf ein etwaiges Bauwerksskippen zu schließen. Diese Methode ist praktikabel und bewährt, dafür aber zeit- und kostenaufwändig. Dies gilt insbesondere für Autobahnvermessungen, wo Fahrspuren aus Sicherheitsgründen



**Abb. 2:**  
Sperre des rechten  
Fahrstreifens zur  
Durchführung  
tachymetrischer  
Überwachungs-  
messungen an  
einer Stützkon-  
struktion (links);  
Anordnung von  
Bireflex-Zielen und  
IoT-Sensoren zur  
Überwachung der  
Bauwerksneigung  
(rechts)

gesperrt werden müssen (Abb. 2 links). Permanente Monitoringlösungen mit Totalstationen sind ebenfalls zu teuer, um sie großflächig einzusetzen zu können. Eine günstigere Alternative für punktuelle Verformungsmessungen stellen auftarke, niedrigpreisige Internet-of-Things (IoT) Neigungssensoren dar (Abb. 2 rechts). Allerdings ist bei diesen die (Temperatur-)Stabilität der Sensoren und der Konsolen entscheidend und zum Teil nicht hinreichend gegeben.

Heute nutzen viele Ingenieurbüros für Vermessung Laserscanning in deren Tagesgeschäft. Wenig verwunderlich ist es also, dass terrestrisches Laserscanning für Verformungsmessungen von einzelnen Stützmauern wie z.B. Raumgitterkonstruktionen bereits eingesetzt wurde. In Kombination mit tachymetrischen Messungen wird ein Koordinatensystem zur Registrierung der Punktfolken geschaffen, um anschließend einen Punktfolkenvergleich durchzuführen. Die Schwierigkeiten mithilfe der am Markt verfügbaren Softwareprodukte auf signifikante Verformungen zu schließen, wird anhand eines Beispiels einer Stützmauer in Holst et al. (2017) erläutert. Nachdem nicht garantiert ist, dass derselbe Punkt in zwei Epochen gescannt wird, kommen unterschiedliche Verfahren zum Einsatz, welche zum Teil sensitiv auf die Parametereinstellungen sind. Außerdem fehlen stochastische Modelle, um die Verformungen auf Signifikanz testen zu können.

## 2.3 Mobiles Laserscanning: Idee und Herausforderungen

Kommerzielle, mobile Laserscanning-Systeme (MLS) sind aufgrund ihrer Preise noch nicht sehr weit verbreitet. Vielleicht liegt es daran, dass es kaum Studien bzw. Berichte zu Verformungsmessungen mit MLS gibt. Die grundlegende Idee im Forschungsprojekt ist es, mit Geschwindigkeiten um ca. 80 km/h straßenseitige Stützbauwerke vollflächige zu erfassen, ohne dabei den Fließverkehr maßgeblich zu behindern. Die Methode verspricht Skalierbarkeit und damit eine kosteneffiziente Messüberwachung der Oberflächengeometrie von einer Vielzahl an Bauwerken.

Den hohen Erwartungen an den Einsatz von MLS stehen folgende Herausforderungen/offene Fragen gegenüber:

- Ähnlich wie beim terrestrischen Laserscanning stellt sich die Frage nach dem Punktfolkenvergleich. Wie können 3D-Koordinaten verglichen und auf Verformungen geschlossen werden, wenn niemals exakt dieselben Punkte erfasst werden? Welche Verformungen sind signifikant?
- Zusätzlich kommt hinzu, dass mobiles Laserscanning für großflächige Aufnahmen ausgelegt ist. Es fallen große Datenmengen an und diese müssen effizient ausgewertet werden, um das Potenzial von mobilem Laserscanning voll ausschöpfen zu können.

- Die Registrierung der Punktwolken funktioniert im großen Stil über die Integration von GNSS und inertialer Messeinheiten. Wie gut stimmen Punktwolken aus mehreren Epochen überein und wie gut ist die Ko-Registrierung mehrerer Scanner unter herausfordernden Bedingungen?

### 3 Datenaufnahme mit kommerziellen, mobilen Laserscanning-Systemen

#### 3.1 Auswahl geeigneter MLS

Bei sicherheitskritischen Anwendungen gelten die höchsten Qualitätsanforderungen an das einzusetzende Equipment und das Know-how des Nutzers. Aus diesem Grund kommen für die Bauwerksüberwachung nur mobile Laserscanning-Systeme mit hochqualitativen Komponenten in Frage.



Abb. 3: Übersicht der eingesetzten, mobilen Laserscanning-Systeme: Leica Pegasus: Two Ultimate Dualhead (links oben), Siteco Road Scanner 4 (rechts oben), Trimble MX9 (links unten) und Riegl VMX-2HA (rechts unten)

Die Kaufpreise für derartige Systeme inklusive Wartung und Software liegen in der Regel im mittleren bzw. höheren sechsstelligen Eurobereich. Daher kooperieren wir mit Partnern aus Forschung und Industrie, die ihre Systeme zum Einsatz bringen wollen. Für uns bietet es den Vorteil, dass wir Daten von verschiedenen Systemen erhalten und somit gegenüberstellen können. Die eingesetzten MLS gehören wohl zu den hochwertigsten, die der Markt derzeit zu bieten hat (siehe Abb. 3).

Obwohl die Systeme von unterschiedlichen Herstellern stammen, werden zum Teil die gleichen Komponenten verbaut. Beim Leica Pegasus:Two Ultimate Dualhead und dem Siteco Road Scanner 4 sind z. B. zwei Z+F 9012 Profillaserscanner verbaut. Das Trimble MX9 und das Riegl VMX-2HA System setzen jeweils auf zwei Riegl VUX-1HA Laserscanner. Am Papier sind sich die Systeme ähnlich, die resultierenden Punktwolken unterscheiden sich zum Teil aber merklich voneinander. Das liegt zum Teil an unterschiedlichen Firmenphilosophien bzw. in der Handhabung der Dienstleister. Tab. 1 gibt einen Überblick über die

**Tab. 1:** Zusammenfassung der wesentlichsten Unterschiede der eingesetzten MLS

	Leica	Siteco	Trimble	Riegl
<b>Kalibrierung</b>	Hersteller / Vor Ort für 2. Scanner	Vor Ort	Hersteller / Vor Ort	Hersteller
<b>Profilrate</b>	150 Hz*	200 Hz	250 Hz	250 Hz
<b>Scanrate</b>	1 MHz	1 MHz	1,8 MHz	1,8 MHz
<b>Hor. Ausrichtung</b>	30°/60°	45°/45°	54°/54° o. 66°/66°	55°/55°
<b>Ver. Ausrichtung</b>	40°	35°	0° o. ± 12°	39°
<b>Software zur Trajektorienberechnung</b>	Waypoint Inertial Explorer	Applanix POSPac	Applanix POSPac	Applanix POSPac
<b>OS** Aufnahmesteuerung</b>	Windows	Windows	Windows	Linux
<b>Start/Stopp von Tracks</b>	Bei Stillstand	Während der Fahrt	Während der Fahrt	Während der Fahrt
<b>Aufbau/max. Gewicht der Komponenten</b>	komplett, > 70 kg	modular, 20 kg	komplett, 37 kg	mehrteilig, 35 kg

\* 200 Hz möglich

\*\* OS = Operating System (engl. für Betriebssystem)

relevanten Unterschiede zwischen den Systemen bzw. deren Betrieb. Weitere Details zu Produktspezifikationen sind den Datenblättern zu entnehmen.

Mit Bezug auf die Bauwerksüberwachung, sind folgende Punkte anzumerken:

- Die Philosophien bei der Kalibrierung des Systems variieren stark. Während bei modularen MLS die Kalibrierung nach jedem Aufbau notwendig sind, setzen manche Hersteller darauf, dass eine jährliche Werkskalibrierung vollkommen ausreicht. Andere bieten dem Nutzer die Möglichkeit Hebelarme und Boresight-Winkel selbst zu kalibrieren, ohne aber dabei Präzisionsmaße für die Parameter anzugeben. Diese Herangehensweise lässt sich schwer mit jener eines Geodäten vereinen. Schließlich werden altbewährte Messgeräte auch in regelmäßigen Intervallen überprüft und man möge meinen, dass dies bei MLS in hochgenauen Anwendungen ebenfalls der Fall sein sollte.
- Die Ausrichtung der Scanner sowie die Abtast- und Profilraten bestimmen die Erfassung der Umgebung. Der Auftreffwinkel der Laserstrahlen spielt in mehrerlei Hinsicht eine bedeutende Rolle. Näheres dazu ist in Kapitel 5 ausgeführt.

### 3.2 Kooperation mit Dienstleistern

Wird die Datenaufnahme von einem externen Unternehmen durchgeführt, muss klar definiert sein, wie die Leistungen vom Dienstleister bzw. vom Auftraggeber aussehen. Vorab der Kampagne sind zu klären:

- Begleitschutz auf stark befahrenen Straßenabschnitten/Autobahnen,
- Scankonfiguration und Abtastraten, falls einstellbar,
- Fahrgeschwindigkeiten,
- Notwendigkeit einer Feldkalibrierung,
- Bezugssysteme zur Georeferenzierung der Daten,
- Verwendung von Referenzstationsdaten und der
- Lieferumfang.

Die Datenlieferung sollte mindestens enthalten:

- Punktfolgen, getrennt nach den Scannern in einem allgemein lesbaren und kompakten Format wie z. B. LAZ,
- Trajektorien, d. h. Raumposition und -lage des Systems mit hoher Frequenz (z. B. 200 Hz),
- Qualitätsinformation der Trajektorie mit niedriger Frequenz (1 Hz ist ausreichend) und
- Kalibrierparameter und Erläuterung zur Definition der Koordinatensysteme.

### 3.3 Datengrundlage

In zwei Forschungsprojekten und zwei direkt beauftragten Projekten wurden 24 Stützbauwerke in 8 Messkampagnen mit vier kommerziellen, mobilen Laser-scanning-Systemen vermessen. Es resultieren ca. 300 Punktwolken mit ca. 7 Milliarden Punkten rein von Stützmauern und ihrer unmittelbaren Umgebung.

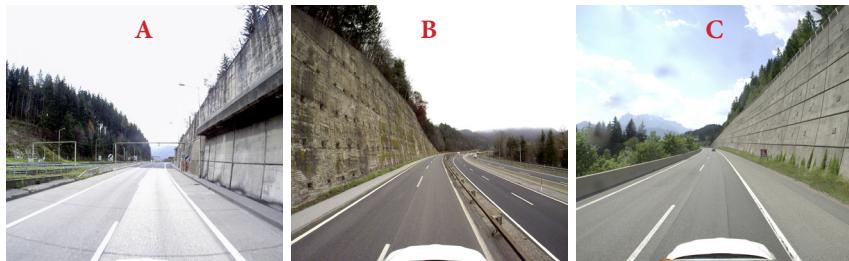


Abb. 4: Übersicht über die in diesem Beitrag behandelten, geankerten Stützkonstruktionen

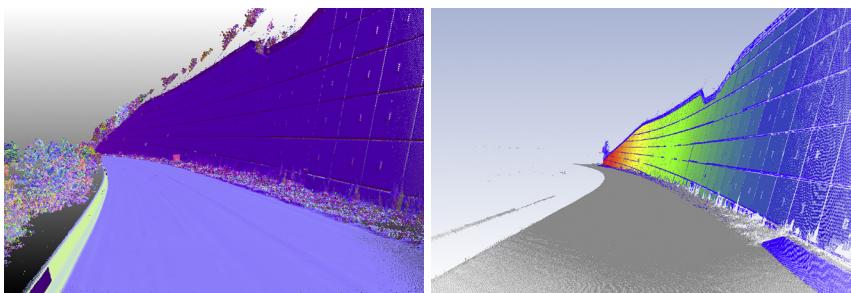
Die Objekte befinden sich entlang von Autobahnen, Bundes- und Landesstraßen sowie entlang von Gleisstrecken in Salzburg, Oberösterreich, Niederösterreich und der Steiermark. Der Großteil der Mauern sind geankerte Elementwände, wobei auch Raumgitterwände, Schwerkraftmauern und Steinschlichtungen aufgenommen wurden. Alle diese Objekte sichern Hänge zur Herstellung von Infrastruktur in alpinem Gelände. Aufgrund der steilen Hänge und der Vegetation ist die GNSS-Abschattung bei all diesen Bauwerken ein großes Thema. In diesem Beitrag werden Daten und Auswertungen von drei Stützbauwerken A, B, C präsentiert (siehe Abb. 4).

## 4 Big Data und zielgerichtete Auswertung

In den letzten Jahren kamen viele neue, mobile Laserscanning-Systeme auf den Markt. Mit mindestens gleichem Tempo entstanden neue Firmen und Softwarelösungen zur Darstellung und Verarbeitung dieser großen Datenmengen (*Big Data*). Klassische Aufgabenstellungen sind Merkmalsextraktionen für Bestandsaufnahmen, Lichtraumkontrollen oder Fahrbahnanalysen, um einige wenige zu nennen. Für Spezialanwendungen, wie z. B. der Verformungsanalyse von vielen verschiedenen Stützbauwerken, liegen keine geeigneten Softwareprogramme vor. Aus diesem Grund empfiehlt es sich, sich bestehende Programmbibliotheken anzueignen und die gewünschten Prozesse selbst zu automatisieren. Dies spart langfristig Zeit und ermöglicht die konsistente Auswertung von z. B. 300 Punktwolken.

## 4.1 Semantische Interpretation

Das Ziel ist es, Verformungen der Stützkonstruktion zu detektieren und intuitiv für die Prüfingenieure darzustellen. Daher müssen die Algorithmen in der Lage sein, die Punktwolken zu *interpretieren* und zu verstehen, welche Punktgruppen das Stützbauwerk repräsentieren und was *Straße* oder *Vegetation* ist. Tatsächlich sind für diese Aufgabenstellung viele verschiedene Lösungsansätze denkbar.



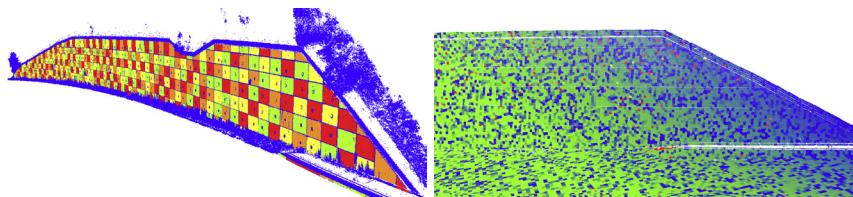
**Abb. 5:** Ausgangssituation sind Punktnormalen, hier dargestellt in Form von HSV-Farben (links) für die semantische Interpretation von Straße (grau), Stützmauer und geankerten Betonelementen (von blau bis rot; rechts) [Stützmauer C]

In unseren Auswertungen nützen wir rein die Geometrieinformation, d.h. die X,Y,Z-Koordinaten. Mithilfe von Statistik und Merkmalsinformationen aus der Normalenberechnung kann diese Aufgabenstellung im Wesentlichen bewerkstelligt werden (siehe Abb. 5). Der interessierte Leser sei auf Kalenjuk et al. (2021) für nähere Informationen zur semantischen Interpretation verwiesen.

## 4.2 Ableitung von Bauwerksverformungen

Nachdem das Bauwerk in der Punktwolke identifiziert wurde, kann die Veränderung der Oberflächengeometrie aus Aufnahmen mehrerer Epochen abgeleitet werden. Wie in Kapitel 2.3 geschildert, existieren in der Regel keine eindeutigen Punktkorrespondenzen zwischen den Epochen. Einige Ansätze zielen darauf ab, in ausgewählten Punkten Korrespondenzen herzustellen (Gojcic et al. 2019). Sie setzen auf markante Merkmale, welche bei künstlichen Bauten wie z. B. bei Elementwänden in der Regel nicht eindeutig sind.

Gerade bei wohldefinierten Geometrien bietet es sich an, diese durch geometrische Primitive anzunähern und deren Parameter, wie z. B. die Neigung oder



**Abb. 6:** Semantische Segmentierung nach Betonelementen (links) und voxel-basierte Segmentierung/Diskretisierung mit Voxelgröße 0,5 m (rechts) [Stützmauer C]

laterale Position, über mehrere Epochen zu beobachten. Die Identifikation der geankerten Betonelemente (siehe Abb. 6) erfolgt nach Ansätzen, wie sie in Kapitel 4.1 beschrieben sind.

Liegen weder viele eindeutige Punkte vor, noch ist die Geometrie wohl definiert, können punktwolken-basierte Methoden eingesetzt werden (Ohlmann-Lauber und Schäfer 2011). Die Idee ist es, Punktcorrespondenzen über die nächstgelegenen Punkte herzustellen, um eine Transformation für eine ganze Punktgruppe zu berechnen. Punktgruppen, also Teilmengen der Punktwolke können grundsätzlich beliebig gewählt werden, solange die Annahme der Starrkörperbewegung nicht verletzt wird. Mit anderen Worten sollte die Voxelgröße bei einer Voxeldiskretisierung nicht zu groß sein, um kleinräumige Verformungen noch auflösen zu können (Abb. 6 rechts). Ein Vertreter dieser Unterkategorie ist z. B. der Iterative Closest Point (ICP) Algorithmus. Wir empfehlen allerdings die Transformationsparameter nicht durch Minimierung der L2-Norm (wie beim ICP), sondern durch Minimierung der Normalabstände zu berechnen. Damit wird unter anderem der primären Sensitivität von Laserscannern in „Line-Of-Sight“ Rechnung getragen. Näheres zu diesem Ansatz ist in Kalenjuk und Lienhart (2022) zu finden.

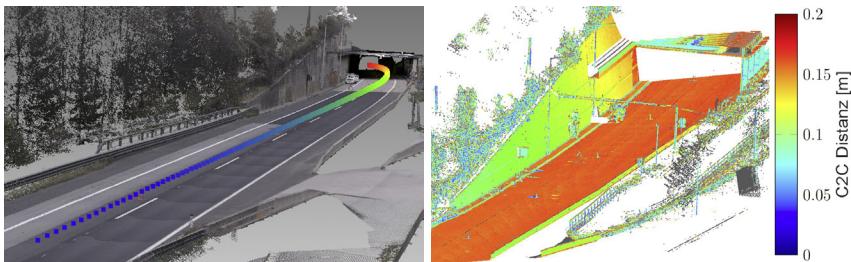
## 5 Qualität von mobilen Laserscanning-Punktwolken

Wie bereits in Kapitel 3 ausgeführt, gelten für die Bauwerksüberwachung hohe Qualitätsanforderungen. Selbst bei hochpreisigen MLS ist nicht garantiert, dass die generierten Punktwolken den eigenen Anforderungen bzw. jenen des Prüfpersonals entsprechen. Dabei fällt in der Praxis oft die Frage seitens der Auftraggeber nach der Genauigkeit. Wie in Kuhlmann (2020) gezeigt, lässt sich diese Frage im Vorhinein nur schwer beantworten, denn viele Einflussfaktoren bestimmen letztendlich Präzision bzw. Genauigkeit von derartigen Multisensorsystemen. Die Empfehlung lautet daher diese empirisch zu bestimmen. Die nachfolgenden Kapitel sind ein Auszug aus Kalenjuk und Lienhart (2022) und beschreiben Fehlerquellen, deren Größenordnung an konkreten Beispielen und

eine Möglichkeit die geometrische Qualität von mobilen Laserscanning-Punkt-wolken zu steigern.

## 5.1 Georeferenzierung

Die Positionsgenauigkeit wird maßgeblich von der direkten Georeferenzierung bestimmt. Unter Verwendung von relativen Positionierungsverfahren ist bestenfalls eine Genauigkeit im Zentimeterbereich zu erwarten. Zur Evaluierung bietet es sich an, Passpunkte einzumessen und diese mit Punkten in den Scandaten zu vergleichen. Diese Herangehensweise erweist sich aber als sehr aufwändig für großflächige, mobile Laserscanning Kampagnen.



**Abb. 7:** Separierung der Trajektorienlösungen als Indiz für die Qualität der Georeferenzierung (links) und Cloud-to-Cloud (C2C) Abweichungen von zwei Punktfolgen, aufgenommen in zwei Fahrten mit zeitlichem Versatz von ca. 15 Minuten (rechts) [Stützmauer A]

Alternativ können Qualitätsmaße aus der Trajektorienberechnung als Indiz für die Güte der Georeferenzierung herangezogen werden. Beispielsweise ist festzustellen, dass die Differenz zwischen Vorwärts- und Rückwärtsprozessierung einer Messfahrt genau im Bereich des Portals eines 2,5 km langen Tunnels am größten ist (Abb. 7 links). Selbst bei gewichteter Mittelung beider Lösungen ist in diesem Bereich von einer verminderten Absolutgenauigkeit auszugehen. Dies lässt sich anhand zweier Messfahrten empirisch feststellen. In diesem Beispiel treten Abweichungen von 18 cm in der Höhe und über 10 cm in der Lage auf (Abb. 7 rechts).

Beim statischen Laserscanning werden Standpunkte entweder über Zielmarken oder über Best-Fit-Algorithmen, wie z. B. ICP, zueinander registriert. Sofern die Standpunkte stabil sind, können sie über starre Transformationen miteinander verknüpft werden. Beim mobilen Laserscanning hingegen gibt es a priori keine stabilen Standpunkte bzw. Bereiche. Abb. 8 zeigt die C2C-Distanzen zweier Punktfolgen einer geankerten Stützkonstruktion, die innerhalb weniger Minuten von zwei Fahrtrichtungen aus aufgenommen wurden. Nachdem es sich

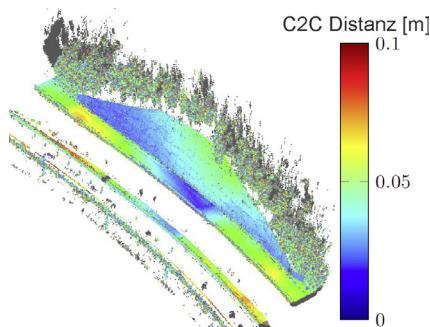


Abb. 8:

Cloud-to-Cloud (C2C) Abweichungen von zwei Punktwellen, aufgenommen in zwei Fahrten mit entgegengesetzten Fahrtrichtungen und einem zeitlichem Versatz von weniger als 5 Minuten [Stützmauer B]

um ein symmetrisch konfiguriertes System handelt (siehe Tab. 1), resultieren die lokalen Abweichungen von 8 cm aus der Georeferenzierung. An dieser Stelle sei angemerkt, dass die Ankerwand knapp 20 m hoch ist, Bäume über dieser wachsen und die Straße knapp an der Mauer verläuft.

Mit Bezug auf dieser Datengrundlage muss festgestellt werden, dass keine Verformungsmessungen durchgeführt werden können, wenn die Punktwellen selbst um mehrere Zentimeter *deformiert* sind. Ein Lösungsansatz, mit dem es doch funktionieren kann, ist in Kapitel 5.3 präsentiert.

## 5.2 Ko-Registrierung der Laserscanner

Wie bereits in Kapitel 3.1 erläutert, setzen manche Hersteller auf jährliche Werkskalibrierungen, ohne dem Nutzer die Möglichkeit für Feldkalibrierungen zu geben. Unserer Erfahrung nach sind die Kalibrierwerte nicht bei allen MLS stabil. Abweichungen zwischen den Punktwellen der zwei Scannern sind daher die Folge.

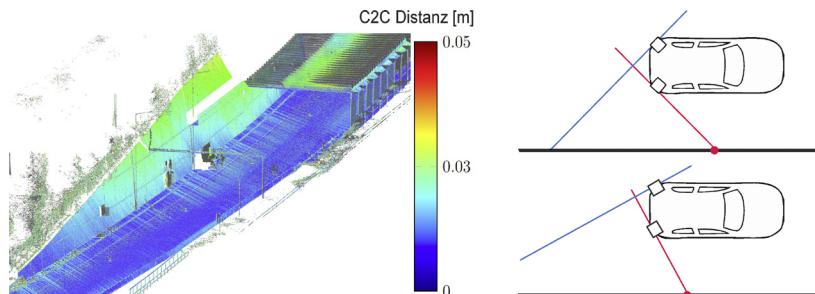


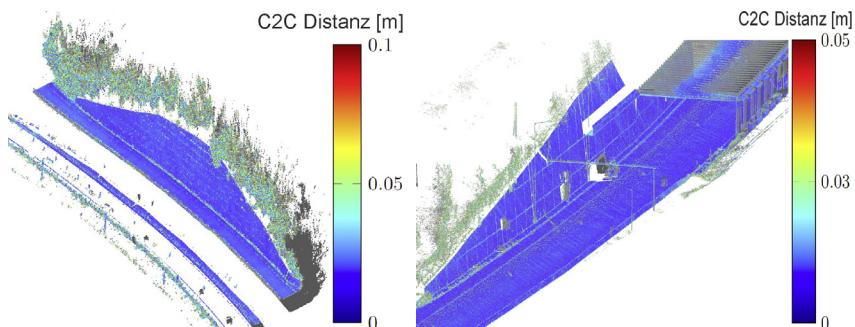
Abb. 9: Cloud-to-Cloud (C2C) Abweichungen von Scanner links und rechts einer Messfahrt (links) [Stützmauer A] und Darstellung zweier Scannerkonfiguration zur Verdeutlichung des zeitlichen Versatzes bei der Aufnahme

In Anbetracht der hochfrequent auftretenden Fehler in der Georeferenzierung, ist die Qualität der Ko-Registrierung der beiden Profillaserscanner ebenfalls nicht konstant. Denn die gleichen Bereiche auf der Objektoberfläche werden von den Laserscannern zeitlich versetzt erfasst. Ist die Fahrtgeschwindigkeit gering oder die Scannerkonfiguration nicht symmetrisch (Abb. 9 rechts), so ist die Zeitspanne zwischen den Abtastungen größer. Im Bereich des Tunnelportals variiert die Übereinstimmung der Scanner innerhalb weniger Meter im Zentimeterbereich (Abb. 9 links). Auch diese Effekte lassen sich mit den im nächsten Abschnitt beschriebenen Ansatz minimieren.

### 5.3 Ansatz zur Qualitätssteigerung

Die hochpreisigen Profillaserscanner weisen auf dem Papier eine Präzision im niedrigen Millimeterbereich auf. Nichtsdestotrotz sehen wir Fehler von 10 cm und mehr. Um das Potenzial dieser teuren Systeme also ausnutzen zu können, versuchen wir die Messdaten der Profillaser von der Georeferenzierung oder den Kalibrierparameter zu lösen.

Die Profillaserscanner tasten bei Stillstand die Umgebung in einer Ebene ab. Erst durch Fortbewegung entsteht das 3D-Abbild. Die grundlegende Idee ist es aus den erhaltenen 3D-Punktwolken einzelne Profile (bzw. Spiralen) zu extrahieren. Diese werden, je nach Profilrate, innerhalb 1/250 s bis 1/150 s (siehe Tab. 1) aufgenommen. In dieser kurzen Zeitspanne können wir davon ausgehen, dass die Georeferenzierung keinen (nennenswerten) Fehler verursacht. Daher entspricht diese Teilmenge der Punktwolke einem Bereich, den wir mittels Starkörpertransformation zu einer anderen Punktwolke registrieren können. Die



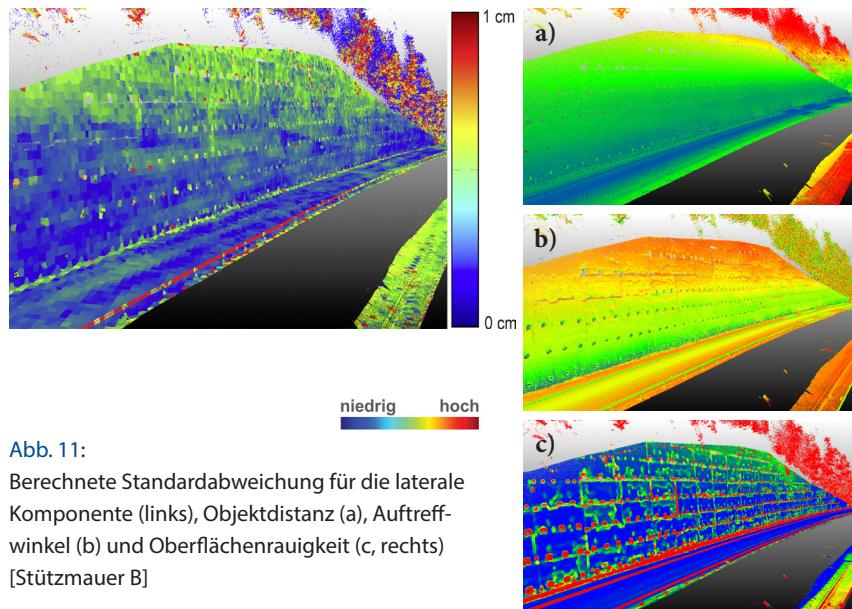
**Abb. 10:** Cloud-to-Cloud (C2C) Abweichungen von zwei Messfahrten (links) [Stützmauer B] und von Scanner links und rechts (rechts) [Stützmauer A]. Die Farbskalen sind unterschiedlich und beziehen sich auf die in Abb. 8 und Abb. 9 dargestellten, nicht reduzierten Abweichungen

Transformationsparameter können wir zu einer Punktfolke aus einer anderen Fahrt ([Abb. 10 links](#)) oder der Punktfolke des zweiten Scanners rechnen ([Abb. 10 rechts](#)). Verglichen mit den ursprünglichen Punktfolken in [Abb. 8](#) und [Abb. 9](#), ist eine deutliche Verbesserung ersichtlich. Die verbleibenden Abweichungen liegen großteils unter 1 cm.

Ähnlich wie bei tachymetrischen Verformungsmessungen, müssen wir stabile und instabile Bereiche identifizieren und zielgerichtet auswerten. Die Stützmauer wird daher in der Punktfolke segmentiert und aus der Registrierung ausgeklammert. Für die Auswertung der Punktfolken werden die in Kapitel 4.1 beschriebenen Algorithmen verwendet. Nähere Informationen können Kalenjuk et al. (2021) entnommen werden.

## 5.4 Empirische Qualitätsbestimmung aus Mehrfachfahrten

Es ist also gelungen mit dem in Kapitel 5.3 beschriebenen Vorgehen sowohl Abweichungen zwischen zwei Messfahrten (Kapitel 5.1, [Abb. 10 links](#)) als auch zwischen zwei Scannern (Kapitel 5.2, [Abb. 10 rechts](#)) zu reduzieren. Zur Verifizierung wurde die Stichprobe erweitert und es wurden vier mobile Laserscanning-Punktfolken in allen  $\binom{4}{2} = 6$  Kombinationen nach der Korrektur einander gegenübergestellt und für jeweils alle Voxel die Standardabweichungen in



lateraler Komponente empirisch bestimmt (Abb. 11 links). Im oberen Bereich der Mauer liegt die Präzision im Bereich von 3,5 mm.

Der Zusammenhang zwischen der empirischen Standardabweichung, der Objektdistanz (a), des Auftreffwinkels (b) und der Oberflächenrauheit (c) sind ersichtlich (Abb. 11). Diese Parameter lassen sich mithilfe der Trajektoriendaten berechnen (siehe Anforderungen in Kapitel 3.2).

Nach aktuellem Stand der Technik existiert keine Möglichkeit, um die Präzision von mobilen Laserscanning-Punktwolken verlässlich vorherzusagen. Das bedeutet also, dass Straßenabschnitte beim ersten Mal mehrfach abgefahren werden sollten, um die Präzision zu bestimmen. Diese ist notwendig, um Bauwerksverformungen statistisch auf ihre Signifikanz testen zu können.

## 6 Zusammenfassung

Die Instandhaltung bestehender Verkehrsinfrastruktur bedarf regelmäßiger Zustandsbeurteilungen von Tunneln, Brücken und Stützbauwerken durch fachkundige Prüfingenieure und Prüfingenieurinnen. Geodätische Überwachungsmessungen gelten in Österreich als Sondermaßnahme und werden in der Regel erst dann vom Bauingenieur angeordnet, wenn sich das Bauwerk bereits in einem kritischen Zustand befindet.

Dieser Beitrag ging der Frage nach, inwieweit mobiles Laserscanning einen Beitrag zur Zustandsbewertung der Verkehrsinfrastruktur leisten kann. Der Laserscanning-Markt wächst rasant und heute existiert eine Vielzahl an kommerziell erhältlicher Gesamtsysteme. Obwohl die mobilen Laserscanning-Systeme am Datenblatt ähnliche Spezifikationen aufweisen, zeigen sich in der Praxis im Betrieb bzw. in den Ergebnissen doch deutliche Unterschiede. Zum einen betrifft das die Möglichkeit von Feldkalibrierungen und die Qualitätsmaße der Kalibrierparameter. Schlechte Kalibrierparameter aber auch variierende Qualität der Georeferenzierung beeinflussen die Übereinstimmung zwischen Scanner links und rechts. Die Georeferenzierung ist mit Sicherheit eine der größten Herausforderungen, um oberflächliche Geometrieänderungen erfassen zu können. In diesem Beitrag wurde ein Lösungsansatz präsentiert, mit dem die hochfrequenten Abweichungen reduziert und damit die mobilen Laserscanning-Punktwolken zueinander registriert werden können. Erst durch diesen Schritt kann das Potenzial von hochpreisigen MLS voll ausgeschöpft werden.

Die Anschaffungskosten eines solchen mobilen Laserscanning-Systems sind hoch und rechtfertigen sich dann, wenn die Bauwerksüberwachung großflächig angewendet werden kann. Hierzu benötigt es einerseits geeignete Softwarepakete und Entwicklungsarbeit. Zum anderen braucht es Lobbying und die richtige Platzierung der Technologie. Zum jetzigen Stand der Technik ist mobiles

Laserscanning ungeeignet, als dass es tachymetrische Messungen an kritischen Bauwerken ersetzen könnte. Genauso wenig werden belastbare Zustandsbeurteilungen rein aus MLS abgeleitet werden können. Die Rolle des mobilen Laserscannings liegt viel eher darin, potenziell geschädigte Bauwerke aus der Vielzahl an Objekten zu identifizieren. Diese *automatische Vorprüfung* kann als Grundlage für die eigentliche Bauwerksprüfung angesehen werden. Sofern die Methode breite Akzeptanz bei den Bauwerkserhaltern finden kann, eröffnet sie den Geodäten neue Geschäftsfelder.

## Literatur

- Adam, D., Bergmeister K., Florineth F. (2007): Stützbauwerke. In: Betonkalender 2007, Teil 1. 96. Jg. Berlin: Ernst & Sohn.
- Deutsche Presse-Agentur (2012): 130 Tonnen Mauer begraben den Münchner unter sich. Die Welt. [www.welt.de/regionales/muenchen/article13935621/130-Tonnen-Mauer-begraben-den-Muenchner-unter-sich.html](http://www.welt.de/regionales/muenchen/article13935621/130-Tonnen-Mauer-begraben-den-Muenchner-unter-sich.html), letzter Zugriff 07/2022.
- Gojcic, Z., Zhou, C., Wieser, A. (2019): Robust point correspondences for point cloud-based deformation monitoring of natural structures. In: Gikas, V. (Ed.): 4th Joint International Symposium on Deformation Monitoring (S.8). Athen: National Technical University of Athens.
- Häflinger, S. (2021): Lokale Korrosion der Bewehrung – kleiner Schaden mit grosser Tragweite. Concrete – ETH Zürich. <https://concrete.ethz.ch/blog/lokale-korrosion-der-bewehrung-kleiner-schaden-mit-grosser-tragweite/>, letzter Zugriff 07/2022
- Holst, C., Schmitz, B., Schraven, A., Kuhlmann, H. (2017): Eignen sich in Standardsoftware implementierte Punktwolkenvergleiche zur flächenhaften Deformationsanalyse von Bauwerken? Eine Fallstudie anhand von Laserscans einer Holzplatte und einer Staumauer. In: zfv – Zeitschrift für Geodäsie, Geoinformation und Landmanagement, Heft 2/2017, 142. Jg., 98–110. DOI: [10.12902/zfv-0158-2017](https://doi.org/10.12902/zfv-0158-2017).
- Kalenjuk, S., Lienhart, W. (2022): A Method for Efficient Quality Control and Enhancement of Mobile Laser Scanning Data. In: Remote Sensing, 14(4), [857]. DOI: [10.3390/rs14040857](https://doi.org/10.3390/rs14040857).
- Kalenjuk, S., Lienhart, W., Rebhan, M. (2021): Processing of mobile laser scanning data for large-scale deformation monitoring of anchored retaining structures along highways. In: Computer-Aided Civil and Infrastructure Engineering, 36(6), 678–694. DOI: [10.1111/mice.12656](https://doi.org/10.1111/mice.12656).
- Kuhlmann, H. (2020): Uncertainty modelling for kinematic multi-sensor systems. DGK – Abteilung Ingenieurgeodäsie & GKGM Joint Workshop, 21–23 September 2020, Bad Lauterbach.
- Nöhrer, F., Rebhan, M., Saurug, B., Marte, R., Grubinger, S., Mauerhofer, G. (2019): Long-term experiences for the safety Assessment of existing retaining structures in Styria. In: Geomechanics and Tunnelling, 12(5), 515–522. DOI: [10.1002/geot.201900035](https://doi.org/10.1002/geot.201900035).
- Ohlmann-Lauber, J., Schäfer, T. (2011): Ansätze zur Ableitung von Deformationen aus TLS-Daten. In: DVW e. V. (Hrsg.): Terrestrisches Laserscanning – TLS 2011 mit TLS-Challenge). DVW-Schriftenreihe, Band 66, Wißner-Verlag, Augsburg, 147–157.

- Rebhan, M. (2019): Forschungsprojekt SIBS: Sicherheitsbewertung bestehender Stütz-bauwerke. VÖBU-Forum, 45, 22–25.
- Rebhan, M., Vorwagner, A., Burtscher, S., Kwapisz, M., Marte, R. (2020): Versuchstechnische Untersuchungen zu Korrosionsschäden an Winkelstützmauern: For-schungsprojekt SIBS. In: Beton- und Stahlbetonbau, 115(4), 270–279. DOI: [10.1002/best.201900073](https://doi.org/10.1002/best.201900073).
- The World Bank (2021): Well-maintained: Economic Benefits from More Reliable & Re-silient Infrastructure. <https://ppp.worldbank.org/public-private-partnership/library/well-maintained-economic-benefits-more-reliable-resilient-infrastructure>, letzter Zu-griff 07/2022.

### **Kontakt**

Slaven Kalenjuk

Institut für Ingenieurgeodäsie und Messsysteme

Technische Universität Graz

Steyrergasse 30, 8010 Graz, Österreich

[slaven.kalenjuk@tugraz.at](mailto:slaven.kalenjuk@tugraz.at)



## **Session 3:**

# **Hydrographische Anwendungen**



# Entwicklung innovativer Technologien für autonome maritime Systeme (EITAMS)

Tobias Neiß-Theuerkauff | Frank Wallhoff | Thomas Brinkhoff | Christian Denker |  
Tarek El-Mihoub | Timotheus Kisselbach | Holger Korte | Yves Korte-Wagner |  
Oliver Köckritz | Thomas Luhmann | Lars Nolle | Robin Rofalski | Christoph Tholen |  
Tobias Werner | Bernhard Schwarz-Röhr | Klaus Windeck

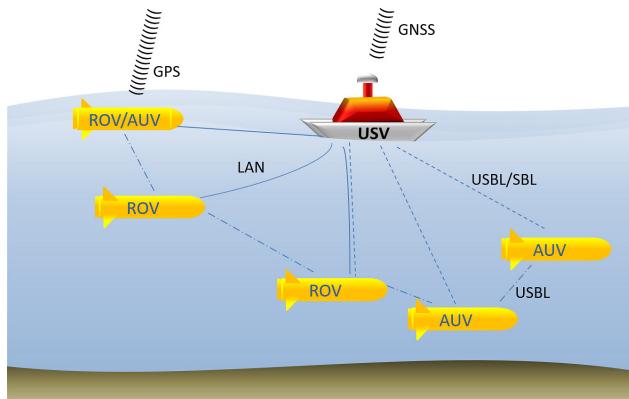
## 1 Abstract

Die immer intensiver werdende Nutzung der Meere und Binnengewässer erfordert eine sich stetig weiter entwickelnde technische Infrastruktur unter Wasser, die geplant, laufend überwacht und gewartet werden muss. Solche Arbeiten werden durch Taucher ausgeführt, zunehmend aber auch durch unbemannte ROVs (Remotely Operated Vehicles) und AUVs (Autonomous Underwater Vehicles), um das menschliche Risiko zu senken und dabei die Effizienz zu steigern. Zur effizienten Überwachung großflächiger Bereiche kann ein Verbund von Unterwasserfahrzeugen eingesetzt werden, der durch ein Überwasserfahrzeug koordiniert wird. Unmanned Surface Vehicles (USV) können dabei komplexe Missionen unterstützend begleiten und steuern, unter anderem bei der Lokalisierung der Unterwasserfahrzeuge.

Ziel des hier vorgestellten Projekts EITAMS war es, ein kostengünstiges vernetztes System solcher Fahrzeuge unter Einbeziehung verschiedener Teildisziplinen (ROV-, AUV- und USV-Steuerung, Suchalgorithmen, Datenmanagement und optische 3D-Messtechnik) zu entwickeln und an einem Demonstrator zu erproben.

## 2 Motivation und Zielsetzung

Für die Erschließung neuer Unterwasserregionen als Infrastrukturgrundlage, z. B. für Offshore-Windkraftanlagen, ist eine genaue Erfassung und Inspektion der Unterwasserregionen erforderlich, während vorhandene Infrastrukturen, wie z. B. Schleusen in Binnengewässern, unter Wasser regelmäßig geprüft werden müssen. Auf der anderen Seite erfordert der zunehmende Eingriff des Menschen in die Unterwasserwelt ebenfalls eine großräumige Überwachung der Umgebung, um zukünftige Umweltschäden zu vermeiden bzw. frühzeitig präventive Maßnahmen durchführen zu können.



**Abb. 1:**  
Vereinfachtes  
Szenario für  
EITAMS Unter-  
wasser-Missionen  
mit der Kommu-  
nikationsdar-  
stellung

Erkundungs-, Inspektions- und Wartungsarbeiten werden zurzeit noch in vielen Fällen von Tauchern übernommen. Dieser Vorgang ist sehr kostenintensiv und zeitaufwändig. Ein Taucher kann aus physischen und psychischen Gründen nur eine begrenzte Zeit unter Wasser arbeiten. Der steigende Wasserdruk in zunehmender Tiefe setzt zudem spezielle Tauchverfahren voraus, die risikobehaftet sind.

Durch den Einsatz von ROVs und AUVs können bei erhöhter Tauchdauer das menschliche Risiko sowie die Einsatzkosten minimiert werden. Des Weiteren ist der größte Teil der Unterwassergebiete nicht durch Taucher erreichbar und setzt den Einsatz von Unterwasserfahrzeugen zwingend voraus.

Ziel des Forschungsprojektes EITAMS ist die Entwicklung eines einsatzfähigen Demonstrators, der die Missionsausführung von autonomen Unterwasseroperationen, unter Einsatz mehrerer AUVs und einem USV, ermöglicht. Dabei sollen photogrammetrische Sensorsysteme zur Objektdetektion und -aufnahme sowie die durch Suchalgorithmen gesteuerte Detektion von Schadstoffen im Fahrzeugverbund unter Wasser zum Einsatz kommen.

Im Vordergrund steht die Entwicklung und Implementierung eines autonomen Gesamtsystems, bei dem am Markt erhältliche, kostengünstige Hardware zum Einsatz kommt. Als Bedingung wurde die flexible und dynamische Anpassung und Überführung des Systems auf andere Trägerplattformen gesetzt, sodass die Übertragbarkeit bzw. die Erweiterbarkeit des Systems auf neuere bzw. größere Systeme in Zukunft gegeben ist. Der Demonstrator, bestehend aus einem USV und mehreren AUVs, soll in der Lage sein, Objekte unter Wasser mittels photogrammetrischer Verfahren zu erfassen, sowie diverse Schadstoffaufkommen mittels Sensorik zu detektieren. Dabei sollen die einzelnen AUVs eigenständig die Unterwasserumgebung in vorgegebenen Bereichen autonom abfahren und untersuchen. Der Verbund soll über das USV administriert und mit Informationen versorgt werden (Abb. 1).

### 3 Verwandte Arbeiten

Der Einsatz von ROVs, AUVs und USVs ist Gegenstand vergangener und laufender wissenschaftlicher Arbeiten. Mit dem am GEOMAR Helmholtz-Zentrum für Ozeanforschung in Kiel seit 2007 im Einsatz stehende ROV KIEL 6000 finden Forschungsfahrten bis zu einer Tiefe von 6000m statt (GEOMAR 2017). Ausgestattet ist es mit sieben Antriebsmotoren, diverser Sensorik zur Lage- und Positionsbestimmung und Kamerasystemen. Je nach Einsatz kann weitere Sensorik angebunden werden. Zur Steuerung des 3,5 t ROVs ist ein mehrköpfiges Team erforderlich.

Das AUV SeaCat der Firma Atlas Elektronik kann bis zu einer Reichweite von 300 m als ROV eingesetzt werden, für größere Bereiche bis 600 m aber auch autonom als AUV agieren (Atlas Elektronik 2022). Eingesetzt wird es u. a. an verschiedenen Forschungsinstituten. Das DLR verwendet es z. B. zur Untersuchung von Altlasten und archäologischen Fundstätten in der Kieler Förde (DLR 2021). Ein weiteres Forschungsprojekt der DLR untersucht mithilfe des SeaCat AUVs die automatische Objekterkennung aus Sonarbildern des AUVs mit Hilfe von Deep-Learning-Algorithmen (Steiniger et al. 2021).

In dem Projekt Zipangu of the Sea (Kangsoo und Kenkichi 2016) wird ein Fahrzeugverbund für die Untersuchung von großen Unterwasserregionen vorgestellt. Es besteht aus einem Mutterschiff, von dem ein USV und mehrere AUVs zu Wasser gelassen werden. Die Kommunikation und Lokalisierung zwischen dem USV und den AUVs erfolgt über akustische Modems. Mithilfe diverser Sensorik soll der Verbund hydrothermale Ablagerungen detektieren.

Ein weiteres Großprojekt wird in Rumson (2018) sowie Xu und Jiang (2021) beschrieben. Der Verbund besteht aus einem Mutterschiff und mehreren USVs, denen jeweils ein AUV zugeordnet ist. Der Gesamtverbund kann zu Wasser gelassen werden, um großräumige Missionen zu Erkundung und Aufnahme von Unterwasserregionen durchzuführen. Die Kommunikation verläuft bidirektional zwischen den USV-AUV-Paaren und übergeordnet zwischen den USVs und dem Mutterschiff.

Ein Demonstrator, bestehend aus einem kleinen USV und einem kleinen AUV, wird in Sarda und Dhanak (2016) vorgestellt. Das Projekt behandelt automatisierte Launch and Recovery Missionen. Darüber soll das USV in die Lage versetzt werden, das AUV zum Einsatzort zu transportieren und dort zu Wasser zu lassen. Nach der Missionsausführung des AUV wird dieses wieder vom USV aufgenommen und zurück zum Hafen transportiert.

## 4 Umsetzung

Zur Erreichung der Zielsetzung wurde das Projektvorhaben in fünf Teilprojekte untergliedert:

### 1. TP1: Kognitive Systemmodellierung

Entwicklung von Algorithmen zur Steuerung autonomer Unterwasserfahrzeuge. Das Einbinden diverser Sensorik zur Hindernis- und Abstandserkennung ist Ziel des Teilprojektes, wie die AUV-Positionsbestimmung unter und über Wasser.

### 2. TP2: Suchalgorithmen für kooperierende AUV

Entwicklung von Algorithmen zur schwarmbasierten Lokalisierung von unterseeischen Schadstoffaustritten mittels AUVs. Hierbei dienen verschiedene Umweltparameter, zum Beispiel die Temperatur, die Salinität oder die Fluoreszenz gelöster organischer Materie, als Indikator für austretende Schadstoffe.

### 3. TP3: Optische 3D-Messtechnik

Entwicklung eines kamerabasierten Multisensorsystems zur Positionierung, Navigation und Kartierung von unbemannten Unterwasserfahrzeugen. Besondere Herausforderungen sind neben den optischen Eigenschaften des Wassers auch die limitierten Platzverhältnisse, welche spezielle Lösungen für Stromversorgung, Kommunikation und Datenverarbeitung erfordern.

### 4. TP4: Datenmanagement

Entwicklung eines raumzeitlichen Datenmanagements für selbstfahrende Unterwasserfahrzeuge. Die bereits erfassten Daten der AUVs und des USV müssen jederzeit georeferenziert für die folgenden Missionsbedingungen abrufbar sein.

### 5. TP5: Einsatzfähiges autonomes USV

Entwicklung eines einsatzfähigen USV. Es werden Elektronikkomponenten für ein autonomes, unbemanntes Überwasserfahrzeug kombiniert, das als Kommunikations- und Versorgungsplattform für die anderen EITAMS-Teilprojekte verwendet werden.

Für die Zusammenführung der einzelnen Teildisziplinen in ein einheitliches, übertragbares Gesamtsystem wurden zunächst die grundsätzlichen Rahmenbedingungen festgelegt. Für die Unterwasseroperationen sind drei ROVs vom Typ BlueROV2 der Firma *Bluerobotics* eingesetzt worden. Diese wurden mit weiterer Hardware wie Kamerasystemen, GPS, Unterwasserkommunikation, Unterwasserpositionierungssystemen, Echolot, 360°-Sonar und akustischen

Ortungssystemen, und zusätzlichen Motoren ausgestattet. Die Basis des Überwasserträgers ist ein Katamaran, der mit Lang- und Kurzstreckenkommunikationssystemen, (RTK-)GNSS, Unterwasserkommunikation, Unterwasserpositionierungssystemen sowie Kameras erweitert wurde.

Die Positionsbestimmung der ROVs erfolgt über die Verwendung eines USBL-Positionierungssystem (ultrashort baseline) der Firma *EvoLogics*, über das auch eine Kommunikation mit den ROVs und dem USV realisiert wird. Für kleinere und unabhängige Versuchsfahrten der ROVs wird zudem ein SBL-Positionierungssystem (short baseline) der Firma *WaterLinked* verwendet (Abb. 1).

Als Grundlage für die Steuerungsarchitektur auf den ROVs und dem USV ist das LSTS-DUNE-Framework der Universität Porto (Pinto et al. 2013) zum Einsatz gekommen. Das LSTS-DUNE-Framework wurde in TP1 kompiliert und für die Verwendung in allen Teilprojekten als Grundsystem vorbereitet, bereitgestellt und sukzessive weiterentwickelt. Die DUNE-Steuerinstanzen der einzelnen Fahrzeuge können sich im gleichen Netzwerk registrieren und miteinander kommunizieren. Hierzu baut das System auf „Consumer“ und „Producer“ Tasks auf, die Nachrichten produzieren und im Netzwerk verteilen sowie auch Nachrichten anderer Tasks empfangen können. Das Senden der Nachrichten kann dabei lokal in der Steuerinstanz eines Fahrzeuges oder über das gesamte Netzwerk erfolgen. Die Kommunikation zwischen den einzelnen Modulen und den Fahrzeugen nutzt das IMC-Protokoll. Durch den taskbasierten Aufbau kann das System modular verwendet und erweitert werden. Das Framework ist unabhängig von der Plattform und der CPU-Architektur, sodass auch eine Übertragung des Systems auf andere Fahrzeuge möglich ist.

Über das verwendete Framework konnten die Teildisziplinen zum Teil unabhängig voneinander entwickelt, aber jederzeit gemeinsam getestet werden.

## 4.1 Teilprojekt 1 „Kognitive Systemmodellierung“

Hauptziel des Teilprojekts 1 war die Implementierung und Evaluation einer autonomen Steuerung von Unterwasservehikeln, welche auch unter nicht vorhersehbaren Bedingungen fehlertolerant agieren können. Dabei war u.a. eine multimodale Echtzeitdetektion von Objekten in der näheren Umgebung erforderlich. Durch eine kognitive Modellierung konnten Unterwasservehikel in die Lage versetzt werden, ihren Systemzustand zu erkennen und daraus dynamische Pläne zu erstellen, welche eine sichere Missionsausführung auch im Verbund mit anderen Fahrzeugen ermöglichen.

Parallel zu der Bereitstellung des LSTS-DUNE-Grundsystems wurde eine Visualisierungs- und Simulationsumgebung auf Basis der Unreal Game Engine (Unreal Engine 2022) für das Gesamtsystem entworfen und implementiert. So

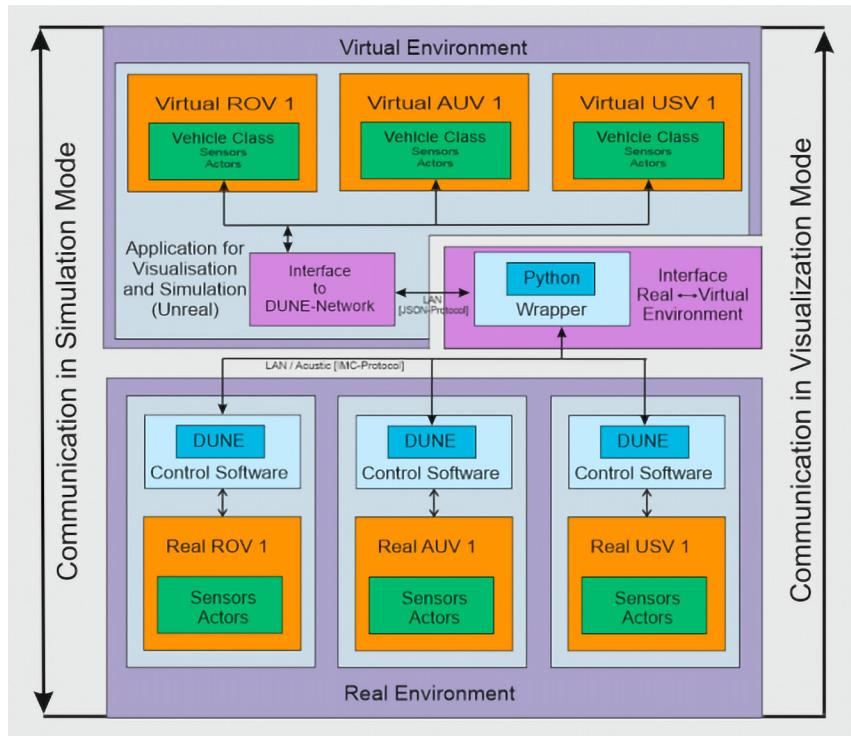


Abb. 2: Systemarchitektur der Kombination von Realfahrzeugen mit der Simulation- und Visualisierungsumgebung

können einfache und komplexere Abläufe vor den Realversuchen permanent in einer sicheren Umgebung vorab analysiert werden. Hierzu wurde, in Verbindung mit dem TP5, ein Python-Wrapper (pyEITAMS) entwickelt, der die IMC-Nachrichten des DUNE-Netzwerkes an die Simulationsumgebung weiterleitet. Auf diese Weise können die realen Fahrzeuge in der Visualisierung in Echtzeit dargestellt werden. Im nächsten Schritt wurde die Visualisierung zu einer Simulation weiterentwickelt, indem in der Game Engine Sensoren (Tiefensensor, GPS, Sonar, etc.) implementiert wurden, die die virtuellen Sensordaten via IMC-Nachrichten bidirektional über den pyEITAMS-Wrapper an das DUNE-Netzwerk und somit an die jeweiligen Fahrzeuge weiterleiten. Die realen Fahrzeuge können somit virtuellen Sensordaten versorgt, die Algorithmen getestet und das Ergebnis in der virtuellen Welt dargestellt werden (Abb. 2) (Neiß-Theuerkauff et al. 2017, 2018). Die Implementierung der Simulationsumgebung wurde an das DUNE-Framework angepasst, sodass die Einbindung neuer Sensorik auch in Zukunft abbildungbar ist.

Für die Entwicklung von missionsbedingten Steuerungsalgorithmen für Fahrzeuge stellt das DUNE-Framework bereits eine grundlegende Struktur bereit. Um diese nutzen zu können, wurde zunächst ein Steuerungsmodul implementiert, welches den BlueROV2 im dreidimensionalen Raum steuern kann. Vier vektoriell angeordnete Motoren steuern dabei die Bewegung in der X-Y-Ebene (Speed, Heading). Weitere vier Motoren steuern die Bewegung in der Z-Ebene (Depth, Roll, Pitch).

Nach der Implementierung der ROV-Steuerung wurde Sensorik für eine autonome Navigation in die Steuerungsarchitektur integriert. Hierzu zählt ein GPS-Sensor für Fahrten an der Wasseroberfläche sowie zwei Systeme für die Positionsbestimmung (*EvoLogics (USBL)* und *WaterLinked (SBL)*) unter Wasser (Abb. 1). Die Steueralgorithmen erkennen durch eine Priorisierung selbstständig, welche Koordinaten verwendet werden müssen. Zur Grundkontaktvermeidung und zum Halten einer Höhe über Grund wurde ein Echolot in das System eingebunden. Die Kollisionsvermeidung mit umliegenden Objekten wurde mittels der Einbindung eines 360°-Sonar-Systems umgesetzt. In der ersten Implementierung kann das Fahrzeug Hindernisse detektieren, welche das Erreichen fixer oder dynamischer Zielkoordinaten verhindert. Kann ein Hindernis nicht umfahren werden, startet das Fahrzeug die Routine zur Erreichung eines Safe-States, welches das Auftauchen des Fahrzeugs und die Ansteuerung der Heimatkoordinaten bedeutet.

## 4.2 Teilprojekt 2 „Suchalgorithmen für kooperierende AUV“

Das Teilprojekt 2 zielt darauf ab, Suchstrategien für Schwärme von AUVs zu entwickeln, um unterseeische Suchaufgaben effizient und effektiv zu lösen. Motiviert durch den Erfolg populationsbasierter Suchmethoden bei der Lösung realer Probleme sollten diese Methoden der künstlichen Intelligenz hinsichtlich ihrer Verwendbarkeit auf die aktuelle Aufgabenstellung untersucht werden.

Im ersten Schritt wurde ein Anwendungsszenario gemeinsam mit dem Kooperationspartner Institut für Chemie und Biologie des Meeres (ICBM) der Universität Oldenburg definiert. Es besteht darin, dass ein Schwarm von AUVs einen unterseeischen Grundwasseraustritt lokalisieren soll. Hierbei dient die Temperatur als Indikator für das austretende Grundwasser. Der Grundwasseraustritt befindet sich in einem Areal von  $400\text{ m} \times 400\text{ m}$ . In dem Szenario wird angenommen, dass dieses Gebiet bereits durch luftgestützte Fernerkundung identifiziert wurde (Tholen et al. 2018).

Aufbauend auf dem definierten Anwendungsszenario wurde eine Simulationsumgebung für die Bewertung der zu entwickelnden Suchstrategien implementiert. Im Rahmen der Simulationen wurden verschiedene statische und

dynamische Fitnessfunktionen für die Bewertung der Suchstrategien entwickelt und evaluiert. Um den Einfluss von Kommunikations- und Lokalisierungsfehlern auf die Performanz der Suchalgorithmen zu untersuchen, können solche Fehler in die Simulation eingebracht werden.

Mit Hilfe der Simulationsumgebung wurden verschiedene Suchalgorithmen entwickelt und bewertet: Blind-Search (El-Mihoub et al. 2020, Self-Adaptive Levy-flight (Tholen et al. 2018) sowie Inertia Levy-flight (Tholen et al. 2018). Es konnte im Rahmen der Simulationen gezeigt werden, dass die entwickelten Suchstrategien den etablierten Suchmustern in Bezug auf die Suchgeschwindigkeit und den Sucherfolg in vielen Szenarien überlegen sind. Bei den populationsbasierten Varianten haben Lokalisierungsfehler und Kommunikationsausfälle negative Auswirkungen auf die Performanz der Algorithmen. Zusätzlich wurde das Worst-Case-Szenario eines vollständigen Kommunikationsausfalls simuliert (El-Mihoub et al. 2018). In diesem Fall wechseln die AUVs in einen neuen Suchmodus, in welchem sie unabhängig vom Rest des Schwarmes operieren können.

Um die entwickelten Suchstrategien auf den zur Verfügung stehenden Fahrzeugen einsetzen zu können, wurde das eingesetzte DUNE-Framework um einzelne Module für die jeweiligen Suchstrategien und um Module zur Einbindung spezifischer Sensorik erweitert. Die Kommunikation mit den anderen Fahrzeugen schaltet, je nach externen Sensorwerten, Auftrag und Einstellung, die einzelnen Suchstrategien zu. Die durch die Suchstrategien berechneten Koordinaten werden als neue Wegpunkte von den Steueralgorithmen verarbeitet.

### 4.3 Teilprojekt 3 „Optische 3D-Unterwassermesstechnik“

In diesem Teilprojekt wurde ein optisches Multisensorsystem, bestehend aus drei automatisierbaren, hochauflösenden Kameras und zusätzlicher Low-Cost-Sensorik (Inertiale Messeinheit, Short Baseline Positionierung, Thermometer, Barometer, Leitfähigkeitssensor) entwickelt (Rofalski und Luhmann 2018). Aufgrund hoher Datenmengen der Kameras wurde die Daten- und Stromverbindung über ein Ethernetkabel zu einem Rechner an der Oberfläche realisiert. Zur Positionierung wurden drei Kameras mit vor- und rückblickendem Sichtfeld am ROV angebracht und mithilfe verschiedener Auswerteverfahren verarbeitet, sodass in Kombination mit den zusätzlichen Sensoren eine stabile Position geschätzt werden kann. Das Dreikamerasytem bietet den Vorteil, eine robustere geometrische Basis zu schaffen, als es bei vergleichbaren Systemen mit zwei (Stereo) Kameras der Fall ist, um so zeitabhängige Driften zu vermeiden. Das Kamerasytem ist modular aufgebaut und lässt sich flexibel sowohl in den Blue-ROV2 als auch in beliebige andere Unterwasserplattformen integrieren (siehe Abb. 1 und 2). Eine eigens entwickelte Auslösung und zentrale Datenverwaltung

auf einem Einplatinenrechner gewährleisten einerseits die Synchronisierung der drei Kameras untereinander und bietet andererseits eine Schnittstelle zur Integration weiterer Sensoren. Die bislang kabelgebundene Variante soll perspektivisch durch eine kabellose Variante ersetzt werden, um höhere Flexibilität in Anwendungen und Integration in andere Plattformen zu erreichen. Simulationen zur erreichbaren Genauigkeit eines Mehrkamerasystems wurden in Kahmen et al. (2019, 2020) publiziert. Besonderer Schwerpunkt der Analysen und Simulationen war der Einfluss einer Mehrmedienkalibrierung für unterschiedliche Kameraanordnungen. Auch wurde diskutiert, welche Genauigkeit von der Vernachlässigung des Mehrmedienfalls zu erwarten wäre. Es konnte hier gezeigt werden, dass für mittlere bis geringe Genauigkeitsanforderungen und homogene Objektdistanzen auch Standardauswerteverfahren hinreichende Qualitäten erzeugen. Sobald Objektdistanzen stark variieren (einige Dezimeter bis mehrere Meter) oder höchste Genauigkeitsanforderungen <1 mm herrschen, ist eine explizite Modellierung des Mehrmedienfalls unumgänglich. Weiterhin ist bei der Kalibrierung zu beachten, dass die erwartete Objektentfernung bei der in-situ Aufnahme bereits bei der Kalibrierung hinreichend abgedeckt wird, um ein vollständiges Abbild der Aufnahmesituation zu erhalten.

Zur Berücksichtigung der Strahlbrechung wurde eine Bündelausgleichung mit expliziter Modellierung des Mehrmedienfalls nach dem Raytracing-Ansatz von Mulsow (2010) entwickelt. Die Software wurde objektorientiert in C++ geschrieben und fügt sich in die bestehende Softwarebibliothek am Institut für Angewandte Photogrammetrie und Geoinformatik (IAPG) nahtlos ein. Durch Nutzung einer leistungsfähigen Optimierungsbibliothek (Agarwal 2021) konnte die ansonsten sehr hohe Rechenzeit maßgeblich reduziert und so auch große Gleichungssysteme mit mehreren tausend Beobachtungen und Unbekannten in wenigen Minuten (Mehrmedienfall) oder Sekunden (Standardmodell) gelöst werden.

#### 4.4 Teilprojekt 4 „Datenmanagement“

Auf AUVs existiert der Bedarf nach einem effizienten Datenmanagementsystem, das die Verarbeitung und Verwaltung von speicher- und rechenintensiven Geodaten erlaubt. Daher wurde in EITAMS eine verteilte Systemarchitektur für ein raumzeitliches Datenmanagement entworfen, entwickelt und evaluiert.

Für die räumliche Datenverwaltung auf den AUVs wird die Datenbankengine „SQLite“ verwendet. Gemeinsam mit der Geo-Erweiterung „SpatiaLite“ steht damit ein einbettbares System zur Verarbeitung von räumlichen (Sensormess-) Daten auf einem Unterwasserfahrzeug zur Verfügung. Dieser Ansatz erlaubt die Sortierung von Daten nach räumlichen Kriterien und ermöglicht die effiziente

Ausführung räumlicher Basisanfragen. Beispielsweise stehen für das Auffinden von bislang nicht untersuchten Geländeabschnitten oder die Identifizierung der nächstgelegenen Knoten in einem Unterwassersensornetzwerk entsprechende Datenbankoperatoren bereit.

Das dabei definierte Datenschema orientiert sich am OGC-Standard „Sensor-Things API“ und führt eine spatio-temporale Organisationsstruktur ein. Durch den Einsatz standardkonformer Komponenten steht mit „Well-Known Binary“ (WKB) ein spezifiziertes Austauschformat bereit, das die Synchronisierung räumlicher Daten mit der zentralen Instanz vereinheitlicht.

Sensormessdaten gehen oftmals nahezu in Echtzeit und miteinander verknüpft in die Missionsplanung und Fahrzeugsteuerung ein. Auf die effiziente Verarbeitung solcher Datenströme ist eine herkömmliche Geodatenbank nicht ausgelegt. Dazu wurde eine SQLite-Erweiterung entwickelt (Werner und Brinkhoff 2018). Sie spezialisiert sich auf die Verarbeitung von Datenströmen und ergänzt das bestehende System um Datenstrukturen und spezielle Abfrageoperatoren. Diese Operatoren verarbeiten gegenüber den konventionellen Datenbankoperatoren Datensätze sequenziell. Dabei werden Datensätze einmalig ausgewertet und anschließend entweder verworfen oder gespeichert. Eine Auswertung der abgelegten Datenbasis ist somit nicht mehr notwendig. Besonders Aufgaben, bei denen eine wiederholte Ausführung identischer Abfragen notwendig ist, profitieren von dieser Methodik.

Der Raumbezug wird dabei unter der Verwendung der Spezifikation „Tiny Well-known Binary“ (TWKB) hergestellt. Für raumbezogene Datenströme wurden insbesondere sechs neuartige Operatoren entwickelt, die fensterbasiert arbeiten (Werner und Brinkhoff 2020). Beispielhaft kann dies dazu dienen, um auf AUV-Sensormessdaten mit geschwindigkeitsbedingten Dichteunterschieden diese in einfacher Weise auszugleichen.

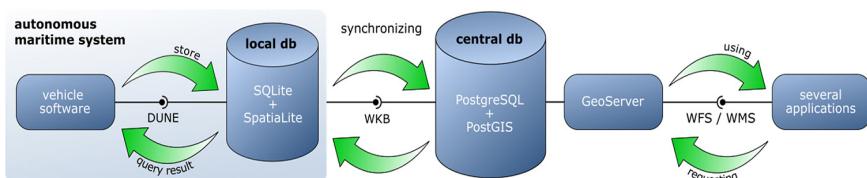


Abb. 3: Systemarchitektur

Im Rahmen einer Mission können alle Sensormessdaten unter Verwendung standardisierter Geodatenformate mit einer zentralen Datenbasis synchronisiert werden: Eine zentrale PostgreSQL-Datenbank sammelt die verorteten Sensormessdaten und Beobachtungen der Unterwasserfahrzeuge und verarbeitet diese mithilfe der Geodatenbankerweiterung „PostGIS“. Ein angebundener Geoserver

stellt mit Geodiensten standardisierte Schnittstellen zum Austausch und Integration der Datenbasis in weiterführende Anwendungen bereit.

Zwecks Evaluation wurden der Datenmanagementkomponente Daten wie Salzgehalt, Temperatur und Druck aus den anderen EITAMS-Teilprojekten aus verschiedenen Messkampagnen zugeführt. Darauf aufbauend können weiterführende Anwendungen mithilfe von Geodiensten die Daten einbinden und beispielsweise für Analysen verwenden (Abb. 3).

#### 4.5 Teilprojekt 5 „Einsatzfähiges USV“

Ziel des Teilprojekts 5 war die Entwicklung und Erprobung eines autonomen Überwasserfahrzeugs, das vielfältige Aufgaben im Fahrzeugverbund übernimmt. Realisiert wurde der Geräteträger auf Basis eines „emma BOSS-Katamarans“, der durch mechanische Umbauten und Erweiterungen für den Einsatz im Seegang ertüchtigt wurde (Abb. 4). Das Fahrzeug wurde weiterhin so ausgerüstet, dass es in Gewässern mit Schiffsverkehr sicher eingesetzt werden kann (Navigationslichter etc.). Die Steuerungssoftware des USV beruht auf der im Projekt einheitlich verwendeten Systemarchitektur auf Basis LSTS-DUNE-Framework, in das neben den Schiffsantrieben verschiedene Sensoren und Kommunikationseinrichtungen eingebunden sind.

Die für das Gesamtsystem wesentliche Positionsbestimmung der AUV und die Unterwasserkommunikation wird über ein USBL-Positionierungssystem der Firma *EvoLogics* abgewickelt. Um die auch im autonomen Einsatz notwendige

- 1) Primärer GPS-RTK-Empfänger
- 2) Echolot-Steuergerät, Sekundärer GPS-Empfänger
- 3) Accelerometer, Gyroskop, Magnetkompass
- 4) Sensor-Ethernet-Schnittstellenmodul
- 5) Linux-Bordrechner
- 6) Antriebs-Ethernet-Schnittstellenmodul
- 7) Antriebs-Leistungstechnik
- 8) Echolotsonde
- 9) Antrieb Backbord
- 10) Antrieb Steuerbord
- 11) 14V Akku 1
- 12) 14V Akku 2

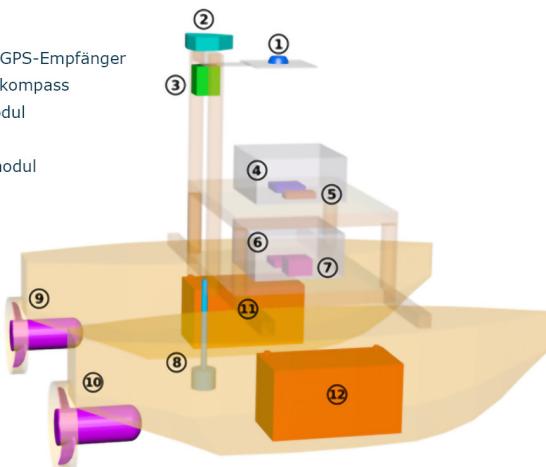


Abb. 4: 3D-Ansicht mit den Bestandteilen der ersten Ausbaustufe des USV (ohne USBL)

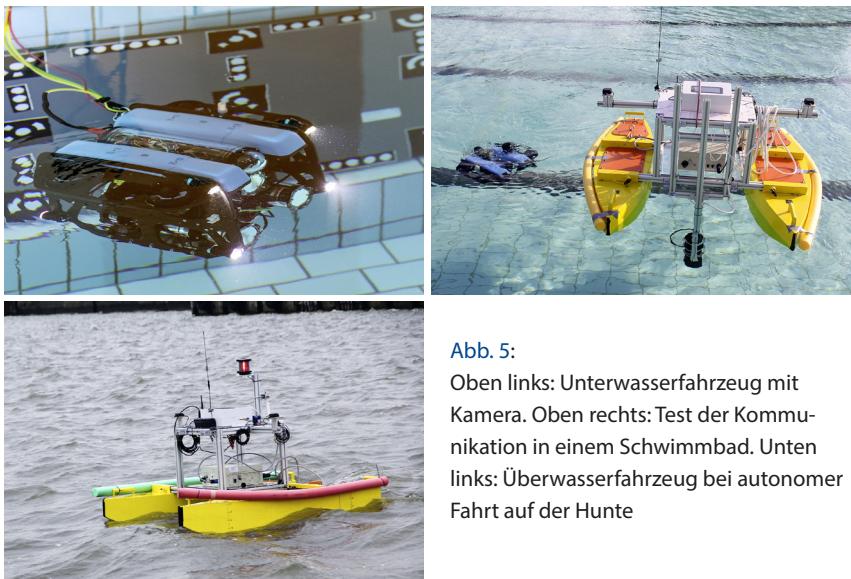
Kontrolle über die Fahrzeuge zu behalten, kann das USV auf verschiedene Arten mit externen Systemen kommunizieren. Diese bidirektionale Kommunikation nach außen erfolgt im Nahbereich über ein eigenes mobiles, leistungsfähiges WLAN-Outdoor-Netzwerk mit 300 bis 450 Metern Reichweite. Für die Langstreckenkommunikation ist ein Modem für das öffentliche Mobilfunknetz eingebunden. Der praktische Einsatz des Systems wird durch speziell entwickelte Kommunikationspylone wesentlich vereinfacht, die, an einem festen Ort aufgebaut, als Relaisstation wirken und mit zusätzlicher eigener Sensorik sowie einer Kamera eine Remote-Überwachung der Operation erlauben.

Zur Navigation werden GNSS und lokale Sensoren (Fluxgate-Magnetkompass, Drehraten- und Beschleunigungssensoren) verwendet. Die höchste Genauigkeit der Positionierung wird mit dem in das USV integrierten RTK-System (Real Time Kinematik) erreicht. Hier werden Korrekturdaten des Satellitenpositionierungsdienstes SAPOS verwendet, um die Genauigkeit der Navigation zu verbessern. Die Korrektur kann bei bestehender Internetverbindung in Echtzeit erfolgen; damit kann eine Positionsgenauigkeit im Zentimeterbereich erreicht werden. Ohne Internetverbindung ermöglicht ein in EITAMS implementiertes Moving-Base-Verfahren, in dem der Kommunikationspylon als Referenzstation fungiert, ebenfalls eine zentimetergenaue Positionsbestimmung des USVs. Neben den satellitengestützten Navigationsmitteln enthält der Geräteträger eine inertiale Messplattform, mit der das Tauchen, Stampfen und Rollen sowie die linearen Geschwindigkeiten und Beschleunigungen des Fahrzeugs gemessen werden.

Durch den modularen Aufbau der Hard- und Softwarearchitektur konnte der vorhandene ADANAV-Regler leicht in das System integriert werden. Es können zu Forschungszwecken aber auch andere Regler mit geringsten Rüstzeiten erprobt werden. Die Regelung wurde in umfangreichen Labor- und Revierversuchen parametrisiert und getestet.

## 5 Ergebnisse und Zusammenfassung

Die Arbeiten der Teilprojekte wurden fortlaufend in verschiedenen Szenarien getestet und evaluiert (Abb. 5). Neben gemeinsamen Versuchen in Hallen- und Schwimmbädern, Binnengewässern und offener See wurden die Einzelsysteme auch unabhängig voneinander eingesetzt. In Fließgewässern waren die angedachten prototypischen Versuchsfahrten mit dem BlueROV2 aufgrund der zu starken Strömungen nur sehr schwer realisierbar. Durch den modularen Aufbau der Steuerungsarchitektur ist eine Übertragung der implementierten Algorithmen auf größere und leistungsfähigere Versuchsträger in Folgeprojekten jedoch gegeben.

**Abb. 5:**

Oben links: Unterwasserfahrzeug mit Kamera. Oben rechts: Test der Kommunikation in einem Schwimmbad. Unten links: Überwasserfahrzeug bei autonomer Fahrt auf der Hunte

Auf allen Vehikeln wurde die in TP1 bereitgestellte Steuerungssoftware für den übergreifenden Austausch aller Informationen verwendet. Eine Kommunikation zwischen dem Schwarm der AUVs und dem USV wurde erfolgreich implementiert. Der Datenaustausch kann dabei drahtgebunden oder drahtlos über ein USBL-Modem der Firma *EvoLogics* (*EvoLogics* 2022) erfolgen. Die Positionsbestimmung der ROVs unter Wasser wurde zusätzlich zum USBL-Modem über ein SBL-System (*Waterlinked UGPS* 2022) realisiert. Weitere Sensorik zur Navigation, wie z. B. das Ping1d Echolot und das bildgebende Ping360 Sonar (*BlueRobotics* 2022a, 2022b) sowie die in TP2 verwendeten Detektoren für spezielle Chemikalien, wurden ebenfalls in das Framework eingebunden.

Die Steuerungskomponenten der ROVs wurden fortlaufend an die im Projektverlauf neu hinzukommenden Sensorkomponenten angepasst, um die Fähigkeiten der ROVs zu erweitern. Die Steuerungssoftware ist in der Lage, vordefinierte Trajektorien in z. B. einer bestimmten Höhe über Grund abzufahren. Dabei wählt die Steuerungssoftware automatisch die je nach Umgebungsbedingungen (z. B. Über- oder Unterwasserfahrt) am besten zur Navigation geeigneten Sensoren aus. Im nächsten Schritt konnten dynamische Missionen wie Leader-Follower-Missionen umgesetzt werden.

Des Weiteren kann die Steuerungssoftware auf dynamische Veränderungen der Missionspläne reagieren. Damit können der Steuerungseinheit z. B. anzu-fahrende Koordinaten aus TP2 zur autonomen Schadstoffdetektion übergeben werden. Diese werden unabhängig von der Steuerungssoftware berechnet und

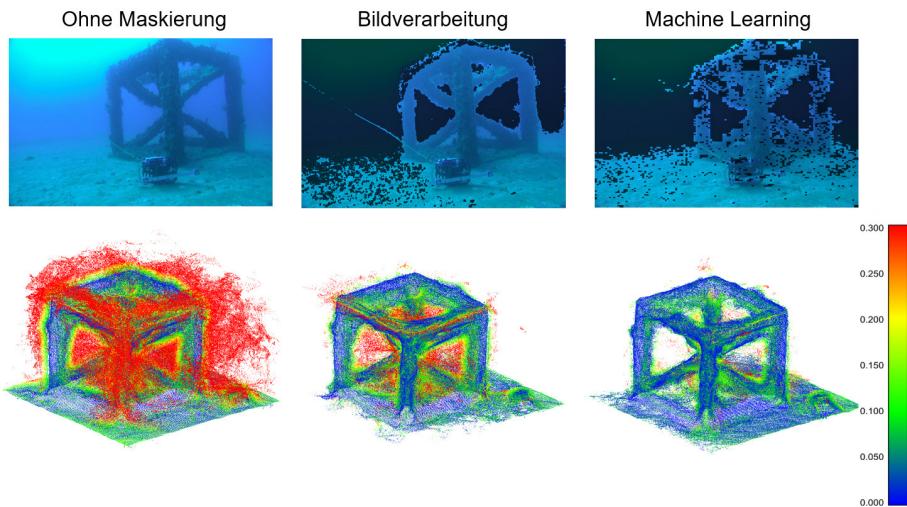
dynamisch von externen Prozessen übergeben. Bei Nichtausführbarkeit steuert das ROV automatisiert einen Safe-State an.

Darüber hinaus wurde eine Schnittstelle zur Unreal Simulationsengine erstellt (Unreal Engine 2022). Hiermit können Missionen zunächst in virtuellen Umgebungen erprobt werden, um die zeitintensiven und fehleranfälligen Realversuche vorzubereiten (Neiß-Theuerkauff et al. 2017, 2018).

Im Rahmen von Experimenten im Hallenbad kann gezeigt werden, dass die Implementierung der Integration von Suchalgorithmen aus TP2 in das Gesamtframework wie erwartet funktioniert. Die Suchalgorithmen berechnen auf Basis der Sensordaten neue Wegpunkte und geben diese an die Steuermodule weiter. Nach Erreichen eines Wegpunktes werden automatisiert neue Wegpunkte berechnet.

Die optische 3D-Unterwassermesstechnik wurde wegen der starken Zugkräfte der notwendigen Kabelverbindung zur Datenübertragung weitgehend eigenständig getestet. Untersuchungen in Gewässern fanden zunächst in kontrollierter Umgebung (Lehrschwimmbecken, Aquarium) statt, um Kalibrierverfahren und Algorithmen testen und untersuchen zu können. Die Real-Erprobung fand anschließend in Gewässern mit unterschiedlichen optischen Eigenschaften statt. So wurden Teile des Kamerasystems auf ein ROV des Bundesamts für Seeschiffahrt und Hydrographie portiert und zur 3D-Aufnahme eines versunkenen Kutters in der Neustädter Bucht (Ostsee) eingesetzt (Rofalski et al. 2020b). Die Daten konnten mit schiffsbasierten Echolotdaten fusioniert werden und bieten großes Potenzial für künftige Entwicklungen. Weiterhin wurde das Gesamtsystem mit dem genutzten BlueROV2 in klaren Gewässern des Indischen Ozeans eingesetzt. In Kooperation mit der Curtin University in Perth wurden hier künstliche Riffe untersucht und vermessen (Rofalski et al. 2020a). Es konnten 3D-Rekonstruktionen der Riffe und deren biologischen Bewuchs erstellt und zusätzlich Verfahren zur automatisierten Maskierung für die Structure-from-Motion-Auswertung unter Wasser entwickelt werden (Abb. 6). Somit steht ein gewässererprobtes photogrammetrisches Messsystem zur Verfügung, welches für ein breites Spektrum an Anwendungen genutzt und auch auf andere Plattformen übertragen werden kann.

Das USV und die Kommunikationseinrichtungen wurden in all ihren Komponenten kontinuierlich in umfangreichen Tests in Schwimmbädern und Binnengewässern, aber auch auf Schifffahrtsrevieren (Hunte) erprobt. Die Steuerung des USV erlaubt es, Wegepunkte mit vorgegebener Geschwindigkeit anzufahren und Positionen auch unter dem Einfluss von Wasserströmung zu halten. Es sind ebenfalls Fahrten mit vorgegebenem Kurs und Geschwindigkeit möglich. Die Kursvorgaben der Regelung können automatisch z. B. aus den im Teilprojekt 2 entwickelten Modulen für die Suchalgorithmen übernommen werden. Die Positionsgenauigkeit des USV liegt abschließend im Zentimeterbereich.



**Abb. 6:** Verschiedene Maskierungen und resultierende Punktwolken aus den Aufnahmen des Multisensorsystems

Das Führungssystem PyEITAMS ermöglicht die Steuerung/Regelung aller im EITAMS-Verbund operierenden Fahrzeuge. Es ermöglicht einen Remote-Zugriff auf die Zustandsdaten der Vehikel und die Rohdaten der Sensoren. Auf einer höheren Ebene ermöglicht es die Kontrolle der Steuerungen. Schließlich können Missionen anwenderfreundlich z. B. mit Unterstützung durch Google Earth oder der Open-Source-Software openCPN geplant, übertragen und durchgeführt werden.

Das entwickelte Gesamtsystem ist modular und architekturunabhängig aufgebaut, so dass eine Überführung des Demonstrators auf zukünftige Projekte gegeben ist. Mit dem Projekt EITAMS konnte somit die Grundlage für vielseitig einsetzbare, kostengünstige Systeme zur autonomen Analyse und Überwachung von Unterwasserregionen entwickelt werden.

## Literatur

- Agarwal (2021): Agarwal. Unter Mitarbeit von K. Mierle und Others. <http://ceres-solver.org>, letzter Zugriff 07/2022.
- Atlas Elektronik (2022): Technical Overview. Website. Hg. v. Atlas Elektronik. [www.atlas-elektronik.com/solutions/mine-warfare-systems/seacat.html](http://www.atlas-elektronik.com/solutions/mine-warfare-systems/seacat.html), letzter Zugriff 07/2022.
- BlueRobotics (2022a): Product Description of Ping Sonar Altimeter and Echosounder. <https://bluerobotics.com/store/sensors-sonars-cameras/sonar/ping-sonar-r2-rp/>, letzter Zugriff 07/2022.

- BlueRobotics (2022b): Product Description of Ping360 Scanning Imaging Sonar. <https://bluerobotics.com/store/sensors-sonars-cameras/sonar/ping360-sonar-r1-rp/>, letzter Zugriff 07/2022.
- DLR (2021): DLR untersucht Altlasten und archäologische Fundstätten in der Kieler Förde. Hg. v. DLR. Institut für den Schutz maritimer Infrastrukturen. [www.dlr.de/mi/desktopdefault.aspx/tabcid-12121/21336\\_read-73416](http://www.dlr.de/mi/desktopdefault.aspx/tabcid-12121/21336_read-73416), letzter Zugriff 07/2022.
- El-Mihoub, T., Tholen, C., Nolle, L. (2018): Blind Search Patterns For Off-Line Path Planning. In: Proceedings, 32nd European Conference on Modelling and Simulation ECMS 2018. DOI: [10.7148/2018-0121](https://doi.org/10.7148/2018-0121).
- EvoLogics (2022): EvoLogics Dokumentation. <https://evologics.de/usbl>, letzter Zugriff 07/2022.
- GEOMAR (2017): Remotely Operated Vehicle „ROV KIEL 6000“. Helmholtz-Zentrum für Ozeanforschung Kiel. In: Journal of large-scale research facilities 3 (3), Artikel A117. DOI: [10.17815/jlsrf-3-160](https://doi.org/10.17815/jlsrf-3-160).
- Kahmen, O., Rofalski, R., Conen, N., Luhmann, T. (2019): On Scale Definition within Calibration of Multi-Camera Systems in Multimedia Photogrammetry. In: ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences. DOI: [10.5194/isprs-archives-XLII-2-W10-93-2019](https://doi.org/10.5194/isprs-archives-XLII-2-W10-93-2019).
- Kahmen, O., Rofalski, R., Luhmann, T. (2020): Impact of Stereo Camera Calibration to Object Accuracy in Multimedia Photogrammetry. In: Remote sensing. DOI: [10.3390/rs12122057](https://doi.org/10.3390/rs12122057).
- Kangsoo, K., Kenkichi T. (2016): The Zipangu of the Sea Project Over-view: Focusing on the R&D for Simultaneous Deployment and Operation of Multiple AUVs. In: Day 1 Tue, March 22, 2016. Offshore Technology Conference Asia. Kuala Lumpur, Malaysia, 22.03.2016–25.03.2016: OTC.
- Mulsow C. (2010): A FLEXIBLE MULTI-MEDIA BUNDLE APPROACH. In: Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci. XXXVIII/5, 472–477.
- Neiß-Theuerkauff, T., Korte-Wagner, Y., Wallhoff, F. (2018): Realtime Simulation And 3D-Visualisation Of Surface And Underwater Vehicles For Monitoring And Evaluating Autonomous Missions. In: Proceedings, 32nd European Conference on Modeling and Simulation ECMS 2018. DOI: [10.7148/2018-0129](https://doi.org/10.7148/2018-0129).
- Neiß-Theuerkauff, T., Werner, T., Wallhoff, F., Brinkhoff, T. (2017): 3D-Visualisierung von Über- und Unterwasserfahrzeugen zur Evaluation von Steuerungsalgorithmen mithilfe einer Game-Engine. In: Go-3D 2017: Mit 3D Richtung Maritim 4.0. Stuttgart: Fraunhofer Verlag, 2017.
- Pinto, J., Dias, P.S., Martins, R., Fortuna, J., Marques, E., Sousa, J. (2013): The LSTS tool-chain for networked vehicle systems. In: 2013 MTS/IEEE OCEANS – Bergen. 2013 MTS/IEEE OCEANS. Bergen, 10.06.2013–14.06.2013: IEEE, 1–9.
- Rofalski, R., Luhmann, T. (2018): Fusion von Sensoren mit optischer 3D-Messtechnik zur Positionierung von Unterwasserfahrzeugen. In: DVW e.V. (Hrsg.): Hydrographie 2018 – Trend zu unbemannten Messsystemen. DVW-Schriftenreihe, Band 91, Wißner-Verlag, Augsburg, 223–234.
- Rofalski, R., Tholen, C., Helmholz, P., Parnum, I., Luhmann, T. (2020a): Measuring artificial reefs using a multi-camera system for unmanned underwater vehicles. In: Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci. XLIII-B2-2020, 999–1008. DOI: [10.5194/isprs-archives-XLIII-B2-2020-999-2020](https://doi.org/10.5194/isprs-archives-XLIII-B2-2020-999-2020).

- Rofalski, R., Westfeld, P., Nistad, J.-G., Büttner, A., Luhmann, T. (2020b): Fusing ROV-based photogrammetric underwater imagery with multibeam soundings for reconstructing wrecks in turbid waters. In: Journal of Applied Hydrography (116), 23–31.
- Rumson A. (2018): Mapping the Deep Ocean with Multiple AUVs. Hg. v. Hydro International. [www.hydro-international.com/content/article/mapping-the-deep-ocean-with-multiple-auvs](http://www.hydro-international.com/content/article/mapping-the-deep-ocean-with-multiple-auvs), letzter Zugriff 07/2022.
- Sarda, E., Dhanak, M. R. (2016): A USV-Based Automated Launch and Recovery System for AUVs. In: IEEE J. Oceanic Eng., 1–19. DOI: [10.1109/JOE.2016.2554679](https://doi.org/10.1109/JOE.2016.2554679).
- Steiniger, Y., Groen, J., Stoppe, J., Kraus, D., Meisen, T. (2021): A study on modern deep learning detection algorithms for automatic target recognition in sidescan sonar images. In: 6th Underwater Acoustics Conference and Exhibition. 6th Underwater Acoustics Conference and Exhibition. Virtual Meeting, June 20–25, 2021: ASA (Proceedings of Meetings on Acoustics), S. 70010.
- Tholen, C., El-Mihoub, T., Nolle, L. (2018): On A Novel Search Strategy Based On A Combination Of Particle Swarm Optimisation And Levy-Flight. In: Proceedings, 32nd European Conference on Modelling and Simulation ECMS 2018. DOI: [10.7148/2018-0190](https://doi.org/10.7148/2018-0190).
- Unreal Engine (2022): Unreal Engine Datenblatt. [www.unrealengine.com/en-US/](http://www.unrealengine.com/en-US/), letzter Zugriff 07/2022.
- Waterlinked UGPS (2022): Firmenwebsite. [www.waterlinked.com/underwater-gps](http://www.waterlinked.com/underwater-gps), letzter Zugriff 07/2022.
- Werner, T., Brinkhoff, T. (2018): Managing Spatio-Temporal Data Streams on AUVs. In: 2018 IEEE OES Autonomous Underwater Vehicle. (Piscataway, NJ): IEEE, 2018.
- Werner, T., Brinkhoff, T. (2020): Window Operators for Processing Spatio-Temporal Data Streams on Unmanned Vehicles. In: Proceedings of the 23th AGILE Conference on Geographic Information Science. DOI: [10.5194/agile-giss-1-21-2020](https://doi.org/10.5194/agile-giss-1-21-2020).
- Xu, H., Jiang, C. (2021): Heterogeneous oceanographic exploration system based on USV and AUV: a survey of developments and challenges. In: Journal of University of Chinese Academy of Sciences 38 (2), 145–159. DOI: [10.7523/j.issn.2095-6134.2021.02.001](https://doi.org/10.7523/j.issn.2095-6134.2021.02.001).

## Kontakt

Tobias Neiß-Theuerkauff, M. Sc.  
Jade Hochschule Oldenburg  
Ofener Straße 16/19, 26121 Oldenburg  
[neiss-theuerkauff@jade-hs.de](mailto:neiss-theuerkauff@jade-hs.de)



# **RoboVaaS (Robotic Vessels as a Service) und seine Evolution – das modulare ASV SeaML:SeaLion als Multisensor-Trägersystem**

Vincent E. Schneider

## **1 RoboVaaS – Entwicklung von Trägerplattform und Dienstleistungsarchitektur**

Die Miniaturisierung von Sensoren und deren Kombination in Multisensor-systemen hat eine Vielzahl von vorher unrealisierbaren Anwendungen geschaffen. So ist beispielsweise das Zusammenspiel der Entwicklung kompakter Steuerungs- und Ortungselektronik sowie der Miniaturisierung hochpräziser hydrographischer Instrumente eine der Grundlagen für die Gewässertiefen-bestimmung mittels kleiner autonomer Fahrzeuge als Plattformen für Multisensorsysteme. Die sogenannten Autonomous Surface Vehicle (ASV) bieten eine Vielzahl von Einsatzzwecken, so zum Beispiel automatisierte und routine-mäßige hydrographische Vermessungen. Hier ist unter anderem die „Echo.1“ der Hamburg Port Authority (HPA) zu nennen, welche seit Frühling 2020 im Hydrographie-Abteilung des Hafens im Einsatz ist und mit einem Kongsberg Fächerecholot zur Kartierung ausgestattet ist (hamburg.de 2020). Eine der Herausforderungen bei dem Einsatz von ASV für maritime Dienstleistungen wurde hier gut sichtbar – die Unterbringung der Messtechnik in dem 1,5 m langen ASV unter Berücksichtigung der Gewichtslimitierungen sowie das Erfüllen der sicherheitstechnischen Anforderungen (Thies und Lautenschläger 2022). Viele kommerzielle ASV wählen den Designansatz des Katamarans aufgrund höherer Stabilität und der ruderlosen Steuerung durch differentiellen Schub zweier Motoren. Auch ergeben sich durch die Freifläche zwischen den Rümpfen vielfältige Möglichkeiten Nutzlasten an Deck zu transportieren oder kontrolliert ins Wasser zu lassen (Schneider et al. 2020).

Genau diese Funktionalitäten waren im Projekt RoboVaaS (Robotic Vessels as a Service) gefragt, weshalb zwei in Eigenentwicklung gefertigte autonome Katamarane (die ASV „SeaML“ und „SeaML:SeaLion“, siehe Kapitel 3) eingesetzt wurden, um robotergestützte Dienstleistungen über bestehende Konzepte hinaus zu untersuchen. Innerhalb des dreieinhalbjährigen Projektes wurden unter Einbindung von Stakeholdern wie der HPA sowie Industrie- und Wissenschaftspartnern, fünf Dienstleistungen definiert, entwickelt und getestet. Von Anfang

an ebenfalls im Projekt verankert war die Präsentation und Demonstration der Projektergebnisse vor einem Fachpublikum, um so den Praxisbezug herzustellen (Schneider et al. 2020, Burmeister et al. 2021). Ziel dieses Betrags ist es, das Konzept der robotergestützten as-a-Service Lösungen des Projektes RoboVaaS am Beispiel der hydrographischen Vermessung vorzustellen. Weiterhin soll die Entwicklung sowie Evolution der Fraunhofer Test- und Demonstrationsplattformen SeaML sowie SeaML:SeaLion präsentiert werden. Abschließend werden die Eigenschaften als Multisensorplattform beleuchtet und an bestehenden Folgeprojekten aufgezeigt.

## 2 RoboVaaS am Beispiel des Hydrographie Services

Wie der Name RoboVaaS klar ausdrückt, sind der Dreh- und Angelpunkt des Projektes die Entwicklung und Demonstration von as-a-Service Konzepten, welche durch den Einsatz von robotischen Fahrzeugen auf und unter dem Wasser realisiert werden. Innerhalb des Projektes wurden fünf vielversprechende Services entwickelt, implementiert und getestet: 1) Echtzeit-Strandungsvermeidungsdienst, 2) Schiffsrumpfinspektion mittels ROV (Remotely Operated Vehicle) und ASV sowie 3) Kaimauerinspektion mittels ROV und ASV, 4) Hydrographische Tiefenmessungen und 5) Data Muling – eine akustische Mittelstrecken-Kommunikationstechnologie, die unter Wasser zum Einsatz kommt (Schneider et al. 2022). Im Kontext dieser Tagung sei hier kurz die RoboVaaS-Architektur erläutert, und beispielhaft die hydrographische Dienstleistung näher beschrieben.

Zur Realisierung der angedachten hafennahen Dienstleistungen wurde eine generelle Service-Infrastruktur mit drei Hierarchie-Ebenen entwickelt. Auf der *Nutzer-Ebene* kann eben dieser Nutzer (z. B. Hydrographie-Abteilung eines Hafens) eine Anfrage über die web-basierte Benutzeroberfläche stellen. Diese Anfrage wird über die RoboVaaS-Cloud an die *Software-Ebene* weitergeleitet, wo ein Server im Shore-Control-Center die Anfrage validiert, verarbeitet und freigibt. Danach wird der Auftrag an die *Fahrzeug-Ebene* weitergeleitet, wo einem Fahrzeug aus der robotischen Flotte der Auftrag zugewiesen wird. Diese Aufteilung erlaubt die einfache Skalierbarkeit des Gesamtsystems, eine sichere Kommunikation durch vorherige Registrierung und kontinuierliche Identifizierung der Nutzer im RoboVaaS-Netzwerk und eine getrennte Auftragserstellung und -ausführung. Der Nutzer kann dabei in Echtzeit die Ergebnisse des Auftrags einsehen oder im Nachhinein über die Web-Oberfläche auf die Daten zugreifen (**Abb. 1**).

Die beschriebene Softwarearchitektur erlaubt die Implementierung der fünf Dienstleistungen innerhalb der Web-Oberfläche, sodass Nutzer einen Dienst an-

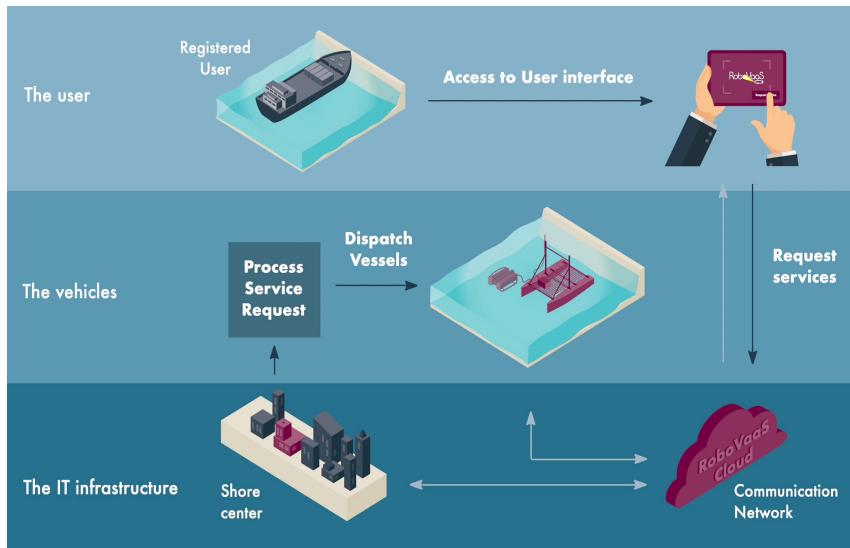


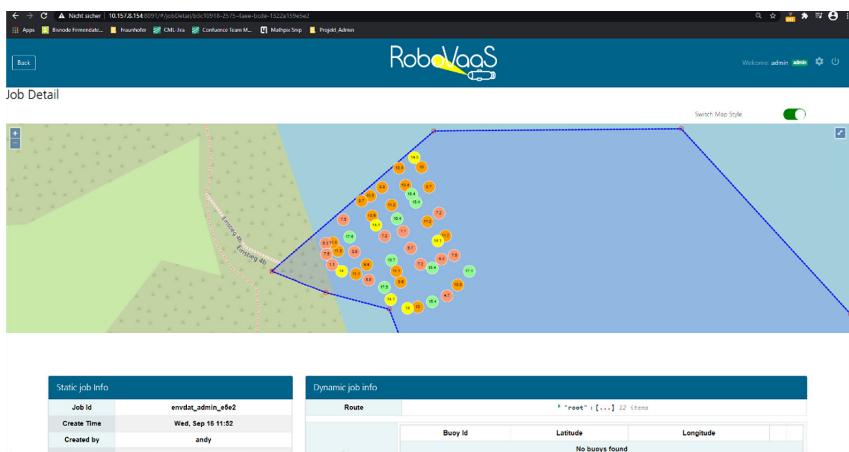
Abb. 1: Die RoboVaaS-Softwarearchitektur mit ihren drei Hauptebenen: dem Benutzer (oben), den Fahrzeugen (mittig) und der IT-Infrastruktur (unten)

legen, auslösen, die Durchführung überwachen und die Ergebnisse überprüfen können. Alle Services haben dabei eine direkte Verankerung in realen Anwendungsfeldern. So ist zum Beispiel die regelmäßige Kartierung von Gewässern mit hohem Verkehrsaufkommen in Industrienationen gewährleistet, jedoch machen Grundberührungen immer noch 20 % der Vorfälle (Allianz 2019). Dies macht eine regelmäßige Vermessung der Wassertiefe unerlässlich und ist besonders in tidebehafteten Gewässern und Häfen wie Hamburg von Bedeutung. Der Einsatz von ASV ist hier besonders geeignet, da durch die geringe Größe auch für größere Peilschiffe unzugängliche Gebiete entweder überhaupt oder auch bei geringem Wasserstand erreicht werden können. Innerhalb von RoboVaaS wurde daher diese Dienstleistung in die Benutzeroberfläche vollumfänglich integriert und mittels der Demonstrationsplattform SeaML die gesamte RoboVaaS Service Pipeline getestet (Schneider et al. 2022). Zur Datenaufnahme wurde hier das SeaML mit einem Einstrahl-Echolot ausgerüstet (Abb. 2), um exemplarisch Tiefendaten aufzuzeichnen. In der Endanwendung kann hier ein Fächerecholot zur flächendeckenden Datenerfassung zum Einsatz kommen. Wichtig war die komplette Pipeline zu testen, um so die Gesamtfunktionalität der RoboVaaS Dienstleistung zu validieren. Am Testort wurde die gesamte IT-Infrastruktur in mobiler Form aufgesetzt, samt Shore Control Center, RoboVaaS Server sowie Browser-basierter Nutzerschnittstelle zur Erstellung und Überprüfung der Testläufe. Insgesamt wurden 27 komplett und erfolgreiche Testläufe von RoboVaaS

Dienstleistungen durchgeführt, wobei 8 davon der Hydrographie-Anwendung zuzurechnen sind und 17.000 valide Datenpunkte (Abb. 3) erhoben wurden (Schneider et al. 2022).



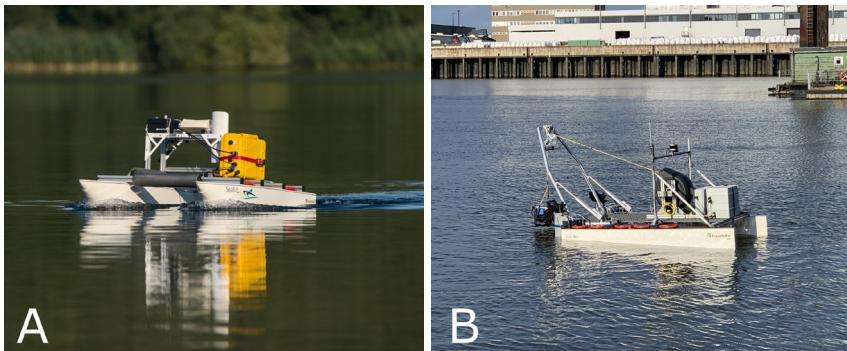
**Abb. 2:**  
Hydrographie-Setup  
des SeaML. Gut zu  
erkennen ist das  
Rohr, in welchem  
das Einstrahl-Echo-  
lot montiert ist. Das  
Echolot erzielt seine  
besten Ergebnisse,  
wenn es 1 m unter  
der Wasseroberfläche  
montiert ist, weshalb  
dieses Design ge-  
wählt wurde.



**Abb. 3:** Ergebnisse der Tiefenmessung, wie sie in der WebUI dargestellt werden. Zu erkennen ist hier die Wegpunkt-Strecke des SeaML und die farbig eingefärbten Tiefenwerte, um schnell markante Stellen zu identifizieren. Die exakten Zahlenwerte werden je Punkt dargestellt oder sind in Tabellenform einsehbar (hier nicht dargestellt).

### 3 Die Evolution eines ASV – von SeaML zu SeaLion

Ein essenzieller Bestandteil des RoboVaaS Projektes war und ist die unmittelbare Einbindung von speziell adaptierten robotischen Fahrzeugen zur möglichst realitätsnahen Demonstration der fünf Dienstleistungen. Hierzu wurde zunächst das am Fraunhofer CML entwickelte ASV „SeaML“ (Schneider und Oeffner 2020) entsprechend umgerüstet, um alle projektrelevanten Funktionalitäten abzubilden (Abb. 4A). Hierbei waren drei Konfigurationen des ASV notwendig.



**Abb. 4:** Die vom CML entwickelten ASV, beide kamen im Projekt RoboVaaS zum Einsatz. A) „SeaML“ mit an Deck montierter Steuerelektronik (gelbes Kompartiment) kann ein ROV mittels starrem LARS ablassen und einholen. B) „SeaLion“ mit Winde und ausschwenkbaren A-Frame als LARS. Die Steuerelektronik ist in den Rümpfen verbaut. An Deck befinden sich Navigations- und Windensteuereinheit.

Eine Inspektion-Konfiguration, wobei als Nutzlast ein ROV mit dazugehöriger Winde und Transportkäfig montiert wurde und bei Bedarf abgelassen werden kann. Eine hydrographische Konfiguration mit dem oben abgebildeten Einstahl-Echolot und eine Data Muling Konfiguration, bei der als Nutzlast ein speziell gefertigtes Hydrophon mit entsprechender Auswertungshardware montiert wurde. Die schnelle Entwicklung der Softwarearchitektur und deren TRL (Technology Readiness Level) zeigte jedoch auf, dass die Umrüstung des SeaML das technische Potenzial des RoboVaaS Konzeptes nicht ausschöpfen würde. Daher wurde innerhalb von zehn Monaten ein neues ASV mit dem Namen SeaML:SeaLion (Abb. 4B) konzipiert, designt, entwickelt und für die RoboVaaS Demonstrationen ausgerüstet. Hervorzuheben sind hier die mehr als verdoppelte Nutzlastkapazität, das versatilere LARS (Launch and Recovery System) mit schwenkbarem Kran und das verbesserte Antriebssystem mit nun 48V sowie höherer Reichweite und Geschwindigkeit (Tab. 1).

**Tab. 1:** Eigenschaften der ASV „SeaML“ & „SeaLion“, vom CML entwickelt und in RoboVaaS eingesetzt

Name	SeaML 1.0	SeaML:SeaLion
Bootstyp	ASV – Katamaran	ASV – Katamaran
Größe [B × L]	1210 mm × 1500 mm	2200 mm × 1500 mm
Payload	50 kg	120 kg
Akkulaufzeit	Max 6h	Max 24h
Höchstgeschwindigkeit	3 Knoten	8 Knoten
Anzahl Motoren	4 Motoren	2 Motoren
Motortyp	Elektromotoren	Elektromotoren
Leistung Motor	4 × 350 W	2 × 1 kW
Rumpfmaterial	GFK	GFK
Fahrtgebiet	Binnengewässer	Binnengewässer und Küstengebiete
Umgebungs- wahrnehmung	Kamera	Lidar, Stereokamera, Radar, AIS
Hersteller	Fraunhofer CML – Eigenbau	Fraunhofer CML – Eigenbau

## 4 SeaLion als Multisensorplattform und dessen Evolution über RoboVaaS hinaus

Innerhalb von RoboVaaS wurde eine komplette Servicearchitektur für maritime robotische Dienstleistungen entwickelt und validiert. Diese Entwicklungen umfassten die Software-Infrastruktur sowie die Entwicklung eines geeigneten Fahrzeugs zur Ausführung von fünf verschiedenen hafennahen Services. Der Höhepunkt der Funktionsdemonstration wurde mit der Live-Demonstration auf dem ITS World Congress erreicht, auf welchem die RoboVaaS Dienstleistungsinfrastruktur einem Fachpublikum live im Hamburger Hafen vorgestellt wurde (Schneider et al. 2021). Doch die Entwicklung wurde hier nicht gestoppt. Die Modularität des RoboVaaS Ansatz zur Software- und Hardwareentwicklung war von Anfang an ein Designkriterium und erlaubte die Evolution beider Säulen, was im Folgenden anhand einer Reihe von Anchlussprojekten dargestellt werden soll.

Hier ist zunächst das Horizon 2020 Projekt SCIPPER (Shipping Contribution to Inland Pollution Push for the Enforcement of Regulations) zu nennen. Dieses Projekt verfolgt die umfassende Datenerhebung von Schiffsemissionen mit einem Multisensor-Ansatz, wobei Emission im Schornstein, in der Abgasfahne aus der Luft sowie von Land und mittels Satelliten gemessen werden. Das CML hat hier die web-basierte Nutzerschnittstelle (Au et al. 2021) und dahinter geschaltete Datenbank so weiterentwickelt, dass all diese Daten gesammelt, gespeichert und aufbereitet werden können, um so Verstöße gegen Emissionsregulieren feststellen zu können (SCIPPER 2022a, 2022b). Ein weiteres Projekt, das die RoboVaaS-Software-Infrastruktur massiv weiterentwickelt hat, ist das Horizon 2020 Projekt SeaClear (SEarch, identificAtion and Collection of marine Litter with Autonomous Robots). Hier wird eine Flotte von autonomen robotischen Fahrzeugen zu Luft, auf und unter dem Waser eingesetzt, um Müll im Wasser zu detektieren und gezielt zu sammeln. Die in RoboVaaS entwickelte Softwarearchitektur wurde hier entsprechend erweitert, um die Daten zur Steuerung und Kommunikation aller Multisensor-Fahrzeuge zusammenzuführen und ein autarkes Betreiben des Systems zu ermöglichen (SeaClear 2022a, 2022b). Das Horizon 2020 Projekt RAPID (Risk-aware Automated Port Inspection Drone(s)) entwickelt Inspektionsdienstleistungen im Hafenumfeld rund um Flugdrohnen. Hierbei wird die RoboVaaS Benutzerschnittstelle um eine U-Space Integration erweitert, um fliegende Drohnen und deren Einsatz gemäß der Regularien kontrollieren und koordinieren zu können. Des Weiteren wird die Missionsdauer der Drohnen durch eine Batteriewechselsystem vervielfacht, welches vom Fraunhofer CML entwickelt auf dem SeaLion montiert wird (Schneider 2022). Das SeaLion dient dadurch als Transportmedium, Start- und Landeplattform und Energieversorgung in einem. Das SeaLion und die Drohne funktionieren in diesem Kontext als Multisensorplattform um eine langanhaltende Inspektion von kritischer Hafeninfrastruktur zu gewährleisten (RAPID 2020, 2022).

Um auch mit weiteren Entwicklungen in der autonomen Steuerung und Betrieb von Fahrzeugen mitzuhalten, ist zudem das CML-interne Entwicklungsprojekt iSeaLion gestartet. Hierbei liegt das Hauptaugenmerk auf der Integration von einer fortgeschrittenen Lageerfassung zur Objekt- und Hinderniserkennung. Das SeaLion wird hierzu zunächst mit einem Lidar ausgestattet. Dies ermöglicht die Erfassung der Umgebung in Echtzeit sowie die Verbesserung der Navigation in Hinsicht auf Positionsgenauigkeit (z. B. ergänzende SLAM-Navigation) und Robustheit der Positionsbestimmung gegen Störungen (z. B. GPS-Signalverlust). Des Weiteren wird eine 360°-Kamera integriert, um Objekte im Wasser und an Land identifizieren zu können. Dies dient Aspekten wie der Evaluierung von Gefahren (Treibholz, Müll) aber auch Identifikation von anderen Verkehrsteilnehmern (Erkennung von Schiffen und Abgleich mit AIS-Daten). Die 360°-Kamera ermöglicht es zusätzlich, die am CML entwickelte und zur Schleppersteuerung

im Projekt FernSAMS eingesetzte VR/AR-Technologie zu integrieren (Byeon et al. 2021). Dies kann besonders zur Evaluierung von möglichen Gefahren durch einen Operator zum Einsatz kommen, welche von SeaLion detektiert und als kritisch eingestuft wurden.

Als mit der Entwicklung des SeaML:SeaLion begonnen wurde, war eines der Kernentwicklungsziele eine modulare Plattform zu schaffen, welche möglichst versatil und erweiterbar ist. Dieses Ziel kann als erreicht angesehen werden, gemessen an den Projekten in denen die Technologie zum Einsatz kommt. Als modulares Sensorsystem kann einerseits das SeaLion selbst gesehen werden mit der Vielzahl an Sensoren zur autonomen Steuerung, aber auch mit den möglichen Nutzlasten, wie ROV zur Unterwasserinspektion oder Flugdrohen zur Überwasserinspektion. Als integraler Bestandteil dieses Multifahrzeugsystems ist die entwickelte Softwarearchitektur zu verstehen, welche die Steuerung, Datenerfassung sowie Datenauswertung bündeln und einheitlich darstellen kann.

Das SeaLion kann somit als modulare Multisensorplattform zur Datenerhebung verstanden werden, wobei die vorgestellte Softwarearchitektur die Datenauswertung und -aufbereitung abbildet. Die kontinuierliche Weiterentwicklung in EU-Projekten sowie Industrie- und Eigenforschungsprojekten garantiert die Evolution entsprechend der technischen Entwicklungen und Kundenansprüche und sichert eine langfristige und nachhaltige Nutzung des SeaLion im Rahmen der Fraunhofer Forschungs- und Entwicklungsprojekte.

## Funding Disclaimer

The RoboVaaS project was funded by German Federal Ministry of Economic Affairs and Energy (BMWi), Italian Ministry of Education, Universities and Research (MIUR) and Irish Marine Institute (MI) and co-funded by European Union's Horizon 2020 research and innovation programme under the framework of ERA-NET Cofund MarTERA (Maritime and Marine Technologies for a new Era).

## Literatur

- Allianz (2019): [www.agcs.allianz.com/content/dam/onemarketing/agcs/agcs/reports/AGCS-Safety-Shipping-Review-2019.pdf](http://www.agcs.allianz.com/content/dam/onemarketing/agcs/agcs/reports/AGCS-Safety-Shipping-Review-2019.pdf), letzter Zugriff 04/2020.
- Au, C. N., Delea, C., Schneider, V. E., Oeffner, J., Jahn, C. (2021): A web-oriented architecture for deploying multiple unmanned vehicles as a service. In: TransNav 15 (1), 155–164.
- Burmeister, H.-C., Schneider, V.E., Delea, C., Oeffner, J., Blanck, B. (2021): RoboVaaS – Future port service by scalable robotic vessels. 27th ITS World Congress. Hamburg, Germany, 11–15 October 2021.

- Byeon, S., Grundmann, R., Burmeister, H.-C. (2021): Remote-Controlled Tug Operation via VR/AR: Results of an In-Situ Model Test. In: TransNav 15 (4), 801–806.
- hamburg.de (2022): [www.hamburg.de/bvm/weltkongress-2021/13725514/wasserdrohne](http://www.hamburg.de/bvm/weltkongress-2021/13725514/wasserdrohne), letzter Zugriff 02/2022.
- RAPID (2020): <https://rapid2020.eu>, letzter Zugriff 02/2022.
- RAPID (2022): <https://cordis.europa.eu/project/id/861211>, letzter Zugriff 07/2022.
- Schneider, V.E. (2022): Autonomous inspection of port infrastructure. In: Ship and Offshore – Special Smart Ship, 32–33.
- Schneider, V.E., Delea, C., Oeffner, J., Dooley, G., Duda, A., Riordan, J. (2021): Final RoboVaaS Demonstration live at ITS World. [www.youtube.com/watch?v=HbJJCo\\_-dJQ](https://www.youtube.com/watch?v=HbJJCo_-dJQ), letzter Zugriff 02/2022.
- Schneider, V.E., Delea, C., Oeffner, J., Sarpong, B., Burmeister, H.-C., Jahn, C. (2020): Robotic service concepts for the port of tomorrow: Developed via a small-scale demonstration testbed. European Navigation Conference. Dresden, 11.–14.05.2020. DGON.
- Schneider, V.E., Oeffner, J. (2020): Hardware for the port of the future. In: Hansa International Maritime Journal.
- Schneider, V.E., Zantopp, N., Oeffner, J. (2022): RoboVaaS. Praxisorientierte Entwicklung von robotischen Systemen mit As-a-Service-Ansatz für den Hafen der Zukunft. In: Hydrographische Nachrichten 121, 14–20. DOI: [10.23784/HN120-03](https://doi.org/10.23784/HN120-03).
- SCIPPER (2022a): <https://cordis.europa.eu/project/id/814893/de>, letzter Zugriff 07/2022.
- SCIPPER (2022b): <https://www.scipper-project.eu/>, letzter Zugriff 07/2022.
- SeaClear (2022a): <https://seaclear-project.eu/>, letzter Zugriff 02/2022.
- SeaClear (2022b): <https://cordis.europa.eu/project/id/871295/de>, letzter Zugriff 07/2022.
- Thies, T., Lautenschläger, O. (2022): USVs – Innovative Technologie im täglichen Einsatz für die Hydrographie. In: DVW e. V. (Hrsg.): Hydrographie – Messen mit allen Sinnen. DVW-Schriftenreihe, Band 102, Wißner-Verlag, Augsburg, 45–49.

## Kontakt

Vincent E. Schneider

Fraunhofer Center für Maritime Dienstleistungen und Services (CML)

Am Schwarzenberg-Campus 4, Gebäude D, 21073 Hamburg

[vincent.schneider@cml.fraunhofer.de](mailto:vincent.schneider@cml.fraunhofer.de)



# Pipelinedetektion durch Autonomous Underwater Vehicles (AUVs)

Markus Kraft

## 1 Fragestellung/Problemstellung

An Gewässer- und insbesondere an Meeresböden sind nicht zuletzt seit dem Voranschreiten der Überseekommunikation und dem notwendigen Transport von fossilen Energielieferanten wie Erdgas und Erdöl eine große Anzahl an Kilometern von Pipelines, Stromkabeln und Telekommunikationskabeln verlegt worden. Offshore Windparks werden mit den Umspannwerken an Land durch Starkstromkabel verbunden und zahlreiche Rohrleitungen durchqueren für den Transport von Kondensat, Öl oder Gas die deutsche Außenwirtschaftszone (BSH 2022).

Sowohl Strom- als auch Fossilenergietransportpipelines bilden einen essenziellen Baustein der bestehenden lokalen und globalen Infrastruktur. Dementsprechend tiefgreifend wären Schäden an diesen Pipelines oder Kabeln, die für die Energiewirtschaft weitreichende Folgen hätten und zu Engpässen und Ausfällen führen können. Eine ebenso gravierende oder noch schwerwiegender Wirkung können Schäden in Form von Rissen, Brüchen oder gar Durchschlägen für die Tier- und Pflanzenwelt und damit das ökologische System haben. Selbst zum Errichten einer solchen Pipeline muss in ab gewisser Maße die Umweltverträglichkeit geprüft werden (BSH 2022).

Um diesen Risiken entgegenzuwirken und obendrein die globale Energieversorgung zu gewährleisten, müssen insbesondere Pipelines am Meeresboden mit einer spezifischen Regelmäßigkeit inspiziert und auf mögliche Schäden untersucht werden. Die Inspizierung wird in den meisten Fällen mit so genannten Working-Class ROVs und/oder Tauchern durchgeführt. Die Missionen erfordern einen hohen Aufwand an Material, Energie und menschlichen Ressourcen. Aus diesem Grund ist eine flächendeckende Inspizierung aus der Nähe entsprechend teuer und mit einem erhöhten menschlichen Unfallrisiko verbunden. Zudem sind Missionen mit einem zum Schiff verbundenen ROV wesentlich zeitaufwendiger als mit einem frei beweglichem Beobachtungssubjekt.

Aufgrund dieser infrastrukturellen Abhängigkeit von Tiefseeobjekten (Pipelines) und deren Wartung wächst der Bedarf an autonomer und unbemannter Vermessung dieser Objekte. In den letzten zwei Dekaden wurden vermehrt unbemannte Messplattformen für Gewässervermessung entwickelt (Mai et al. 2016),

um bathymetrische Daten zu sammeln, die in Modellen aufbereitet werden (Lubczonk et al. 2022).

## 2 Autonome Lösung zum Auffinden und Überwachen von Tiefseekabeln

### 2.1 Projekt CIAM

Das Projekt CIAM (Comprehensive Integrated and Fully Autonomous Subsea Monitoring; dt.: Kooperative Erarbeitung einer wegweisenden, integrierten autonomen Lösung für Monitoring in der Tiefsee) ist ein Verbundprojekt mit insgesamt neun Projektpartnern aus Wissenschaft und freier Wirtschaft unter der Schirmherrschaft der ROSEN Technology and Research Center GmbH mit Unterstützung des Bundesministeriums für Wirtschaft und Klimaschutz. Ziel des Projektes ist die Entwicklung einer autonomen Lösung für Tiefsee-Inspektion, u. a. für Pipelines.

### 2.2 Autonome Unterwasserfahrzeuge (AUV)

Im Rahmen der Motivation dieses Projektes sollen das Konzept und die Funktionsweise eines autonomen Unterwasserfahrzeugs (AUV) hier näher erläutert und weitere Anwendungsmöglichkeiten beschrieben werden. Im Folgenden werden zudem neben den autonomen Unterwasserfahrzeugen die weiteren Fahrzeugtypen aus der Familie der unbemannten Messplattformen vorgestellt.

#### 2.2.1 Unbemannte Messsysteme

Bereits aus der Luftfahrt sind unbemannte Messplattformen (Unmanned Aerial Vehicles, UAVs) auch als Sensorplattformen für die Vermessung bekannt. In der Gewässervermessung kommen ebenso bereits mehrere Arten von unbemannten Messplattformen zum Einsatz. Diese lassen sich abhängig von ihrer Anwendung in verschiedene Klassen einteilen:

- Unmanned Surface Vehicle (USV) ([Abb. 1](#))
- Unmanned Underwater Vehicle (UUV)
- Autonomous Surface Vehicle (ASV)
- Autonomous Underwater Vehicle (AUV)

Hier lässt sich bereits eine Unterscheidung zwischen lediglich unbemannten Plattformen und – detaillierter – autonomen Plattformen erkennen. Die Diffe-



Abb. 1: Unmanned Surface Vehicle SL40 von Ocean Alpha (Ocean Alpha 2022)

renzierung ergibt sich also aus den Fähigkeiten eines Fahrzeugs autonom agieren zu können oder fremdgesteuert bzw. ferngesteuert werden zu müssen.

Eine bekannte und bereits genannte Klasse von unbemannten Messplattformen sind Remotely Operated Vehicles (ROVs). ROVs sind mit einer umfassenden Sensorik und Arbeitstechnik wie Greifarmen und anderen Instrumenten ausgestattet. Zwischen dem ROV und einem Begleitschiff besteht zu jedem Zeitpunkt eine Kommunikationsverbindung und ein Energiefluss, da die detaillierten und umfangreichen Arbeitsschritte unter Wasser eine menschliche Bedienung, den Operator, erfordern. Auch innerhalb der ROVs gibt es Unterscheidungen zwischen unterschiedlichen ROVs wie z.B. Work-Class ROVs, Observation ROVs oder auf dem Meeresboden fahrende Kettenfahrzeuge (so genannte Crawlers).

Für die „klassische“ Gewässervermessung vom Boot stellen die USVs eine effiziente Alternative für die Vermessung von unzugänglichen oder sehr flachen Gewässerbereichen dar, in denen auch LiDAR-Messungen wegen eventuell vorhandener Trübung keine aussagekräftigen Ergebnisse liefern können. Wie der ROV, werden auch – nicht-autonome – USVs vom Schiff oder Land aus ferngesteuert, wobei in den meisten Fällen aufgrund der Anwendung keine Kabelverbindung für die Energiezufluss besteht und die Messplattform eigene Energiekapazitäten verwendet. Für ozeanographische Messinstrumente (autonom) sind dafür Solarpanels teilweise ausreichend, in der Vermessung werden für den höheren Energiebedarf Akkus benötigt (Geomar 2022).

Werden die Messplattformen nicht von einem Benutzer ferngesteuert, sondern agieren autonom oder nach einem vorgegebenen Plan an der Gewässeroberfläche, spricht man von ASVs. Eine Mischform von ASVs und AUVs sind sogenannte Glider, die häufiger als in der Gewässervermessung in der physikalischen Ozeanographie anzutreffen sind. Diese werden zur Erkundung der Wassersäule in den Ozeanen eingesetzt, die bis zu mehreren Wochen ohne Begleitung durch großflächige Messgebiete fahren und physikalische Parameter

wie Temperatur, Salzgehalt und chemische Zusammensetzung des Meerwassers aufzeichnen (NOC 2022).

Für Einsätze unter der Meeresoberfläche, bei denen aus Anwendungsgründen kein physischer Kontakt durch Kommunikations- und Stromkabel zu einer Steuerungsplattform/Begleitschiff besteht, werden Unterwasserfahrzeuge eingesetzt die ein Messgebiet autonom abfahren (AUVs). Für diese Gruppe der unbemannten Messplattformen ergeben sich durch die Abkopplung von einer zentralen Schiffstation gleich mehrere zusätzliche Herausforderungen, da durch die nicht mehr vorhandene Energiebereitstellung der Strom möglichst effizient selbst generiert und/oder in Speicherungselementen/Akkus transportiert werden muss. Zusätzlich sorgt die Kommunikationsmöglichkeit zu einer an der Wasseroberfläche stationierten Plattform normalerweise für eine sicherere Positionierung und Navigation, die nun mit erheblichen Ungenauigkeiten behaftet ist da sich das AUV beinahe vollständig auf Koppelnavigation verlassen muss, vorausgesetzt die Operation findet in einem Gebiet ohne akustische Positionierungsinfrastruktur statt.

## 2.2.2 Stützpositionierung unter Wasser

Da unter Wasser kein GNSS-Empfang möglich ist, können in einigen vorab abgesteckten Messgebieten Basislinien definiert und an den Endpunkten mit akustischen Beacons abgesteckt werden (LBL, Long-Baselines). Ein mit einem entsprechenden Transceiver ausgestattetes Unterwasserfahrzeug kann durch akustische Distanzmessung zu den einzelnen Beacons anschließend durch Triangulationsverfahren seine Position mit einer weitestgehend konstanten und lediglich von den Abständen und Orientierungswinkeln in Relation zu den Beacons abhängigen Ungenauigkeit bestimmen. Das Stützverfahren durch abgesteckte Schallquellen bedarf eines infrastrukturellen Aufwands, da diese Transponder zunächst selbst in das Messareal gebracht und eingemessen werden müssen. Für Missionen mit beteiligten Begleitschiffen können die Unterwasserpositionierungsverfahren Ultra-Short-Baselines (USBL) und Short-Baselines (SBL) verwendet werden. Bei diesen wird die Schallquellen am Rumpf des Schiffs angebracht und oberhalb der Wasseroberfläche besteht eine lückenlose GNSS-Verbindung.

## 2.2.3 Autonom vs. Fremdgesteuert

In der autonomen Vermessung muss zwischen verschiedenen Stufen der Autonomie eines Multisensorsystems unterschieden werden. Man findet in der Literatur verschiedene Definitionen und Unterscheidungen der Autonomie, in welchen sich nicht selten auf autonomes Fahren mit dem PKW bezogen

wird (Parasuraman et al. 2000, SAE 2016, Huang et al. 2004). Auch unter Fachleuten wird die Einteilung eines Multisensorsystems (MSS) in autonom, teilautonom oder ferngesteuert divers diskutiert (Schiller et al. 2015).

Es können dennoch vier grundsätzliche Operationsmodi festgehalten werden (zusammengefasst von Dufek und Sternberg 2018 nach Huang et al. 2004):

- „Vollständige Autonomie (fully autonomous): Das System führt eine vordefinierte Mission von Anfang bis Ende ohne menschlichen Eingriff aus.
- Teilautonomie (semi-autonomous): Der Anwender und/oder das unbemannte System planen und führen die Aufgabe unter Verwendung unterschiedlicher Interaktionsebenen aus.
- Fernlenkung/Teleoperation (teleoperation): Der Anwender nutzt Video und/oder Sensorinformationen, um entweder den Antrieb direkt zu steuern, oder inkrementelle Ziele von außerhalb über Kabel/Funk zu übermitteln. System ergreift nur eingeschränkt Eigeninitiative.
- Fernsteuerung (remote control): Der Anwender steuert den Antrieb des Systems ohne Video- oder Sensorinformationen via Kabel/Funk unter Verwendung visueller Informationen. Das System ergreift keine Eigeninitiative.“

Das Ziel in der Entwicklung eines AUV und im Rahmen des CIAM Projektes ist es die vollständige Autonomiestufe zu erreichen und das MSS eine vordefinierte Mission eigenständig ausführen zu lassen.

## 2.3 Möglichkeiten der Unterwasserdetektion von Objekten

Um Objekte verschiedener Art unter Wasser erfassen zu können, benötigt es entsprechende Sensorik, die auf dem AUV installiert werden muss. Abhängig von der Umgebung und auch der Anwendung können optische, akustische, elektrische oder magnetische Sensoren Vorteile eingesetzt werden.

Im optischen Bereich der Datenerfassung sind Kamera und Unterwasser-Laserscanner zu nennen. Kameras bedürfen hierbei einer Beleuchtungsanlage, die einen nicht unerheblich Anteil an Strom verbraucht, jedoch unverzichtbar für die Nutzung ist. Mit zwei angebrachten Kameras kann eine Stereo-Nutzung ermöglicht werden, mit der nach Luftbild-Photogrammetrie Vorbild Höhen und Distanzen zu Objekten ermittelt werden können. Ein Unterwasser-Laserscanner bietet eine sichere Methode des Abtastens von Pipelines in hoher Auflösung. Für eine ausreichende Nutzung muss jedoch wie auch bei der Kameranutzung eine Mindestflughöhe bzw. -tiefe eingehalten werden, da die Trübung des Gewässers direkten Einfluss auf die Lasermessung hat (Laurenzis et al. 2014).

Um den Meeresboden akustisch zu vermessen und natürliche sowie unnatürliche Objekte aufzuspüren, werden in der Seevermessung neben Einstrahl-

echoloten hauptsächlich Fächerecholote eingesetzt. Im Gegensatz zu den optischen Messmethoden haben akustische Sensoren eine relative hohe Reichweite (abhängig von der Messfrequenz) und können somit weit vor einem Laserscanner Daten erfassen, die allerdings aus großer Entfernung eine schlechtere Auflösung aufweisen. Im Falle einer Flughöhe von beispielsweise 100 m, besitzt ein Fächerecholot im Equi-Distant-Modus einen Footprint (akustischer Fußabdruck) von 34 cm, für eine Flughöhe von 10 m verringert sich dieser auf 3,4 cm. Fächerecholote decken mit einem Fächerwinkel von etwa 130° (knapp 430 m Fächerbreite bei 100 m Flughöhe) den Seeboden ab und liefern somit eine gute Datengrundlage für den Detektionsprozess der Pipeline.

Neben einem nach unten gerichteten Fächerecholot können zudem Forward-Looking-Sonare (nach vorn gerichtete Fächerecholote) bzw. Imaging-Sonare eingesetzt werden, um die Umgebung des AUVs zu kartieren und Objekte zu verfolgen. In der Praxis werden während der Pipelineverfolgung (Zhang et al. 2022, Gower et al. 2022) sowie in anderen Fachgebieten wie in der Marinen Biologie (Maki et al. 2020) häufig die forward-looking-Systeme zur Hindernis- und Gefahrenerkennung genutzt. Sub-Bottom Profiler (SBP) sind Einstrahlecholote, die mit tiefen Messfrequenzen eine hohe Eindringtiefe in den Meeresboden erlangen und Strukturen in den oberen Sedimentschichten auflösen können. Für den Fall einer Überspülung sind diese Sensoren somit hervorragend einsetzbar um die Pipeline wieder aufzufinden. Um detaillierte Schäden am Gehäuse der Pipeline feststellen zu können, sind sie in der Regel jedoch nicht ausreichend, da die Auflösung des SBP innerhalb des Sediments nicht die eines z. B. Laserscanners erreicht (Zhen et al. 2015).

Zuletzt sind in der Reihe der Sensorgruppen noch Magnetometer und elektrische Feldstärkemessgeräte zu nennen. Diese können genau wie das SBP eine Pipeline erkennen, ohne dass diese physisch an der Sedimentoberfläche liegt und besitzen zudem die Möglichkeit, Korrosionsschäden in Rohrleitungen zu erfassen (Narkhov et al. 2017).

Die Kombination aus diesen Sensorikgruppen ermöglicht so eine stabile Erfassung und im Nachhinein auch Verfolgung der Pipeline.

Das AUV als Multisensorsystem für die Pipelinedetektion bildet sich somit aus den Ebenen der notwendigen und der „peripheren“ Sensorik: Für ein funktionstüchtiges AUV, welches sich eigenständig unter Wasser fortbewegen und selbst navigieren kann, werden die Grundlagentechnologien wie der Antrieb, die Stromversorgung und das inertiale Navigationssystem benötigt. Um zusätzlich Objekte/Pipelines zu detektieren, werden Sensoren wie das Fächerecholot, Imaging-Sonar, Magnetometer, elektrische Feldsensoren, Kamera und Laserscanner hinzugezogen. Diese als peripher deklarierten Sensoren können auch der Stütznavigation dienen, beispielsweise kann durch eine Sensorfusion von INS und Sonar die Positionsgenauigkeit erhöht werden. Eine Sensorfusion ist ratsam, da

gerade bei längeren Missionsdauern die Drift eines Inertialsystems zu einer unzureichenden Genauigkeit führt.

## 2.4 Funktionsweise und Prinzip der Unterwassermannisionen

Im Einsatz fährt das AUV alleine oder mit einer Dockingstation zum Startort des Messgebiets und sinkt anschließend auf die vorgegebene Tiefe ab, bevor mit der vordefinierten Mission gestartet wird.

Da ab dem Verlassen der Meeresoberfläche der Kontakt zu Satelliten und damit die Positionierungsmöglichkeit durch Festpunktnavigation verloren geht, hängt die Navigation nunmehr allein von der Performance des inertialen Messsystems ab. Sobald das Messgebiet bzw. der Meeresboden erreicht ist, wird das Objekt des Interesses/die Pipeline mit den an Bord befindlichen Sensoren gesucht. In diesem Abschnitt erfassen alle an Bord befindlichen Sensoren gleichzeitig Messdaten, wobei die Herausforderung in der Gewichtung einzelner Sensoren besteht, so dass für jedes eintretbare Szenario (Pipeline vergraben, sichtbar oder gar unterspült) die Erfassung und Klassifizierung dieser möglich ist. Sobald die Pipeline mit den peripheren Sensoren erfasst und per Klassifizierungsalgorithmus als solche erkannt ist, können die Steuerungselemente des AUV so gelenkt werden, dass die Messplattform fortan die Pipeline in einer fest definierten Höhe überfliegt. Das Durchfahren eines Messgebietes während einer Rohrvermessung ist trivialerweise in den meisten Fällen eindimensional, somit muss lediglich entlang der Pipeline in einer bestimmten Geschwindigkeit gefahren und Daten aufgezeichnet werden. Während der Inspizierung ist es wichtig, die Flughöhe einzuhalten, da hiervon die Validierung der Sonardaten und vor allem die des Magnetometers abhängt.

Werden an der Pipeline im vorliegenden Messgebiet durch die Sensorik des AUV im Nachhinein Schäden und Unregelmäßigkeiten entdeckt, können an diesen speziellen Stellen ROVs und Taucher eine detailliertere Inspektion und eventuelle Reparaturen durchführen.

## 2.5 Besondere Herausforderungen für AUV-Missionen unterhalb der Wasseroberfläche

### 2.5.1 Navigation und Positionierung unter Wasser

Eine große Hürde für AUV-Missionen ist die ungenaue Navigation unter Wasser. Da im generellen Falle davon ausgegangen werden muss, dass das AUV unterhalb der Wasseroberfläche weder Kontakt zu einem Begleitschiff noch zu

einer akustischen Basislinieninfrastruktur wie den Long-Baselins besitzt, wird die Position des AUVs aus den inertialen Messungen desselbigen berechnet. Da jedes inertiale Messsystem mit einem konstanten Fehler, dem Bias, behaftet ist findet durch die Kumulierung der Fehler nach jeder Messung eine Positionsdrift statt, bei hochentwickelten faseroptischen Kreiseln üblicherweise 0,003°/h (Vietheer 2019).

Möglichkeiten, die Ungenauigkeiten zu verringern und die Drift einzuschränken, bieten Methoden der Sensorfusion. Mittels eines Doppler Velocity Logs (DVL) kann die Position anhand von genauen Geschwindigkeitsdaten abgeschätzt werden, vorausgesetzt das DVL befindet sich in Reichweite des Meeresbodens. Das Fusionsprinzip ist analog zu beispielsweise der Fusion von INS und Odometern bei der Tunnelvermessung anzusehen.

Eine weitere Methode ist die Erarbeitung eines SLAM-Algorithmus (Simultaneous Localization and Mapping) mit den erfassten Umgebungsdaten der optischen und akustischen Sensoren des AUVs. Diese als feature-based Navigation bezeichnete Methode findet gerade in langen Pipelineinspizierungen von >100 km Anwendung, z.B. im Langdistanz-Inspizierungsprojekt von Total Energie (Gower et al. 2022).

## **2.5.2 Erkennung von Pipelineobjekten, Validierung der Messdaten, Genauigkeitsanforderungen, Verfolgung der Pipeline**

Um die Pipeline zu erfassen und als solche zu erkennen, werden zunächst die o.g. Messsensoren verwendet. Bereits auf der Ebene eines jeden Sensors treten unterschiedliche Schwierigkeiten auf, die einzeln berücksichtigt werden müssen. Beispielsweise sind die Messfrequenzen eines Fächerecholots für einzelne Anwendungen unterschiedlich, so dass abhängig von Gebiet, Flughöhe, Untergrundbeschaffenheit und zu detektierendem Objekt die Frequenzen und andere Parameter angepasst werden müssen. Ähnliches gilt für einen am AUV befestigten Sub-Bottom Profiler und/oder das bereits beschriebene forward-looking-Sonar.

Besondere Herausforderungen ergeben sich in Gebieten, in denen eine Pipeline mit Sedimenten überdeckt ist. Hier findet die Detektion mittels Sub-Bottom Profiler und unter Umständen eines magnetisch-elektrischen Feldsensor statt.

Ist die Pipeline erfasst, muss diese im nächsten Schritt als solche erkannt werden. Dafür werden Klassifizierungsalgorithmen angewendet, die aus den von unterschiedlichen Sensoren generierten Punktwolken Klassifizierungen vornehmen und somit z. B. den Seeboden von der Pipeline trennen. In weiterführenden Schritten werden die Punktwolken in Gruppen eingeteilt, so dass neben der Unterteilung Objekt True/False ebenfalls weitere Objektgruppen erkannt werden können wie Bewuchs, Gestein, Sandrippel oder Rohrflansche.

Ein weiteres wichtiges Thema ist die Genauigkeitsanforderung für die aufgenommenen Pipelinedaten selbst. Da das Ziel der Messkampagne ist, potenzielle und bestehende Schäden an Pipelines zu erkennen, erfordern die direkten Messungen der Sensoren an der Pipeline eine Genauigkeit im Zentimeterbereich. So können Beschädigungen, Verformungen und potenzielle Bruchstellen auch von außen erkannt werden. In Kombination mit einer eventuellen Inline-Inspektion mittels Molchen (Vermessungsroboter, die eine Pipeline innen durchfahren und auf Schäden untersuchen) ist es möglich, einen Schaden als 3D-Modell darzustellen. Neben der vom Betreiber gewünschten Auflösung im Zentimeterbereich erfordern hydrographische Standards in der von der IHO definierten „special Order“ für Bereiche mit „critical underkeel clearance“ und einer Flughöhe von 5 m eine vertikale Messgenauigkeit von 3,75 cm (IHO 2020).

### **2.5.3 Stromversorgung**

Die Energieversorgung ist bei einem AUV anders als beim ROV nicht durch ein Begleitschiff gewährleistet und hängt von hochleistungsfähigen Brennstoffzellen ab. Besonderes Merkmal muss hier auf die Effizienz des Systems gelegt werden in Bereichen wie Strömungsdynamik und Antrieb. Für den speziellen Fall von Unterwasserfahrzeugen ergibt sich beispielsweise laut Preradovic (2013), dass unter Einbeziehung aller notwendigen Bedingungen wie Anbauteilen, Rumpf stabilisatoren, benötigtes Volumen, etc. eine Pinguin-ähnliche äußere Bauform den geringsten Strömungswiderstand unter Wasser nach sich zieht.

Die Stromversorgung kann entweder Batterie- oder Brennstoffzellgetrieben (Wasserstoff) stattfinden. In einer Untersuchung mit dem Ziel zum Aufbau eines Brennstoffzellsystems für autonome Unterwasserfahrzeuge konnten mit einem hybriden System aus Batterien und Polymerelektrolyt-Brennstoffzellen Betriebsdauern von 71 Stunden erreicht werden (Hitscherich 2017). Auf dem Markt verfügbar sind zudem druckneutrale Batterien, die in einem Umgebungsdruck bis zu 600 bar einsatzfähig sind, zur Stromversorgung von AUVs eingesetzt werden und eine Einsatzdauer von 36 Stunden ermöglichen (Jaffre et al. 2019).

### **2.5.4 Kommunikation mit Zentrale/Begleitschiff**

Eine Kommunikation mit dem AUV ist in sehr begrenztem Maße durch akustische Signale möglich. Jedoch können durch USBL lediglich eine Handvoll Befehle kommuniziert werden (z. B. Abtauchen, Auftauchen). Zudem ist die Technik der Unterwasserkommunikation noch auf keinem Stand um für die Anwendungen in der Pipelineinspektion als verlässliche Methode genutzt zu werden.

Anstatt eines Begleitschiffs können Dockingstationen als eine Auflade- und Andockstation dienen, sowie als eine Möglichkeit, aufgezeichnete Daten bereits

an Land zu übertragen. Die Dockingstationen erfüllen in ihren Kompetenzen die Kriterien eines USVs und bedürfen weniger Aufwand und Kosten als ein besetztes Schiff.

### 3 Ausblick und Möglichkeiten – AUV-Einsätze in der Zukunft

Zusammenfassend lässt sich feststellen, dass AUVs für eine flächendeckende Vermessung und Inspektion von Seekabeln und Pipelines eine vielversprechende Möglichkeit darstellen. Durch den geringen Aufwand an Material und Personal in der Missionsdurchführung können Kosten eingespart und die Umwelt geschont werden. Sie ermöglichen unter anderem eine regelmäßige Inspektion von Unterwasserpipelines, als es mit ROVs und Tauchern möglich wäre.

Durch bereits zahlreich vorhandene Möglichkeiten der Inline-Inspektion (Beavers et al. 2015) mit sogenannten Molchen können mit der Kombination aus Inline-Inspektion und äußerlicher Begutachtung durch AUVs ein umfassendes Bild von Pipelines gewonnen werden.

Die große Herausforderung wird auch in Zukunft die driftende Ungenauigkeit in der Positionierung sein. Auch mit einem hochwertigen Inertialsystem ist es nicht möglich, den Bias auszuschließen und ein Driften zu verhindern. Jedoch können mit den Ansätzen der Sensorfusion mit DVL und akustischen sowie optischen Sensoren, die für die Umgebungserfassung zuständig sind, Lösungen für eine Verringerung dieser Ungenauigkeiten geschaffen werden. Mit hochentwickelten SLAM-Algorithmen ist es weiterhin möglich, Stützungen für die Unterwassernavigation zu schaffen, und für eine genaue Positionierung können Dockingstationen mit USBL ausgestattet werden. In einem vordefiniertem Messgebiet wie z. B. einem Offshore-Windpark ist es durchaus im Interesse einer regelmäßigen und qualitativen Kontrolle der Anlagen, ein permanentes LBL-Netz einzurichten.

Die Weltschiffahrtsorganisation (IMO) hat mit ihren „Interim Guidelines for MASS trail“ bereits Richtlinien für einen international gültigen Umgang mit autonomen Schiffen (MASS: Maritime Autonomous Surface Ships) geschaffen. Jedoch fallen Forschungsprojekte mit autonomen Unterwasserfahrzeugen bislang unter zeitlich und räumlich begrenzte Regelungen, die zudem abhängig sind von den Anrainerstaaten (Klindt 2022).

Eine Chance neben der kommerziellen Pipelineinspektion bieten AUVs für die Wissenschaft: Die flächendeckende Kartierung des Ozeans kann vorangetrieben werden, indem auf großem Gebiet eine hochauflösende Kartierung mit AUVs vorgenommen werden könnte (Wynn et al. 2014). Ob und in welcher Form dies zu realisieren ist, hängt auch davon ab, wie die technischen Kapazitäten eines AUVs in Zukunft beispielsweise hinsichtlich der Akkulaufzeit erweitert werden können.

## Literatur

- Beavers, J. A., Bensman, L. A., Kowalski A. R. (2015): Direct Assessment. In: Oil and Gas Pipelines, Part V: Inspection and Monitoring, 485–494. DOI: [10.1002/9781119019213.ch33](https://doi.org/10.1002/9781119019213.ch33).
- BSH (2022): Rohrleitungen. [www.bsh.de/DE/THEMEN/Offshore/Offshore-Vorhaben/Rohrleitungen/rohrleitungen\\_node.html;jsessionid=99FA89DEDA45399C063414C681654749.live21304](http://www.bsh.de/DE/THEMEN/Offshore/Offshore-Vorhaben/Rohrleitungen/rohrleitungen_node.html;jsessionid=99FA89DEDA45399C063414C681654749.live21304), letzter Zugriff 08/2022.
- Dufek, T., Sternberg, H. (2018): Unbemannte Multisensorsysteme und Nutzungsmöglichkeiten in der Hydrographie. In: DVW e. V. (Hrsg.): Hydrographie 2018 – Trend zu unbemannten Messsystemen. DVW-Schriftenreihe, Band 91, Wißner-Verlag, Augsburg, 9–28.
- Geomar (2022): Floats, Glider, AUV. [www.geomar.de/en/research/fb1/fb1-po/observing-systems/floats-glider-aув](http://www.geomar.de/en/research/fb1/fb1-po/observing-systems/floats-glider-aув), letzter Zugriff 08/2022.
- Gower, S. A., Lardeux, M., Gilmour, B., Ling, D. (2022): Subsea Robotics – AUV Pipeline Inspection Development Project. In: Offshore Technology Conference, Houston, Texas, USA, May 2022. DOI: [10.4043/31733-MS](https://doi.org/10.4043/31733-MS).
- Hitscherich, M. (2017): Polymerelektrolyt-Brennstoffzellensystem für ein autonomes Unterwasserfahrzeug. In: Fraunhofer IRB-Verlag (Hrsg.): Wissenschaftliche Schriftenreihe des Fraunhofer ICT, Band 76, ISBN: 978-3-8396-1251-4.
- Huang, H.-M., Albus, J., Messina, E., Wade, R.-L. (2004): Specifying Autonomy Levels for Unmanned Systems: Interim Report. In: Proceedings of the SPIE, 5422, 386–397. DOI: [10.1117/12.552074](https://doi.org/10.1117/12.552074).
- IHO (2020): Standards for Hydrographic Surveys. S-44 Edition 6.0.0., International Hydrographic Organisation. [https://ihonet.int/uploads/user/pubs/standards/s-44/S-44\\_Edition\\_6.0.0\\_EN.pdf](https://ihonet.int/uploads/user/pubs/standards/s-44/S-44_Edition_6.0.0_EN.pdf), letzter Zugriff 08/2022.
- Jaffre, F., Littlefield, R., Grund, M., Purcell, M. (2019): Development of a New Version of the REMUS 6000 Autonomous Underwater Vehicle. In: OCEANS 2019 – Marseille, 2019, 1–7. DOI: [10.1109/OCEANSE.2019.8867297](https://doi.org/10.1109/OCEANSE.2019.8867297).
- Klindt, H. (2022): Digitalisierung und autonome Verkehre – zwischen Fakten und Visionen. In: DVW e. V. (Hrsg.): Hydrographie – Messen mit allen Sinnen. DVW-Schriftenreihe, Band 102, Wißner-Verlag, Augsburg, 135–139.
- Laurenzis, M., Christnacher, F., Scholz, T., Metzger, N., Schertzer, S., Bacher, E. (2014): Underwater laser imaging experiments in the Baltic Sea. In: Proceedings of the SPIE, 92500D. DOI: [10.1117/12.2067166](https://doi.org/10.1117/12.2067166).
- Lubczonek, J., Kazimierski, W., Zaniewicz, G., Lacka, M. (2022): Methodology for Combining Data Acquired by Unmanned Surface and Aerial Vehicles to Create Digital Bathymetric Models in Shallow and Ultra-Shallow Waters. In: Remote Sensing, 14(1), 105. DOI: [10.3390/rs14010105](https://doi.org/10.3390/rs14010105).
- Mai, C., Pedersen, S., Hansen, L., Jepsen, K.-L., Yang, Z. (2016): Subsea Infrastructure Inspection: A Review Study. In: IEEE International Conference in Underwater System Technology: Theory and Applications (USYS), 71–76. DOI: [10.1109/USYS.2016.7893928](https://doi.org/10.1109/USYS.2016.7893928).
- Maki, T., Horimoto, H., Ishihara, T., Kofuji, K. (2020): Tracking a Sea Turtle by an AUV with a Multibeam Imaging Sonar: Toward Robotic Observation of Marine Life. In: International Journal of Control, Automation and Systems, 18, 597–604. DOI: [10.1007/s12555-019-0690-4](https://doi.org/10.1007/s12555-019-0690-4).

- Narkhov, E.D., Muravyev, L.A., Sergeev, A.V., Fedorov, A.L., Denisov, A.Y., Shirokov, A.A., Sapunov, V.A. (2017): Applications of Modern High-Precision Overhauser magnetometers. In: AIP Conference Proceedings, 1886(1) S. 020075. DOI: [10.1063/1.5002972](https://doi.org/10.1063/1.5002972).
- NOC (2022): Gliders. [www.noc.ac.uk/facilities/marine-autonomous-robotic-systems/gliders](http://www.noc.ac.uk/facilities/marine-autonomous-robotic-systems/gliders), letzter Zugriff 08/2022.
- Ocean Alpha (2022): Small Unmanned Surface Vehicle. Multi-Function Small Unmanned Surface Vehicle for Hydrographic Survey. [www.oceanalpha.com/product-item/sl40/](http://www.oceanalpha.com/product-item/sl40/), letzter Zugriff: 08/2022.
- Parasuraman, R., Sheridan, T.B., Wickens, C.D. (2000): A Model for Types and Levels of Human Interaction with Automation. In: IEEE Transactions on systems, man, and cybernetics – Part A: Systems and Humans, 30(3), 286–297. DOI: [10.1109/3468.844354](https://doi.org/10.1109/3468.844354).
- Preradovic, O. (2013): Gestaltung eines autonomen Unterwasserfahrzeugs mit elektromagnetischer Aufstauchvorrichtung und multifunktionalem Transportsystem. Dissertation TU Berlin. DOI: [10.14279/depositonce-3821](https://depositonce.tu-berlin.de/10.14279/depositonce-3821).
- SAE (2016): Taxonomy and Definitions for Terms Related to Driving Automation Systems for On-Road Motor Vehicles. In: SAE International, 30. DOI: [10.4271/J3016\\_201609](https://doi.org/10.4271/J3016_201609).
- Schiller, L., Döscher, T., Gimpel, P., von Deimling, J., Thies, T. (2015): Ist die Zukunft ferngesteuert oder autonom? In: Deutsche Hydrographische Gesellschaft e. V. (Hrsg.): Hydrographische Nachrichten 102, Band 11/2015, 14–22.
- Vietheer, C.J. (2019): Comparison of MEMS and FOG based Inertial Systems for Hydrographic Applications. In: Deutsche Hydrographische Gesellschaft e. V. (Hrsg.): Hydrographische Nachrichten 114. DOI: [10.23784/HN114-03](https://doi.org/10.23784/HN114-03).
- Wynn, R. B., Huvenne, V.A. I., Le Bas, T. P., Murton, B. J., Connelly, D. P., Bett, B. J., Ruhl, H. A., Morris, K. J., Peakall, J., Parsons, D. R., Sumner, E. J., Darby, S. E., Dorrel, R. M., Hunt, J. E. (2014): Autonomous Underwater Vehicles (AUVs): Their past, present and future contributions to the advancement of marine geoscience. In: Marine Geology, Volume 352, 451–468. DOI: [10.1016/j.margeo.2014.03.012](https://doi.org/10.1016/j.margeo.2014.03.012).
- Zhang, Y., Zhang, H., Liu, J., Zhang, S., Liu, Z., Lyu, E., Chen, W. (2022): Submarine pipeline tracking technology based on AUVs with forward looking sonar. In: Applied Ocean Research, 122 (103128). DOI: [10.1016/j.apor.2022.103128](https://doi.org/10.1016/j.apor.2022.103128).
- Zhen, L., Lihua, C., Siyou, T., Jinjing, P., Jishang, X. (2015): Problems of Application of High-Frequency Sub-Bottom Profiler Technology to Submarine Pipeline Inspection. In: Marine Geology Frontiers, 31(7), 66–70. DOI: [10.16028/j.1009-2722.2015.07010](https://doi.org/10.16028/j.1009-2722.2015.07010).

## Kontakt

M.Sc. Markus Kraft

HafenCity Universität Hamburg

Henning-Voscherau-Platz 1, 20457 Hamburg

[markus.kraft@hcu-hamburg.de](mailto:markus.kraft@hcu-hamburg.de)

## **Session 4: Anwendungen und Projekte**



# **PlantSens: Ein schienenbasiertes Multisensor-Messsystem für eine automatisierte, bedarfs- und zielgerechte Bewässerung von Nutzpflanzenbeständen im Gewächshaus**

Lukasz Rojek | Matthias Möller | Markus Richter | Monika Bischoff-Schaefer

## **1 Einführung**

Wasser ist ein wichtiger Bestandteil der fundamentalen Lebensprozesse aller Organismen, einschließlich Pflanzen (Govender et al. 2009). Die Wasserverfügbarkeit steht mit der Gesunderhaltung der Kulturpflanzen in direktem Zusammenhang und hat einen erheblichen Einfluss auf ihr Wachstum, die Qualität und den Ertrag (Rojek et al. 2019a). Der weltweit steigende Wasserverbrauch, verursacht durch den Klimawandel, beansprucht, vor allem in der Landwirtschaft, eine nachhaltige Nutzung dieser begrenzten und kostbaren Ressource. Die Produktion von Obst und Gemüse im geschützten Anbau (z. B. im Gewächshaus), aber auch im Freiland, insbesondere im ökologischen Pflanzenbau in ariden Gebieten, ist von zusätzlicher Bewässerung abhängig. Des Weiteren wird in semi-ariden und humiden Gebieten immer häufiger eine zusätzliche Wasserversorgung eingesetzt, um die Produktivität zu erhöhen (González-Dugo et al. 2006).

Ein intelligentes Bewässerungssystem, das den Wasserstatus der Pflanzen automatisch überwacht, um den genauen Bewässerungszeitpunkt und -ort zu ermitteln, ist eine enorme Unterstützung und Zeitersparnis für die Landwirte. Dennoch ist es eine große Herausforderung, das perfekte Gleichgewicht zwischen einer effizienten Wassernutzung und der maximalen Pflanzenproduktivität zu erreichen. Der Einsatz moderner Aufnahme- und Positionierungssensoren ermöglicht eine präzise und zielgerechte Bewässerung, die dem tatsächlichen Wasserbedarf jeder einzelnen Pflanze entspricht.

Das Projekt *PlantSens*, das vom Bundesministerium für Ernährung und Landwirtschaft (BMEL) in Verbindung mit dem Projektträger Bundesanstalt für Landwirtschaft und Ernährung (BLE) von 2017 bis 2020 gefördert wurde, verfolgt die Zielsetzung, ein multisensorisches Steuerungs- und Überwachungssystem für eine automatische Wasserstresserkennung von Nutzpflanzenbeständen zu entwickeln.

## 1.1 Pflanzenstress

Pflanzenstress kann in zwei Hauptkategorien unterteilt werden, nämlich in abiotischen Stress und biotischen Stress (Gull et al. 2019). Der abiotische Stress betrifft die physikalischen oder chemischen Änderungen in der Umgebung wie z.B. Trockenheit, übermäßige Bewässerung oder extreme Temperaturen, während biotische Faktoren organische Einflüsse, z. B. Krankheiten, Pilze oder Schädlinge, umfassen (Gull et al. 2019).

### 1.1.1 Wasserstress

Abiotischer Pflanzenstress, ausgelöst durch eine unzureichende Wasserversorgung, wird als Wasserstress bezeichnet und gehört zu einer der häufigsten Belastungsfaktoren, die vor allem bei den intensiven Produktionssystemen das Pflanzenwachstum deutlich schwächen und die Erträge verringern können. Da Wasser einen erheblichen Einfluss auf die physiologischen Funktionen von Pflanzen wie die Photosynthese und Nährstoffaufnahme aufweist, reagieren die meisten Kulturpflanzen bereits auf geringe Änderungen in der Wasserverfügbarkeit sehr empfindlich. So kann Wassermangel zu morphologischen Veränderungen am Pflanzenblatt führen. Symptome, die ohne zusätzliche Messgeräte mit bloßem Auge erkennbar sind, wie z. B. das Einrollen der Blätter aufgrund des Zellspannungsverlustes oder die Blattverbrennungen, deuten auf einen sehr fortgeschrittenen Zustand von Wasserstress hin, der bereits größere Schäden in der Gesunderhaltung der Pflanze verursachte. Die rechtzeitige Bestimmung und Behandlung des Wasserstresses verhindert die negative Auswirkung auf die Lebensprozesse der Pflanze.

### 1.1.2 Verfahren zur Wasserstresserkennung

Damit die Pflanzenbestände bedarfsgerecht bewässert werden können, muss der Stresszustand regelmäßig kontrolliert werden. Das bodenbasierte Messverfahren mittels Bodenfeuchtesensoren ist die konventionelle und leicht anwendbare Methode zur Bewässerungssteuerung anhand des erfassten Bodenwassergehalts. Da sich das Wasser im Boden nicht an allen Stellen gleichzeitig verteilt, entspricht der ermittelte Wasserstress nicht immer dem Grad, dem die Pflanze in der Wirklichkeit ausgesetzt ist. Somit könnte beispielsweise eine niedrigere Bodenfeuchte zum Zeitpunkt einer weniger intensiven Evapotranspiration adäquat sein (Seeling et al. 2009). Ein weiterer Nachteil ist die hohe Anzahl an Sensoren, erforderlich für die Heterogenität und präzise Überwachung, die das Gesamtsystem kosten- und wartungsintensiv machen.

Die fortgeschrittenen Messmethoden zur Ermittlung des Wassergehalts anhand des Wasserpotenzials mit Hilfe einer Druckkammer oder durch das Trocknungsverfahren sind wesentlich genauer, aber sehr zeitaufwändig (Berni et al. 2009, Nanda et al. 2018). In beiden Verfahren handelt es sich um eine invasive Messmethode, bei der das zu messende Blatt von der Pflanze entfernt werden muss. Darüber hinaus werden bei bodenbasierten und direkten Erfassungsmethoden die Stressparameter punktuell, d. h. an einer einzelnen Pflanze oder an einem Pflanzenteil erfasst, so dass nur die durchschnittlichen Bedingungen abgebildet werden können. Daher sind diese Verfahren aufgrund der begrenzten Anzahl von Messobjekten, die gleichzeitig überwacht werden können, für größere Pflanzenbestände nicht geeignet (Berni et al. 2009).

In den letzten Jahrzehnten haben indirekte Messungen vom Pflanzenstress aufgrund der technischen Verbesserung von optischen Sensoren an Bedeutung gewonnen. In zahlreichen Studien wurden unterschiedliche Indikatoren in Bezug auf die gemessene Temperatur der Pflanzenblattoberfläche und der Absorption der Lichtstrahlung von Wasser im Pflanzenblatt erforscht. Diese Methodik hat einen klaren Vorteil gegenüber der direkten Stresserkennung, da die Infrarot-Thermografie und die optische Spektroskopie keinen physischen Kontakt mit den Pflanzenblättern erfordern. Somit verläuft der Überwachungsprozess zerstörungsfrei. Im Gegensatz zu bodenbasierten und direkten Messverfahren können die Kameramodule eine flächenhafte Datenerfassung durchführen, indem sie auf beweglichen Plattformen montiert werden.

## 1.2 PlantSens

Im Rahmen des Projektes *PlantSens* wurde ein multisensoriales System entwickelt. Die Messung der Pflanzen erfolgt über eine selbstentwickelte photogrammetrische Apparatur mit einem integrierten Positionierungssystem (Rojek et al. 2019b).



**Abb. 1:** Praktischer Einsatz der Aufnahmeapparatur an *Solanum lycopersicum* (Tomatenpflanzen) im Gewächshaus der Berliner Hochschule für Technik

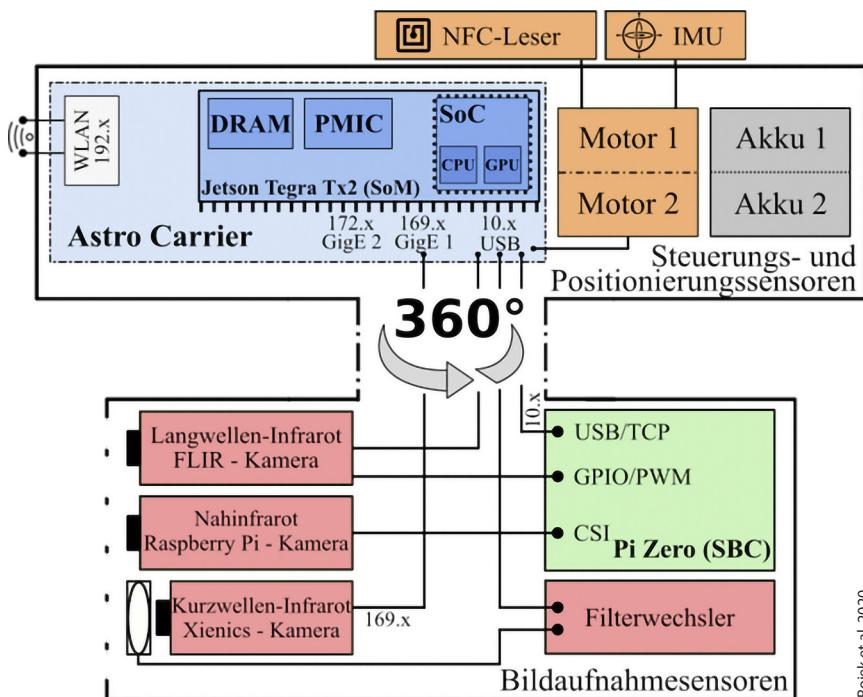
Die Messeinheit ist auf einer beweglichen Trägerplattform an einem Schienensystem direkt über der Pflanzenkultur (siehe Abb. 1) montiert, wodurch die Durchführung eines berührungslosen Messverlaufes in kontinuierlichen Messintervallen möglich ist (Rojek et al. 2020). Es werden nur die oberen Pflanzenblätter photogrammetrisch erfasst. Die Aufnahme erfolgt aus einer kurzen Entfernung von ca. einem Meter senkrecht zur Fahrtrichtung des Systems. Ein Schrittmotor bewegt das Kamerasystem mit einer konstanten Schrittgeschwindigkeit zwischen den Pflanzenreihen fort. Ein zusätzlicher Motor bestimmt die horizontale Orientierung der Aufnahmeeinrichtung, so dass die Pflanzen bei der Hin- und Rückfahrt von beiden Seiten aufgenommen werden können (Rojek et al. 2020). Das Messsystem ist so konzipiert, dass es von der schienenbasierten Trägerplattform abmontiert und für eine stationäre Messung eingesetzt werden kann.

## 2 Multisensor-Messsystem

Das Multisensor-Messsystem besteht aus einer Kombination mehrerer Sensor-elemente, die unterschiedliche Messgrößen mit verschiedenen Aufnahmeprinzipien erfassen, um schließlich die Zielgröße, den Wasserbedarf der Pflanzen, zu bestimmen. Die Messmodule sind in zwei technische Bereiche aufgeteilt und in Abb. 2 schematisch dargestellt. So befinden sich die Steuerungs- und Positionierungssensoren im oberen und die Bildaufnahmesensoren im unteren Teil des Gehäuses. Das untere Bauteil lässt sich um 360° drehen, sodass die Pflanzen von unterschiedlichen Blickwinkeln photogrammetrisch aufgenommen werden können (Rojek et al. 2020).

### 2.1 Netzwerkarchitektur

Ein fundamentaler Bestandteil eines Überwachungssystems ist die Netzwerkarchitektur, die für eine sichere und stabile Datenübertragung zwischen einzelnen Systemkomponenten sorgt. Das Pflanzen-Monitoring-System basiert auf einem Client-Server-Modell bestehend aus einem Multisensor-Messsystem (MSMS) zur Bild- und Positionsaunahme von Pflanzen, einer Wetterstation zur Erfassung der meteorologischen Informationen und einem zentralen Server zur Speicherung, Auswertung und Visualisierung der Messdaten (Rojek et al. 2019b). Bei der Umsetzung dieses Konzeptes wurde die bereits existierende Netzwerkinfrastruktur der Berliner Hochschule für Technik (BHT) verwendet und um ein eigenes lokales Netzwerk innerhalb des Gewächshauses mittels eines WLAN-Routers erweitert (Rojek et al. 2020). Der Server und Router sind über



Rojek et al. 2020

Abb. 2: Aufbau des Multisensor-Messsystems

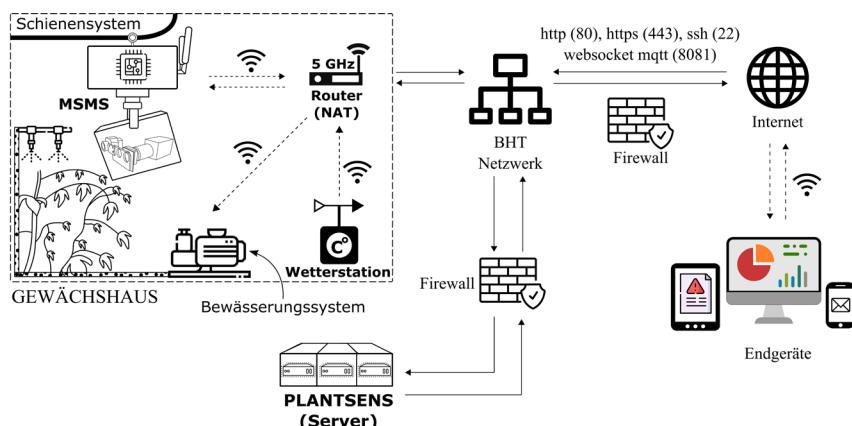


Abb. 3: Netzwerkarchitektur des PlantSens-Monitoringsystems

eine physische Leitung (LAN) an das BHT-Netzwerk angeschlossen, so dass sie miteinander kommunizieren können. Da die Messsensoren auf einer beweglichen Trägerplattform montiert sind, erfolgt die Datenübertragung drahtlos über die 5 GHz-Funkleitung (WLAN) des Routers, der den Zugriff auf den Server gewährleistet (Rojek et al. 2020). Die Netzwerkarchitektur ist in Abb. 3 präsentiert.

Die einzelnen Monitoringdienste auf dem Zentralserver, u. a. das Dateisystem, die Datenbank, webbasierte Applikationen und Steuerungsprozesse, sind in getrennte virtuelle Umgebungen (Container) aufgeteilt worden. Dies ermöglicht eine bessere Isolation der Anwendungsprozesse und eine effiziente Benutzung der Hardwareressourcen, die nach Bedarf dynamisch partitioniert werden (Rojek et al. 2021).

Der externe Zugriff auf das System außerhalb des Hochschulnetzwerkes wird sowohl durch die Firewall der Hochschule als auch die Firewall des PlantSens-Servers überprüft (Rojek et al. 2021).

## 2.2 Kommunikation

Ein automatisiertes Steuerungssystem erfordert ein Echtzeit-Kommunikationsprotokoll zur Integration der großen Anzahl von Sensoren und Aktuatoren. Hierfür wurde das Message Queue and Telemetry Transport (MQTT)-Protokoll verwendet, das im Internet der Dinge (Internet of Things – IoT) zu einem ISO-Standard (ISO/IEC 20922) geworden ist. MQTT ist eine leichtgewichtige Machine-to-Machine (M2M) Kommunikationsmethode zur Nachrichtenübertragung zwischen Sendern und Empfängern über einen zentralen Broker. Diese Technologie verwendet das Publish/Subscribe-Konzept, ein sogenanntes ereignisbasiertes Kommunikationsmodell, das in Abb. 4 dargestellt ist.

Ein Ereignis (event) repräsentiert eine Information, die ein Client mit anderen Geräten teilt. Dabei kann es sich um eine physikalische Messgröße eines Sensors, wie z. B. Lufttemperatur oder um eine Handlungsanforderung an einen Aktuator, handeln. Jede einzelne Nachricht wird mit einem Namen (topic) versehen. Ein Gerät (Client) kann eine bestimmte Nachricht, ein Ereignis, senden (publish) oder sich für ein bestimmtes Thema registrieren (subscribe), um andere Ereignisse zu empfangen. Die Datenübertragung wird von einer zentralen Einheit, dem Broker (Server), gesteuert. Der Broker ist für das Empfangen der Ereignisse, die Filterung der Themen und die Weiterleitung der Nachrichten an die interessierten Clients zuständig.

Im Gegensatz zu den Nachrichtenhalten, die beliebig sein können, muss der Topic-Name einem bestimmten Muster folgen. So kann der Topic-Name mittels des Vorwärtsschrägstrichs „/“ hierarchisch strukturiert werden (Blankenbach und Herle, 2017). Des Weiteren bietet MQTT zwei Wildcard-Optionen:

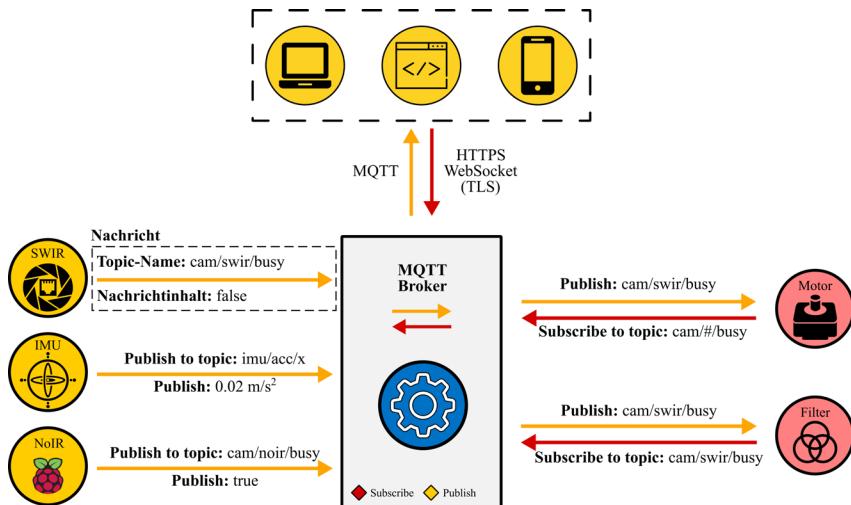


Abb. 4: Schematische Darstellung der Funktionsweise des MQTT-Kommunikationsprotokolls

Single-Level (+) und Multi-Level (#). Beispielsweise könnte sich der Schrittmotor auf den Topic-Namen `cam/swir/busy` abonnieren, um den aktuellen Status der Kurzwelleninfrarotkamera zu erhalten. Sobald die Kamera keine Bilddaten mehr erfasst, kann der Motor weiterfahren. Angenommen der Schrittmotor ist an dem Status aller Kameramodule interessiert, so müsste der einstufige Platzhalter (Single-Level) im Topic-Filter `cam/+/#/busy` verwendet werden. Um alle Nachrichten der Kurzwelleninfrarotkamera zu erhalten, wird der mehrstufige Platzhalter (Multi-Level) im Topic-Filter `cam/swir/#` benutzt. Wenn der Topic-Name mit dem Topic-Filter übereinstimmt, werden die Informationen an die registrierten Clients weitergeleitet.

Das MQTT-Protokoll unterstützt eine dreistufige Dienstgüte (Quality of Service – QoS): 0 – höchstens einmal, 1 – mindestens einmal, 2 – genau einmal. Die niedrigste Stufe 0 garantiert, dass die Nachricht höchstens einmal ankommt. Die Stufen 1 und 2 sind fortgeschrittene Methoden, die die Zuverlässigkeit der Nachrichtenübermittlung erhöhen. Während QoS 1 dafür sorgt, dass das Ereignis mindestens einmal zugestellt wird, stellt QoS 2 sicher, dass keine Duplikate dabei entstehen.

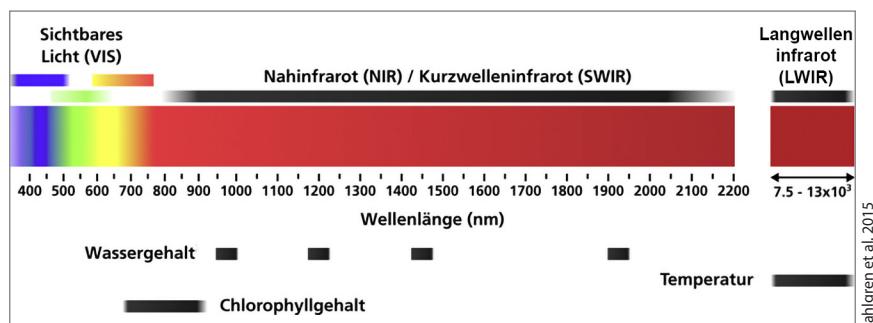
Der letzte Wille (Last Will and Testament – LWT) ist ein besonderes Ereignis, das vom Broker stellvertretend ausgeführt wird, sobald der Client die Verbindung zum Broker verloren hat. Beispielsweise wird die Messapparatur automatisch angehalten, sobald keine Kommunikation mehr zwischen dem Broker und Positionssensoren besteht.

## 2.3 Positionierungssensoren

Eine präzise Positionsbestimmung der photogrammetrischen Messapparatur steht im Mittelpunkt einer ressourcenschonenden Bewässerung. Damit die Pflanzen gemäß dem festgestellten Wasserbedarf zielgerecht irrigiert werden können, muss ihre Position zum Zeitpunkt der Bildaufnahme erfasst werden (Rojek et al. 2019b). Die Positionsbestimmung des Aufnahmesystems im Gewächshaus beruht auf dem Prinzip der Koppelnavigation, bei der die Positionsänderungen anhand der aktuellen Geschwindigkeit und der Richtung berechnet werden. Hierfür wurden ein Schrittmotor und eine inertiale Messeinheit (Inertial Measurement Unit – IMU) miteinander kombiniert (Rojek et al. 2020). Die ermittelten Positionsunterschiede werden jeweils auf den letzten bekannten Standpunkt aufaddiert, um die neue Position zu bestimmen. Dies bedeutet jedoch, dass der Positionsfehler aufgrund der Messgenauigkeiten der Sensoren ebenfalls summiert wird und proportional zu der Zeit wächst. Um die sämtlichen Driftprobleme zu vermeiden, werden zusätzliche Stützinformationen, Referenzpunkte (Landmarker), in Form von NFC-Marker hinzugezogen.

## 2.4 Bildaufnahmesensoren

Die Bildaufnahmeapparatur besteht aus drei unterschiedlichen Kamerasensoren, die hauptsächlich in Wellenlängenbereichen außerhalb des sichtbaren Lichtspektrums von 400 nm bis 13.500 nm arbeiten (siehe Abb. 5). So mit können Informationen über die Einflussfaktoren erfasst werden, die den



**Abb. 5:** Pflanzenblätter interagieren mit den Wellenlängen des sichtbaren Spektrums (VIS, 400–780 nm), des nahen Infrarots (NIR, 780–1000 nm), des kurzwelligen Infrarots (SWIR, 1000–3000 nm, auch mittleres Infrarot genannt) und im Thermalbereich der langwelligen Infrarotstrahlung (LWIR, 7500 nm–13.500 nm).

Wasserstress bei Pflanzen verursachen, aber für das menschliche Auge unsichtbar sind (Rojek et al. 2019a). Des Weiteren sind die Kameramodule mit zusätzlichen Filtern ausgestattet, sodass die optischen Sensoren nur auf die für Pflanzen relevante Spektralbereiche empfindlich sind. Die Bildaufnahme der Pflanzenbestände erfolgt mit einer Nah-Infrarot-Digitalkamera (Visible Near-Infrared – VNIR) zur Zielflächenerkennung, die kurzwellige Infrarotkamera (Short-Wave Infrared – SWIR) zur Ermittlung der Reflexionsintensität des Wassers im Pflanzengewebe und die langwellige Infrarot-Wärmebildkamera (Long-Wave Infrared – LWIR) zur Messung der Oberflächentemperatur der Pflanzenblätter (Rojek et al. 2019b).

#### 2.4.1 Vegetationsindex (NDVI)

Der Normierte Differenzierte Vegetationsindex (Normalized Difference Vegetation Index – NDVI) ist ein Parameter, der die Chlorophyllaktivität der Pflanzen widerspiegelt und somit für die Zielflächenerkennung geeignet ist. Die hohe Chlorophyllaktivität verursacht eine starke Reflexion im Bereich der Infrarotstrahlung, während eine geringe Chlorophyllaktivität eine niedrigere Rückstrahlung des Infrarotsignals generiert (Rojek et al. 2019a).

Der Vegetationsindex wird mit Hilfe einer kostengünstigen *Raspberry Pi* Kamera mit eingebautem *Sony IMX-219 CMOS-Sensor* und entferntem Infrarotfilter aus den Reflexionsdifferenzen im Bereich der Nahinfrarotstrahlung (NIR) und des roten Lichtes (R) ermittelt. Die Berechnung der NDVI erfolgt nach Rouse et al. (1974):

$$\text{NDVI} = \frac{\text{NIR} - \text{R}}{\text{NIR} + \text{R}} \quad (1)$$

Der Umriss des Pflanzenobjektes wird auf das Wärmebild und Kurzwelleninfrarotbild übertragen.

#### 2.4.2 Wasserindex (WI)

Die Wasserstresserkennung basiert auf der Kombination zweier verschiedener photogrammetrischer Aufnahmemethoden. Das erste Messverfahren basiert auf der Tatsache, dass das Wasser im kurzwelligen Infrarotspektrum, insbesondere in den Bereichen 970 nm, 1200 nm, 1450 nm und 1950 nm (Clevers et al. 2007), eine hohe Absorption der Lichtstrahlung aufweist. Der Wasserindex lässt sich aus den Messwerten der höheren Absorption bei 1450 nm und den

Reflexionswerten der niedrigen Absorption bei 1300 nm bestimmen. Der Wasserindex berechnet sich nach Seelig et al. (2009) zu:

$$WI = \frac{SWIR_{1300}}{SWIR_{1450}} \quad (2)$$

Da die Kurzwelleninfrarotkamera *Xenics Bobcat 320 GigE* den gesamten Wellenlängenbereich von 900 nm bis 1700 nm erfasst, ist es erforderlich zusätzliche Filter einzubauen, sodass der Sensor nur die für Pflanzen signifikanten Spektralbereiche empfängt (Rojek et al. 2020).

### 2.4.3 Crop Water Stress Index (CWSI)

Die zweite Messmethode ermittelt den Wasserbedarf der Pflanze anhand der Blatttemperatur, die in einem direkten Zusammenhang mit der Transpirationsleistung und Leitfähigkeit der Stomata (Spaltöffnungen) steht (Leinonen und Jones 2004). Der Wasserstressindex (Crop Water Stress Index – CWSI) wird nach Idso et al. (1981) und Jackson et al. (1981) wie folgt ermittelt:

$$CWSI = \frac{T_{Blatt} - T_{Feucht}}{T_{Trocken} - T_{Feucht}} \quad (3)$$

Dabei beschreiben die Variable  $T_{Blatt}$  die aktuelle Blatttemperatur,  $T_{Trocken}$  und  $T_{Feucht}$  jeweils die Temperatur bei komplett geschlossenen bzw. geöffneten Stomata (Jones 1999, Cohen et al. 2005). Die beiden Grenzwerte für die minimale und maximale Blatttemperatur können im Laufe des Tages variieren und müssen unter Berücksichtigung der klimatischen Bedingungen bestimmt werden.

Die Oberflächentemperatur der Pflanze wird mit einer Wärmebildkamera *FLIR Vue Pro* ermittelt. Um möglichst präzise Temperaturwerte zu bekommen, müssen bei der Infrarot-Thermografie Einflussgrößen wie die atmosphärische Transmission, Emissionsgrad und die Auswirkung der Hintergrundobjekte berücksichtigt werden (Rojek et al. 2019a).

## 3 Messungen und Ergebnisse

Das Ziel der Messungen mit dem PlantSens-System ist eine rechtzeitige Bestimmung des Bewässerungsschaltpunktes auf der Grundlage der Bilddatenanalyse der Thermal- und SWIR-Kamera in Abhängigkeit der Wetterdaten. Die Messungen haben im Gewächshaus der Berliner Hochschule für Technik an Toma-

tenbeständen stattgefunden. Während der Datenerfassung wurden die Pflanzen nicht bewässert, um Messwerte zu erhalten, die einen zunehmenden Bewässerungsbedarf darstellen. Die physiologische Reaktion auf die abnehmende Wasser Verfügbarkeit unter den gegebenen Umweltbedingungen wurde anhand des Gaswechsels mit einem GFS 3000 der Firma Walz überwacht. Des Weiteren wurden die Messwerte mit einem Wet-Bulb-Globe-Temperatur (WBGT)-Messsystem, einem Anemometer, einem Strahlungssensor (Photosynthetically Active Radiation – PAR) und mit Thermoelementen an feucht gehaltenen und mit Vaseline abgedeckten Blättern erhoben, um Annäherungswerte für die minimale und maximale Blatttemperatur bei maximaler und minimaler Verdunstungsraten zur Kontrolle zu erhalten. Das WBGT-System stellte Messwerte der Strahlungstemperatur, der Lufttemperatur und der Feuchttemperatur zur Verfügung, welche für die Berechnung der minimalen und maximalen Blatttemperatur notwendig sind. Die Messungen wurden nicht unter konstanten Außenbedingungen, sondern unter den von den äußeren Klima- und Einstrahlungsbedingungen abhängigen Bedingungen im Gewächshaus durchgeführt, um die Auswirkungen der wechselnden Bedingungen auf Messwerte und Messtechnik zu berücksichtigen.

### 3.1 Ermittlung der maximalen und minimalen Blatttemperatur

Bevor die Entwicklung eines Auswerteverfahrens für die Ermittlung eines Bewässerungsschaltpunktes mithilfe von CWSI und Reflexionsindex erfolgen konnte, mussten die Zusammenhänge zwischen den erhobenen Umweltdaten und den minimalen und maximalen Blatttemperaturen untersucht werden. Für die Analyse des Zusammenhangs zwischen den Umweltdaten und den gemessenen Temperaturen eines angefeuchteten Blattes und eines mit Vaseline überzogenen Blattes wurde eine multiple lineare Regression durchgeführt.

Der Zusammenhang der minimalen und maximalen Blatttemperaturen mit Lufttemperatur  $t_{Luft}$ , Feuchttemperatur  $t_{feucht}$  und Strahlungstemperatur  $t_{globe}$  konnte für den unteren Grenzwert  $t_{wet}$  mit einem Bestimmtheitsmaß  $R^2$  von 0,72 und für den oberen Grenzwert  $t_{dry}$  mit einem  $R^2$  von 0,70 nachgewiesen werden. Die Messwerte des Anemometers und des PAR-Sensors führten zu keiner Verbesserung, so dass diese Daten zumindest für den Einsatz im Gewächshaus außer Acht gelassen werden konnten.

Folgende Regressionsgleichungen wurden verwendet:

$$t_{dry} = 4,35 - 0,033 \cdot t_{globe} + 1,03 \cdot t_{Luft} - 0,17 \cdot t_{feucht} \quad [^\circ\text{C}] \quad (4)$$

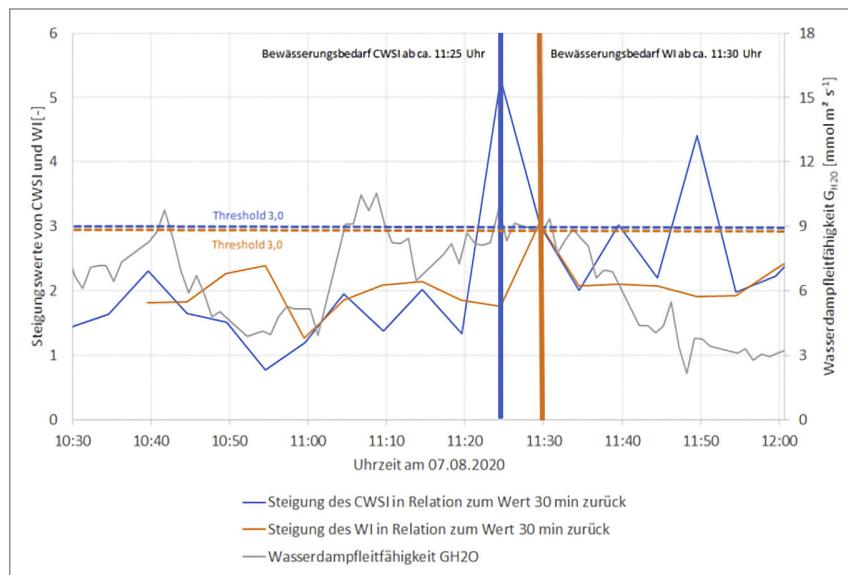
$$t_{wet} = 3,82 - 0,053 \cdot t_{globe} + 0,64 \cdot t_{Luft} - 0,17 \cdot t_{feucht} \quad [^\circ\text{C}] \quad (5)$$

Diese Regressionsgleichungen wurden in nachfolgenden Messserien für die Berechnung der Temperaturgrenzwerte des CWSI zur Entwicklung eines Verfahrens für die Bestimmung des Bewässerungszeitpunktes eingesetzt.

### 3.2 Bestimmung des Bewässerungsschaltpunktes

Für die folgende Beschreibung des Verfahrens wurden Messungen vom 07.08.2020 ausgewählt. Die wechselnden Bedingungen führten dazu, dass die Messwerte hohen Schwankungen unterlagen. Zusätzlich reagieren Pflanzen sehr dynamisch auf unterschiedliche Außenbedingungen, sodass sich deren Reaktionen ebenfalls auf die Messwerte auswirkten. Dennoch konnte anhand der Messdaten der Bewässerungsschaltpunkt ermittelt werden.

Hierfür wurde die Steigung von CWSI und WI in Relation zum Wert 30 min zurück ermittelt. Die Bildaufnahmen erfolgten jedoch alle 5 min. In einer späteren Anwendung hängt der Zeitraum zwischen der Aufnahme der Bilder für die gleiche Position von der Größe der Kulturläche, der Geschwindigkeit der Bewegung des Messsystems durch den Bestand und der Größe eines



**Abb. 6:** Zeitausschnitte aus der Messung am 07.08.2020 an *Solanum lycopersicum* im Gewächshaus mit relativen Steigungsverläufen von CWSI und WI in Verbindung mit dem Verlauf der Wasserdampfleitfähigkeit  $G_{H_2O}$  mit Angabe einer Threshold für die Steigungs-werte, ab deren Erreichen ein Bewässerungsimpuls ausgelöst werden sollte.

Bewässerungskreises ab. Eine Bildaufnahme pro 30 min ist durchaus realistisch, sodass hier diese Zeitspanne verwendet wurde.

Um einen Schaltpunkt für die Auslösung eines Bewässerungsimpulses zu definieren, wurden in Abb. 6 Zeitbereiche herausgelöst, in denen mit hoher Wahrscheinlichkeit ein Bewässerungsimpuls hätte erfolgen müssen. Die entsprechenden Zeitbereiche wurden anhand der sinkenden Wasserdampfleitfähigkeiten ausgewählt. Eine sinkende Wasserdampfleitfähigkeit gab dabei einen Hinweis auf eine sinkende Wasserverfügbarkeit in der Pflanze und einen zunehmenden Bewässerungsbedarf. Für die Ansteuerung eines Bewässerungsimpulses wurde aus den Verläufen der Grenz- beziehungsweise Schaltwert (Threshold) abgeleitet. Die Ableitung der Threshold-Werte für die Steigung der CWSI- und WI-Werte war dabei vorerst willkürlich und orientierte sich nur an den sinkenden Wasserdampfleitfähigkeiten. Die Threshold-Werte für den CWSI und den WI waren in diesem Beispiel gleich. In zukünftigen Praxisversuchen sollte geklärt werden, ob mittels dieser Schaltwerte die Bewässerung gesteuert werden kann.

Die in Abb. 6 angegebenen Schaltpunkte liegen dicht beieinander, so dass hier beide zuvor genannten Annahmen zu einem ähnlichen Ergebnis führen würden.

Im weiteren Verlauf der Verarbeitung der Ergebnisse muss der Bewässerungsimpuls für die entsprechenden Bewässerungskreise ausgelöst werden. Alle Bildaufnahmen sind georeferenziert, das heißt, dass die Position der aufgenommenen Pflanzenbestände bekannt ist. Die Schnittstelle zum entsprechenden Bewässerungskreis muss je nach Bewässerungssystem angepasst werden. Es ist möglich, über Relaiskartensysteme unterschiedliche Bewässerungskreise direkt über den Server anzusteuern. Eine andere Variante wäre, den Bewässerungsimpuls verknüpft mit einer Adresse für einen Bewässerungskreislauf an einen dezentralen Bewässerungscomputer oder einen zentralen Klimacomputer zu übermitteln, so dass von diesen Systemen die Bewässerung ausgelöst werden könnte.

## 4 Fazit

Wie genau lokal begrenzt und bedarfsgerecht bewässert werden kann, hängt von der Art des Bewässerungssystems und dem Aufwand dieses in unterschiedliche Bewässerungskreise aufzuteilen ab. Ein Tropfbewässerungssystem unter Glas lässt sich beispielsweise in unterschiedliche Pflanzreihen aufteilen und über georeferenzierte Magnetventile ansteuern. Ein Gießwagen im Freiland könnte positionsgerecht die Bewässerung einzelner Bereiche unterhalb des Gießgestänges bewässern. Dabei muss sichergestellt werden, dass der Gießwagen seine Position im Bestand selbst bestimmen kann (zum Beispiel über GPS oder die Laufzeit)

und er die Geodaten der Zielflächen erhält. Vergleichbare Systeme könnte man für Bewässerungsmaschinen, Linearberegnungen und festinstallierte Bewässerungssysteme im Freiland konzipieren.

Im Rahmen des Nachfolgeprojektes *PlantSens II* wird das Pflanzenmonitoringsystem weiterentwickelt. Hierfür werden die Methoden zur Bilddatenübertragung über lange Wegstrecken untersucht, sodass die Messeinheit für die Aufnahme von Nutzpflanzen im Freiland mit UAV geeignet ist. Des Weiteren wird die Apparatur zusätzlich mit einer Hyperspektralkamera ausgestattet, um den Gesundheitszustand (Nährstoffmangel, Schädlingsbefall) der Pflanzen erfassen zu können.

Gefördert durch



Bundesministerium  
für Ernährung  
und Landwirtschaft

Projektträger



Bundesanstalt für  
Landwirtschaft und Ernährung

aufgrund eines Beschlusses  
des Deutschen Bundestages

## Literatur

- Berni, J. A. J., Zarco-Tejada, P. J., Sepulcre-Cantó, G., Fereres, E., Villalobos, F. (2009): Mapping canopy conductance and cwsı in olive orchards using high resolution thermal remote sensing imagery. In: Elsevier, *Remote Sensing of Environment*, Band 113 (11), 2380–2388. DOI: [10.1016/j.rse.2009.06.018](https://doi.org/10.1016/j.rse.2009.06.018).
- Blankenbach, J., Herle, S. (2017): Echtzeit-Geodaten im Internet der Dinge. In: Kolbe, T., Bill, R., Donaubauer, A. (Hrsg.): *Geoinformationssysteme*, Wichmann Verlag, Berlin, 2-18. ISBN: 978-3-87907-626-0, ISBN: 978-3-87907-628-4.
- Clevers, J. G. P. W., Kooistra, L., Schaepman, M. E. (2007): Canopy water content retrieval from hyperspectral remote sensing. In: ISPRS Working Group VII/1 Workshop ISPMRS'07: Physical Measurements and Signatures in Remote Sensing. [www.isprs.org/proceedings/XXXVI/7-C50/papers/P12.pdf](http://www.isprs.org/proceedings/XXXVI/7-C50/papers/P12.pdf), letzter Zugriff 07/2022.
- Cohen, Y., Alchanatis, V., Meron, M., Saranga, Y., Tsipris, J. (2005): Estimation of leaf water potential by thermal imagery and spatial analysis. In: *Journal of Experimental Botany*, Band 56 (417), 1843–1852. DOI: [10.1093/jxb/eri174](https://doi.org/10.1093/jxb/eri174).
- Fahlgren, N., Gehan, M. A., Baxter, I. (2015): Lights, camera, action: high-throughput plant phenotyping is ready for a close-up. In: Elsevier, *Current Opinion in Plant Biology*, Band 24, 93–99. DOI: [10.1016/j.pbi.2015.02.006](https://doi.org/10.1016/j.pbi.2015.02.006).
- González-Dugo, M. P., Moran, M. S., Mateos, L., Bryant, R. (2006): Canopy temperature variability as an indicator of crop water stress severity. In: *Irrigation Science*, Springer-Verlag, Band 24, 233–240. DOI: [10.1007/s00271-005-0022-8](https://doi.org/10.1007/s00271-005-0022-8).

- Govender, M., Dye, P.J., Welersbye, I. M., Witkowski, E. T.F., Ahmed, F. (2009): Review of commonly used remote sensing and ground-based technologies to measure plant water stress. In: Water SA, Band 35 (5), 741–752.
- Gull, A., Lone, A. A., Wani, N.U.I. (2019): Biotic and Abiotic Stresses in Plants. In: de Oliveira, A. (Hrsg.): Abiotic and Biotic Stress in Plants, IntechOpen. DOI: [10.5772/intechopen.85832](https://doi.org/10.5772/intechopen.85832).
- Idso, S. B., Jackson, R. D., Pinter, P. J., Reginato, R. J., Hatfield, J. L. (1981): Normalizing the stress-degree-day parameter for environmental variability. In: Agricultural Meteorology, Band 24, 45–55. DOI: [10.1016/0002-1571\(81\)90032-7](https://doi.org/10.1016/0002-1571(81)90032-7).
- Jackson, R. D., Idso, S. B., Reginato, R. J., Pinter, P. J. (1981): Canopy temperature as a crop water stress indicator. In: Water Resources Research, Band 17, 1133–1138. DOI: [10.1029/WR017i004p01133](https://doi.org/10.1029/WR017i004p01133).
- Jones, H.G. (1999): Use of infrared thermometry for estimation of stomatal conductance as a possible aid to irrigation scheduling. In: Elsevier, Agricultural and Forest Meteorology, Band 95, 139–149. DOI: [10.1016/S0168-1923\(99\)00030-1](https://doi.org/10.1016/S0168-1923(99)00030-1).
- Leinonen, I., Jones, H.G. (2004): Combining thermal and visible imagery for estimating canopy temperature and identifying plant stress. In: Journal of Experimental Botany, Band 55 (401), 1423–1431. DOI: [10.1093/jxb/erh146](https://doi.org/10.1093/jxb/erh146).
- Nanda, M. K., Giri, U., Bera, N. (2018): Canopy Temperature-Based Water Stress Indices: Potential and Limitations. In: Bal, S., Mukherjee, J., Choudhury, B., Dhawan, A. (Hrsg.): Advances in Crop Environment Interaction, Springer, 365–385. DOI: [10.1007/978-981-13-1861-0\\_14](https://doi.org/10.1007/978-981-13-1861-0_14).
- Rojek, L., Hehl, K., Möller, M., Richter, M., Bischoff-Schaefer, M. (2019a): Entwicklung eines sensorgestützten Steuerungssystems für eine ressourcen-schonende Bewässerung in der Landwirtschaft von Feld- und Fruchtgemüse auf der Basis der Nahbereichsfotogrammetrie (PLANTSENS). In: Forum GeoBau: Urbane Konzepte und Entwicklungen, Shaker Verlag, Band 9, Aachen, 2019, 55–67. ISBN 978-3-8440-6272-4.
- Rojek, L., Hehl, K., Möller, M., Richter, M., Bischoff-Schaefer, M. (2019b): Strategie für die Entwicklung eines photogrammetrischen Überwachungssystems für eine ressourcenschonende und automatisierte Bewässerung von Nutzpflanzenbeständen im Freiland- und im geschützten Anbau (PLANTSENS). In: AGIT – Journal für Angewandte Geoinformatik, Wichmann Verlag, Band 5, Berlin, 2019, 87–99. DOI: [10.14627/537669008](https://doi.org/10.14627/537669008).
- Rojek, L., Hehl, K., Möller, M., Richter, M., Bischoff-Schaefer, M. (2020): Netzwerk-basiertes Multi-Sensor-Messsystem für eine automatische Bewässerung von Nutzpflanzenbeständen im Gewächshaus (PLANTSENS). In: AGIT – Journal für Angewandte Geoinformatik, Wichmann Verlag, Band 6, Berlin, 2020, 146–160. DOI: [10.14627/537698014](https://doi.org/10.14627/537698014).
- Rojek, L., Trefz, A., Glende, W., Möller, M., Richter, M., Bischoff-Schaefer, M. (2021): Serverstruktur, Vernetzung und Prozessierung von Sensordaten im PLANTSENS-Projekt – das technische Fundament eines Monitoringsystems im Gartenbau. In: AGIT – Journal für Angewandte Geoinformatik, Wichmann Verlag, Band 7, Berlin, 2021, 211–226. DOI: [10.14627/537707023](https://doi.org/10.14627/537707023).

- Rouse, J. W., Haas, R. H., Schell, J. A., Deering, D. W., Harlan, J. C. (1974): Monitoring the vernal advancement and retrogradation of natural vegetation. <https://ntrs.nasa.gov/archive/nasa/casi.ntrs.nasa.gov/19750020419.pdf>, letzter Zugriff 07/2022.
- Seeling, H.-D., Hoehn, A., Stodieck, L. S., Klaus, D. M., Adams, W. W., Emery, W. J. (2009): Plant water parameters and the remote sensing R1300/R1450 leaf water index: controlled condition dynamics during the development of water deficit stress. In: Irrigation Science, Band 27 (5), 357–365. DOI: [10.1007/s00271-009-0152-5](https://doi.org/10.1007/s00271-009-0152-5).

### Kontakt

M. Sc. Lukasz Rojek | Prof. Dr. habil. Matthias Möller | Prof. Dr. Markus Richter  
Berliner Hochschule für Technik  
Luxemburger Straße 10, 13353 Berlin  
[lukasz.rojek@bht-berlin.de](mailto:lukasz.rojek@bht-berlin.de)

# Positionierung von E-Bikes eines Free-Floating E-Bike-Sharing-Systems

Paul Rawiel

## 1 Einleitung

In diesem Beitrag wird die Integration verschiedener Sensoren zur Bestimmung der Position sich bewegender Fahrzeuge vorgestellt. Die ständige Zunahme der Bevölkerung in urbanen Räumen und das damit einhergehende Wachstum des Verkehrsaufkommens führt in Zeiten, in denen die Auswirkungen des Klimawandels immer stärker spürbar werden, dazu, dass die Entwicklung neuer Mobilitätskonzepte als dringend notwendig erachtet wird und den Weg auch auf die Agenda der Politik gefunden hat. Sharing-Systeme mit emissionsfreien Antrieben wie z. B. E-Bikes können hier einen Beitrag leisten, Luftverschmutzung und Lärm in Städten zu reduzieren und damit die Lebensqualität in urbanen Räumen zu steigern. Bei Sharing-Systemen ohne bestimmte Standorte der E-Bikes, an denen sie abgeholt und zu denen sie wieder zurückgebracht werden, ist eine verlässliche Positionierung der E-Bikes von entscheidender Bedeutung. Effiziente, durchgängige und kostengünstige Methoden die E-Bikes zu lokalisieren werden benötigt, sowohl um Kunden korrekte Positionen verfügbarer E-Bikes anzugeben und bei einer Fahrt verlässlich zu navigieren, als auch für die Servicemitarbeiter des Sharing-Anbieters. In den meisten Fällen genügt die Genauigkeit einer einfachen Positionierung mittels GNSS. Gerade in urbanen Umgebungen kommt es jedoch öfter zu Ungenauigkeiten aufgrund von Mehrwegausbreitung, Signalbeugung und Abschattung der Satellitensignale. Dies kann bis zum zeitlich begrenzten Ausfall der Positionierung führen. Verschiedene Low-Cost-Sensoren kommen hier in Frage, um eine Trajektorie der gefahrenen Strecke aufzuzeichnen, die ein E-Bike, ab dem Zeitpunkt, ab dem die GNSS-Position nicht mehr verlässlich genug ist, zurückgelegt hat. Um einen zeitlich begrenzten Ausfall von GNSS zu kompensieren wird die Methode der Koppelnavigation (engl.: Dead Reckoning) auf der Basis von zusätzlichen Sensoren wie Gyroskope und Beschleunigungssensoren angewendet. In früheren Untersuchungen mit einem Car-Sharing-System wurden hier schon Erfolge erzielt, allerdings lassen sich dort durch unterschiedliche Geschwindigkeiten der Räder der Hinterachse Kurvenradien berechnen sowie durch die 42 Sensorimpulse bei einer kompletten Radumdrehung auch wesentlich genauere gefahrene Strecken ermitteln als bei einem E-Bike mit nur einem Sensorimpuls pro Radumdrehung.

## 2 Material und Methoden

Die Koppelnavigation ist eine Methode zur Navigation, die GNSS für einen bestimmten Zeitraum ersetzen kann. Bei der Koppelnavigation wird die aktuelle Position relativ zu einer vorherigen Position bestimmt, in dem man die bekannte Geschwindigkeit und Bewegungsrichtung in einem bestimmten Zeitintervall nutzt, um daraus die aktuelle Position zu berechnen. Für die Koppelnavigation wird also eine Anfangsposition, eine Bewegungsrichtung und die Geschwindigkeit als bekannt vorausgesetzt. Da diese Navigationsmethode nur begrenzte Ausfallzeiten des GNSS-Signals überbrücken soll, kann diese Voraussetzung als erfüllt angesehen werden. Um im weiteren Verlauf Geschwindigkeiten und Bewegungsrichtungen ermitteln zu können wird eine sogenannte Inertial Measurement Unit (IMU) verwendet. Eine IMU besteht aus einem dreiachsigen Beschleunigungssensor, der Beschleunigungen in alle drei Raumrichtungen misst und einem Drehratensensor, der die Drehraten um die drei Raumachsen misst. Solche IMUs werden zu unterschiedlichen Zwecken in unterschiedlichen Sensorplattformen integriert. Die Kalibrierung der IMU spielt bei der Verwendung zur Navigation eine entscheidende Rolle. Sowohl Bias als auch die Drift der Sensoren führen zu einem Positionsfehler, der sich über die Zeit aufaddiert und sehr schnell zu unbrauchbaren Ergebnissen führt. Die Kalibrierdaten bleiben zudem über die Zeit nicht konstant, sondern verändern sich in relativ kurzen Zeiträumen signifikant. Dies wiederum bedeutet, dass die Korrekturparameter für die Sensoren regelmäßig neu bestimmt werden müssen. Eine Möglichkeit hierzu ist, die IMU über ein Kalman-Filter mit dem GNSS zu integrieren und in diesem Zuge die Kalibrierparameter als unbekannte Parameter mit schätzen zu lassen, um sie dann, bei Ausfall des GNSS-Signals, verwenden zu können. Die Sensorintegration allgemein ist bei Groves (2013) oder Grewal et al. (2020) beschrieben. Auch die zeitliche Synchronisation der Sensordaten beeinflusst die Genauigkeit der Positionsbestimmung (Ding et al. 2008), was aber in diesem Beitrag nicht näher betrachtet wird.

Für diesen Beitrag wurde als Sensorplattform ein Board mit einem Microcontroller mit einer Low-Cost-IMU von Bosch (SMI130) und dem GNSS-Empfänger NEO-M8 von u-blox kombiniert. Als Referenz wurden Messungen mit einem Xsens MTi-G700 mit integrierter GNSS-Antenne durchgeführt. Die Matlab Toolbox NaveGo (Gonzales et al. 2015a, 2015b) wurde benutzt, um die Daten der verschiedenen Sensoren in einem erweiterten Kalman-Filter zu integrieren. Mit der Matlab Toolbox NaveGo können die Sensordaten in einem Strapdown Algorithmus verarbeitet und mit GNSS-Messungen zusammengeführt werden. Außerdem lassen sich in der Toolbox Ausfälle des GNSS-Signals simulieren. Die Matlab Skripte sind als Open Source über Github verfügbar (Gonzales et al. 2015b).

Ein wichtiger Punkt für die Integration der verschiedenen Sensoren ist die Transformation der Daten in ein übergeordnetes einheitliches Koordinatensystem um die Bewegung des E-Bikes in 3D beschreiben zu können. Weitergehende Information zu Koordinatensystemen und Transformationen speziell zum Zweck der Navigation finden sich bei Grewal et al. (2020) and Yang et al. (1999). Diebel (2006) beschreibt die theoretischen Konzepte zur Definition der Orientierung eines festen Körpers im Raum mit Hilfe der Eulerschen Winkel und den zugehörigen Transformationsmatrizen.

## 2.1 Sensorkalibrierung

Wie bereits erwähnt, spielt die Kalibrierung der IMU eine wesentliche Rolle für die Koppelnavigation. Während die Drift des Gyroskops recht einfach bestimmt werden kann, nämlich immer dann, wenn die IMU in Ruhe ist, entspricht der gemessene Wert der drei Drehratensensoren genau der Drift um die drei Achsen. Der Sollwert der Messungen ist bei der IMU in Ruhelage gleich 0. Die Drift des Gyroskops kann also während jeder Fahrt immer dann bestimmt werden, wenn das E-Bike in Ruhe ist. Diese Situation des E-Bikes in Ruhe über seine Sensoren festzustellen, stellt eine eigene Herausforderung dar, auf die später noch eingegangen wird.

Die Kalibrierung des Beschleunigungssensors stellt sich komplizierter dar. Der Beschleunigungssensor misst immer die Erdbeschleunigung von etwa 9,81 m/s mit, die für die Navigation aus den Daten herausgerechnet werden muss. Ist die IMU in Ruhelage, verteilt sich die Erdbeschleunigung je nach Lage der IMU im Raum auf die drei Achsen. Die Beschleunigungssensoren können einen Nullpunktsfehler (Bias) und einen Maßstabsfehler (Scale) besitzen, der über bestimmte Messanordnungen ermittelt werden kann (siehe auch Grewal et al. 2020). Eine Probemessung ergab für die verwendete Xsens IMU die in Tab. 1 dargestellten Werte (ermittelt nach Grewal et al. 2020, S. 70).

**Tab. 1:** Ergebnisse der IMU-Kalibrierung

Achse	Bias	Scale
X	-0.01935202	1.00006765
Y	-0.01358702	0.99970273
Z	0.03754575	1.00018655

Nach der WELMEC-Formel für die Erdbeschleunigung in Abhängigkeit der geografischen Breite und der Höhe über NHN,

$$g_r = 9,780318 \left( 1 + 0,0053024 \cdot \sin^2 \varphi - 0,0000058 \cdot \sin^2 2\varphi \right) - 0,000003085 \cdot h \quad (1)$$

ergibt sich für Karlsruhe bei einer geografischen Breite  $\varphi = 49^\circ$  und der Höhe  $h = 120$  m der Wert  $9,809430$  m/s<sup>2</sup> für die Erdbeschleunigung.

Setzt man voraus, dass die IMU so ausgerichtet ist, dass die gesamte Erdbeschleunigung nur auf die Z-Achse wirkt und die IMU in Ruhelage ist, ergibt sich mit den Daten aus Tab. 1 ein Messwert von  $9,8488057$  m/s<sup>2</sup> für die Beschleunigung in Richtung der Z-Achse. Die Messwerte auf den beiden anderen Achsen liegen beim Wert des jeweiligen Bias.

Berechnet man den zurückgelegten Weg aus diesen Beschleunigungswerten ohne Kalibrierung ergibt sich bereits nach 10 Sekunden eine Strecke von etwa 2,3 m, obwohl die IMU nicht bewegt wurde. Dieses Beispiel zeigt, dass eine korrekte Kalibrierung des Beschleunigungssensors essenziell ist. Untersuchungen zur Korrektur von Messwerten einer IMU für die Navigation, dem sogenannten Zero Velocity Update finden sich bei Khairi et al. (2014), Rantakokko et al. (2014) und Wahlström und Skog (2021).

## 2.2 Kalman-Filter

Das Kalman-Filter ist eine geeignete Methode, Daten unterschiedlicher Sensoren zu integrieren und eine Lösung für die Positionsbestimmung zu ermitteln. Das Kalman-Filter bietet die Möglichkeit, während einer Fahrt, wenn die Empfangsbedingungen für GNSS-Signale gut sind und korrekte Positionen im Bereich der erwartbaren Genauigkeit liegen, die IMU-Sensoren zu kalibrieren. Wegen der nicht sehr hohen relativen Genauigkeit zweier aufeinander folgenden Positionen, speziell bei niedrigen Geschwindigkeiten, ist dieser Weg der IMU-Kalibrierung jedoch eher kritisch zu sehen.

Eine andere, bereits erwähnte Möglichkeit ist, die IMU-Sensoren immer dann zu kalibrieren, wenn die IMU in Ruhe ist. Hierfür steht der Begriff Zero Velocity Update.

Die prinzipielle Idee des Kalman-Filters besteht in der Beschreibung eines Systems in Bewegung mit seinen Bewegungsgleichungen, was eine Vorhersage des Systemzustands und den Vergleich mit tatsächlich erfolgten Messungen während der Bewegung ermöglicht. Weitergehende Information hierzu findet sich bei Grewal und Andrews (2001) und bei Grewal et al. (2020). Auf diese Weise kann eine Position iterativ aus seiner Systembeschreibung und kontinuierlichen

Messungen bestimmt werden. Die Systemparameter werden laufend angepasst, basierend auf Annahmen zu Systemrauschen einerseits und dem Messrauschen andererseits.

Der Zustand  $x$  eines Systems zu einem Zeitpunkt  $k$  kann mit der folgenden Zustandsgleichung beschrieben werden:

$$x_{k+1} = \Phi_k x_k + w_k \quad (2)$$

Mit der Systemmatrix  $\Phi_k$  und dem Systemrauschen  $w_k$  (Grewal et al. 2020).

Mit Hilfe der zugehörigen Beobachtungsgleichungen

$$z_k = H_k x_k + v_k \quad (3)$$

werden die Messungen mit dem Systemzustand über die Matrix  $H_k$  verbunden, die den Zusammenhang zwischen den Messungen und den Systemparametern beschreibt. Mit  $v_k$  wird das Rauschen in den Messungen modelliert. Sowohl das Systemrauschen, als auch das Messrauschen werden als erwartungstreu und normalverteilt angenommen. Für die Kovarianzmatrizen  $Q_k$  und  $R_k$  gilt:

$$w_k \sim N(0, Q_k) \quad \text{resp.} \quad v_k \sim N(0, R_k)$$

Die Kalman-Filter-Gleichungen bestehen aus der Prädiktion des Systemzustands und der zugehörigen Kovarianzmatrix zur Zeit  $k$  basierend auf dem vorhergehenden Systemzustand zur Zeit  $k-1$  (Prädiktor) und der Korrektur.

Prädiktor:

$$x_{k(-)} = \Phi_k \hat{x}_{k-1(+)} \quad (4)$$

$$P_{k(-)} = \Phi_k P_{k-1(+)} \Phi_k^T + Q_k \quad (5)$$

Korrektor:

$$K_k = P_{k(-)} H_k^T \left( H_k P_{k(-)} H_k^T + R_k \right)^{-1} \quad (6)$$

$$\hat{x}_{k(+)} = \hat{x}_{k(-)} + K_k \left( z_k - H_k \hat{x}_{k(-)} \right) \quad (7)$$

$$P_{k(+)} = P_{k(-)} - K_k H_k P_{k(-)} \quad (8)$$

$K_k$  ist hier die sogenannte Kalman Gain Matrix. Sie kann als Gewichtsmatrix interpretiert werden, die entweder die Schätzung der zu erwartenden Messungen

durch die Systemparameter  $H_k \hat{x}_{k(-)}$  oder die tatsächlichen Messungen  $z_k$  stärker gewichtet, basierend auf der vorhergehenden Schätzung  $\hat{x}_{k(-)}$ .

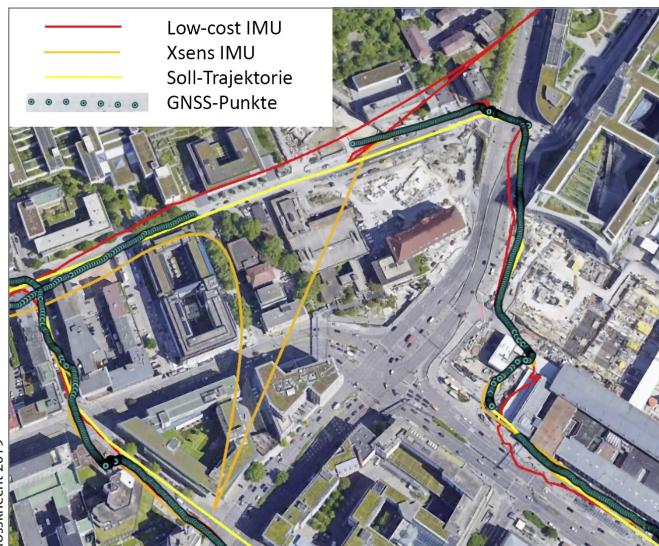
$\hat{x}_{k(-)}$  und  $P_{k(-)}$  sind die a-priori-Werte für den Zustandsvektor des Systems und seine Kovarianzmatrix ohne Nutzung der Genauigkeitsinformation der Messungen.

$\hat{x}_{k(+)}$  und  $P_{k(+)}$  sind die entsprechenden a posteriori-Werte die sich aus der Einbeziehung der Messungen ergeben.

### 3 Ergebnisse

Testfahrten mit einem E-Bike und die Aufzeichnung von Daten sowohl der oben beschriebenen Low-Cost-IMU, als auch der Referenz-IMU von Xsens führten ohne Kalibrierung der Beschleunigungssensoren zu unzureichenden Ergebnissen. Die Abb. 1 zeigt die Trajektorie, welche mit dem Navego-Algorithmus für die Low-Cost-IMU berechnet wurde (rot), die Trajektorie für die Xsens-IMU (orange) sowie die tatsächlich gefahrene Solltrajektorie (grün).

Für diesen Test wurde ein Ausfall des GNSS-Signals für 20 Sekunden simuliert. In der Abbildung ist dies an der unterbrochenen Linie der GNSS-Punkte in der oberen Bildmitte, unterhalb der Legende zu erkennen. Die Berechnungen der Trajektorien für beide IMUs führten zu starken Abweichungen von der Soll-Trajektorie von knapp 300 m für die Xsens IMU und etwa 230 m für die Low-Cost-IMU.



**Abb. 1:**  
Trajektorien  
Low-Cost-IMU  
und Xsens,  
Hintergrundbild:  
Google Earth

Diese Abweichungen zeigen klar, dass ohne eine Lösung zur Kalibrierung der Beschleunigungssensoren während der Fahrt eine sinnvolle Lösung der Positionsbestimmung ohne zusätzliche Sensoren nicht möglich ist.

### 3.1 Sensorkalibrierung

In diesem Abschnitt werden Messungen zum Verhalten der Sensoren gezeigt und Möglichkeiten für deren Kalibrierung untersucht.

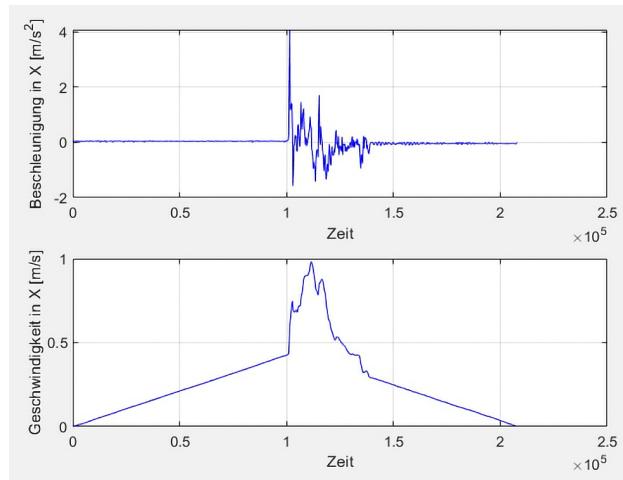
#### 3.1.1 Gyroskop

Die Kalibrierung des Gyroskops stellt sich, wie oben erwähnt, einfacher dar als die der Beschleunigungssensoren. Die Bestimmung der Drift in Ruhelage des Sensors stellt keine große Herausforderung dar. Das Hauptproblem hierbei ist, die Ruhelage des Sensors festzustellen, worauf an späterer Stelle noch eingegangen wird.

#### 3.1.2 Beschleunigungssensoren

Die in Abschnitt 2.1 erwähnten Untersuchungen zum Zero Velocity Update erfolgten größtenteils für die Fußgängernavigation innerhalb von Gebäuden, z. B. zur Verfolgung von Feuerwehrleuten beim Einsatz. Hauptproblem beim Zero Velocity Update ist die zuverlässige Detektion einer Ruhephase der Sensoren. Für die Fußgängernavigation wird daher die IMU meistens am Schuh angebracht. Beim Gehen durchläuft der Fuß verschiedene Bewegungsphasen wie z. B. die Schwing- und die Standphase. Wichtig hierbei ist die Standphase, während der die IMU in Ruhe ist. Es wird von einer bestimmten Zeitdauer für diese Standphase ausgegangen, um die Ruhelage aus den Messwerten zu detektieren. Die Dauer dieses Zeitfensters ist für die zuverlässige Ermittlung der Ruhelage entscheidend. Eine ähnliche Annahme für dieses Zeitfenster beim Gehen mit der IMU am Schuh ist für die IMU am E-Bike nicht möglich. Daher wurden Versuche durchgeführt, um eine geeignete Dauer für diesen Test zu ermitteln.

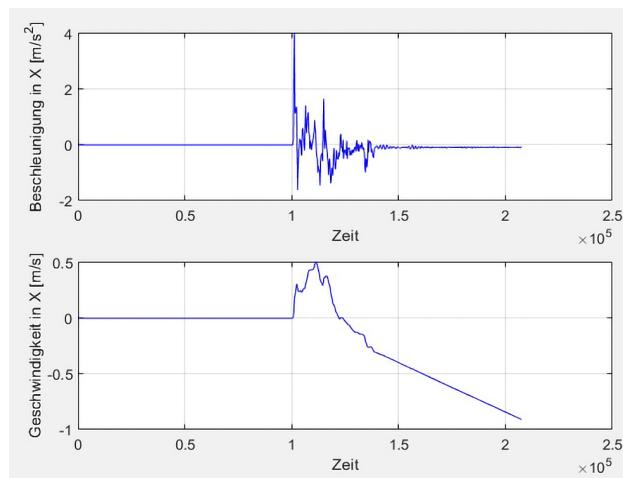
Der Sensor liefert alle 25 Millisekunden einen Satz von Messwerten für Beschleunigungen und Drehraten. Aus Messungen von einigen Sekunden in Ruhelage ergab sich eine Standardabweichung etwa  $0,016 \text{ m/s}^2$  für die Beschleunigungen für jede Achse. Dieser Wert wurde für einen statistischen Test genutzt, um nur signifikante Beschleunigungen für die Berechnung von Geschwindigkeiten und Wegen zu verwenden. Außerdem wurden die Messungen von 10 aufeinanderfolgenden Datensätzen gemittelt um die Gesamtmenge an Daten zu reduzieren und auch eine gewisse Glättung der Daten zu erreichen. Die Abb. 2 zeigt



**Abb. 2:**  
Beschleunigung  
und Geschwindig-  
keit in X-Richtung

Beschleunigungswerte, gemessen in einem Zeitintervall von etwa 2 Sekunden in X-Richtung und die zugehörigen ermittelten Geschwindigkeiten.

Bei der Testmessung war der Sensor zunächst in Ruhe. Der Sollwert für die Beschleunigung ist als  $0,0 \text{ m/s}^2$ . Es wurden Werte leicht über 0 gemessen, was zu einer Zunahme der Geschwindigkeit führt. Nach der Ruhephase wurde der Sensor kurz in X-Richtung bewegt, was am Ausschlag der Beschleunigungswerte zu erkennen ist. Nach der Bewegung erfolgte wieder eine Ruhephase, in der die Geschwindigkeit abnimmt, da die gemessenen Beschleunigungswerte nach der kurzen Bewegungsphase fälschlicherweise leicht unter 0 liegen.



**Abb. 3:**  
Beschleunigung  
und Geschwindig-  
keit nach Kalibrie-  
rung

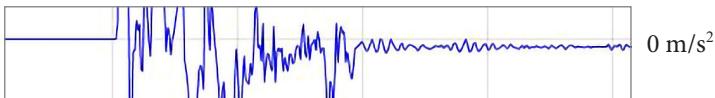


Abb. 4: Vergrößerter Ausschnitt Beschleunigung

Mit den Werten der Kalibrierung aus Tab. 1 erhält man Abb. 3. Hier ist zu erkennen, dass sich in der ersten Ruhephase die gemessene Beschleunigung nicht signifikant von 0 unterscheidet, daher auch die Geschwindigkeit konstant bei 0 bleibt. Nach der kurzen Bewegungsphase fällt der Sensor jedoch nicht wieder auf die Werte nahe 0 vor der Ruhephase zurück. Der Bias hat sich geändert, und es werden Werte leicht unter 0 gemessen, was in Abb. 4, die ein vergrößerter Ausschnitt aus Abb. 3 ist, deutlich wird.

Die dünne waagrechte graue Linie repräsentiert die Nullmarke für die Beschleunigung. Diese leicht zu kleinen Beschleunigungswerte führen wiederum zu einer Zunahme des Absolutwerts der Geschwindigkeit und nach einiger Zeit zu einem erheblichen Streckenfehler. Hieraus wird ersichtlich, dass eine wiederholte Bestimmung der Korrekturwerte für die Beschleunigungen essenziell ist.

### 3.1.3 Zero velocity update

Wie im Abschnitt 3.1.2 erwähnt, gibt es bereits Untersuchungen zum Problem des Zero Velocity update. Die meisten dieser Untersuchungen beziehen sich jedoch auf die Fußgängernavigation mit der IMU am Schuh oder am Fuß und der Erkennung bestimmter Bewegungsphasen beim Gehen.

Diese definierten Bewegungsphasen gibt es beim Radfahren jedoch nicht, was die Lösung des Problems erheblich erschwert. Das Problem besteht darin, Phasen zu erkennen, in denen die Summe der gemessenen Beschleunigungen auf allen drei Achsen gleich der Erdbeschleunigung ist. Dies ist der Fall, wenn die IMU entweder komplett in Ruhelage ist oder sich mit gleichbleibender Geschwindigkeit in eine Richtung bewegt. Es ist also notwendig, ein Zeitfenster von einer bestimmten Dauer zu definieren, innerhalb dessen getestet wird, ob die gemessene Beschleunigung abzüglich der Erdbeschleunigung gleich 0 ist.

Solin et al. (2018) verwendeten den Dickey-Fuller-Test (*augmented Dickey-Fuller test* oder *ADF-Test*) in einer Studie zur Fußgängernavigation mit einem Smartphone. Die nähere Beschreibung des Dickey-Fuller-Tests findet sich bei Dickey und Fuller (1979). Der Dickey-Fuller-Test dient dazu, zu testen, ob ein stochastischer Prozess stationär ist. Dies ist der Fall, wenn die Zeitreihe einen konstanten Erwartungswert hat und die Varianz nicht von der Zeit abhängig ist.

Entscheidend ist hierbei die Dauer des Zeitfensters, aus dem Daten als Eingang für den Test verwendet werden. Solin et al. (2018) verwendeten ein Fenster

von 250 ms Dauer. Die Xsens IMU liefert alle 2,5 ms einen Satz von Messwerten, was einen Datensatz von 100 Messwerten für den Test ergibt.

Eigene Tests mit unterschiedlichen Zeitfenstern haben jedoch keine befriedigenden Ergebnisse geliefert. Unterschiedlich lange Teststrecken lieferten mit unterschiedlichen langen Zeitfenstern für den Dickey-Fuller-Test stark unterschiedliche Ergebnisse. Hier sind noch mehr Testdaten und Untersuchungen notwendig, um verlässlichere Ergebnisse zu erzeugen.

### 3.1.4 Kalman-Filter

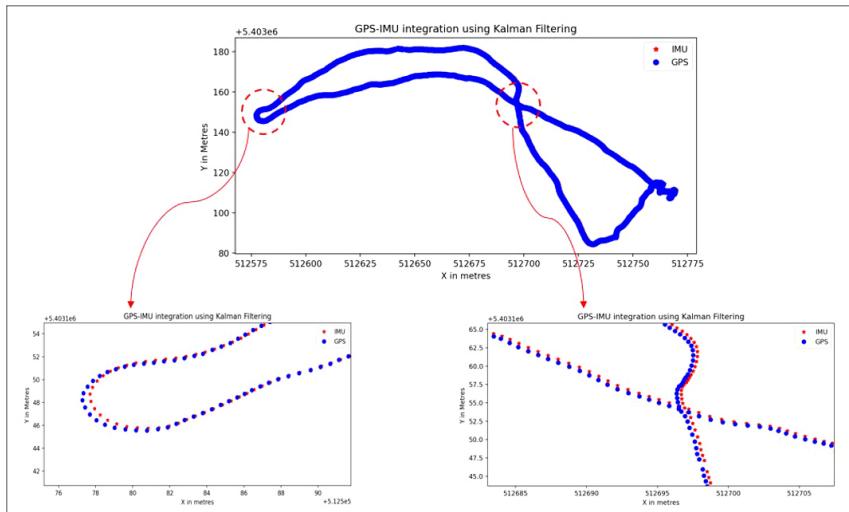
Das in Abschnitt 2.2 beschriebene Kalman-Filter wurde verwendet, um Testtrajektorien unter Verwendung von GNSS- und IMU-Daten zu berechnen. Hierbei wurden die GNSS-Daten verwendet, um die Daten des Beschleunigungssensors zu korrigieren. Verschiedene Tests mit unterschiedlichen Routen wurden durchgeführt. Abb. 5 zeigt eine der Testrouten. Das Kalman-Filter liefert gute Ergebnisse solange die GNSS-Signale verfügbar sind und die Beschleunigungen permanent korrigiert werden können.

Für die Darstellung in Google Earth ebenso wie für Abb. 6 wurden die Positionen nach UTM transformiert. Abb. 6 zeigt das Ergebnis mit zwei vergrößerten Ausschnitten, in denen die Unterschiede zwischen den reinen GNSS-Positionen und den integrierten Daten von GNSS und IMU zu erkennen sind.

Ein simulierter Ausfall der GNSS-Signale von 50 Sekunden Dauer zeigt jedoch, dass die Qualität der Positionen schnell abnimmt. Ein simulierter Ausfall des GNSS-Signals für 50 Sekunden hat hier eine Abweichung der durch Koppelnavigation weiter berechneten Positionen von den GNSS-Positionen von etwa 50 cm in jeder Koordinatenrichtung zur Folge. Mit zunehmender Dauer des



Abb. 5:  
Beispielroute  
für Kalman-  
Filter



**Abb. 6:** Unterschied GNSS-Positionen zu mit Kalman-Filter integrierten GNSS-IMU-Positionen

Ausfalls des GNSS-Signals wächst die Abweichung jedoch nicht linear, sondern quadratisch. Ein längerer Ausfall des GNSS-Signals wäre demnach schwer zu kompensieren.

## 4 Ausblick

Die Messungen zur Bestimmung der Kalibrierparameter der IMU führten zu stark verbesserten Ergebnissen für die Positionsbestimmung, haben aber den Nachteil, dass die Messungen hierfür unter bestimmten Bedingungen nach bestimmten Vorgaben durchgeführt werden müssen. Damit fällt diese Methode für eine Neukalibrierung während der Fahrt aus.

Die Methode des Zero Velocity Update hat das Problem, dass bei einer Fahrt mit dem E-Bike Phasen, in denen die IMU in Ruhelage ist nur sehr schwer zu detektieren sind. Wird eine Ruhephase fälschlicherweise nicht erkannt, werden gemessene Beschleunigungen für die Wegberechnung verwendet, obwohl kein Weg zurückgelegt wird. Wird eine Bewegungsphase fälschlicherweise als Ruhelage erkannt, werden die gemessenen Beschleunigungen für die Neukalibrierung des Sensors anstatt für die Berechnung des Weges verwendet. Eine Systematik im Bewegungsablauf wie bei der Fußgängernavigation existiert hier nicht. Hier könnten weitere Sensoren helfen, die beispielsweise den Stillstand der Räder des E-Bikes ermitteln lassen.

Ein Kalman-Filter ist ohnehin Standard für die Integration von GNSS und IMU-Daten zur Navigation. Weitere Sensoren ließen sich hier möglicherweise integrieren, die ein besseres Schätzen der Kalibrierwerte für die Beschleunigung und eine verlässliche Detektion von Ruhephasen für die Neukalibrierung ermöglichen.

## Literatur

- Dickey, D., Fuller, W. (1979): Distribution of the Estimators for Autoregressive Time Series With a Unit Root. In: Journal of the American Statistical Association, 74(366), 427–431.
- Diebel, J. (2006): Representing Attitude: Euler Angles, Unit Quaternions, and Rotation Vectors. California: Stanford University.
- Ding, W., Wang, J., Li, Y., Mumford, P., Rizos, C. (2008): Time Synchronization Error and Calibration in Integrated GPS/INS Systems. In: ETRI Journal, 30(1).
- Gonzales, R., Giribet, J., Patiño, H. (2015a): An approach to benchmarking of loosely coupled low-cost navigation systems. In: Mathematical and Computer Modelling of Dynamical Systems, 21(3), 272–287.
- Gonzales, R., Giribet, J., Patiño, H. (2015b): NaveGo: a simulation framework for low-cost integrated navigation systems. In: Journal of Control Engineering and Applied Informatics, 2015(17), 110–120.
- Grewal, M., Andrews, A. (2001): Kalman filtering: theory and practice using MATLAB (2 ed.). New York: John Wiley & Sons Ltd.
- Grewal, M., Andrews, A., Bartone, C. (2020): Global Navigation Satellite Systems, Inertial Navigation and Integration. 4th edition. Hoboken NJ: Wiley.
- Groves, P. (2013): GNSS, Inertial and Multisensor Integrated Navigation Systems (2 ed.). Boston, London: Artech House.
- Khairi, A., Moore, T., Hide, C., Hill, C. (2014): Understanding the Performance of Zero Velocity Updates in MEMS-based Pedestrian Navigation. In: International Journal of Advancements in Technology.
- Rantakokko, J., Strömbäck, P., Andersson, P. (2014): Foot- and knee-mounted INS for firefighter localization. Institute of Navigation International Technical Meeting.
- Rossknecht, M. (2019): Integration von GNSS und INS zur Positionsbestimmung von E-Bikes. Stuttgart. Bachelor-Arbeit, HFT Stuttgart, unpublished.
- Solin, A., Cortes, S., Rahtu, E., Kannala, J. (2018): Inertial Odometry on Handheld Smartphones. 21st International Conference on Information Fusion (FUSION), 1–5.
- Wahlström, J., Skog, I. (2021): Fifteen Years of Progress at Zero Velocity: A Review. IEEE Sensors Journal, 21(2), 1139–1151.
- Yang, Q., Snyder, J., Tobler, W. (1999): Map Projection Transformation: Principles and Applications. London: CRC Press.

## Kontakt

Prof. Dr. Paul Rawiel  
Hochschule für Technik Stuttgart  
Schellingstraße 24, 70174 Stuttgart  
[paul.rawiel@hft-stuttgart.de](mailto:paul.rawiel@hft-stuttgart.de)

# Automatisch semantisch-segmentierte Punktwolken – Möglichkeiten und Herausforderungen

Eike Barnefske | Harald Sternberg

## 1 Einleitung

Die Erfassung von Baustellen, Innenräumen und Straßenzügen durch das terrestrische Laserscanning (TLS) und mit Mobilen Mapping Systemen (MMS) ist eine Standardmethode in der Geodäsie geworden. Zweck dieser Aufnahmen ist es, meist ein Modell eines Ist-Zustandes zu erstellen, das neben geometrischen auch semantische Informationen beinhaltet. Die Auswertung wird i. d. R. durch einen Prozess, wie Abb. 1 dargestellt, durchgeführt. Die ersten beiden Prozessschritte erfolgen oftmals automatisch oder semi-automatisch. Bei einigen Vermessungssystemen werden diese Schritte schon im Feld ausgeführt (z.B. Leica RTC360). Wenig automatisiert ist die semantische Auswertung der Punktwolke, die als semantische Segmentierung bezeichnet wird. Bei der semantischen Segmentierung wird die Punktwolke nach Objektklassen wie Tisch, Wand oder Fehler unterteilt. Durch die semantische Segmentierung werden die Punktmerkmale erweitert, so dass z. B. eine automatisierte Modellierung aus der Punktwolke möglich wird.



Abb. 1: Prozess für die Erfassung und Verarbeitung von Innenräumen

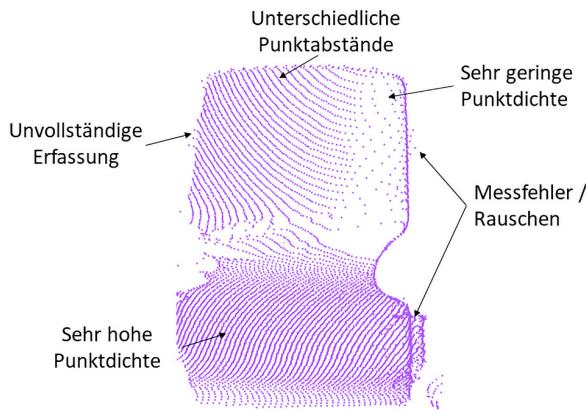
Die manuelle semantische Segmentierung ist für den Menschen, der Punktwolken gut semantisch interpretieren kann, eine leichte, aber sehr zeitintensive Tätigkeit. Die Interpretationsleistung, die ein Mensch erbringt, durch eine Maschine durchführen zu lassen, ist Gegenstand von Forschungen zur künstlichen Intelligenz (KI) in der Geodäsie, welche ein bedeutsames Thema ist. Eine im

Jahr 2020 durchgeführte Umfrage des Verbandes Deutscher Vermessungsingenieure (VDV) e. V. zeigt, dass KI in der Geodäsie nicht nur an Universitäten, Forschungseinrichtungen und in großen Unternehmen ein zentrales Thema ist, sondern auch in Vermessungsbüros. Doch steckt das Thema bei fast allen Befragten in den „Kinderschuhen“. Konkrete Anwendungen, wie z. B. das Laser-scanning, werden schon identifiziert und ein Drittel der Befragten nutzt oder plant KI in Projekten zu nutzen (Grunau 2022).

Die Intention dieses Beitrags ist das Interesse an der KI weiter zu bestärken und Geodäten einen einfacheren Einstieg und Überblick in die semantische Punktwolkenauswertung mit aktuellen *Maschine Learning* (ML)-Methoden zu geben. Im Folgenden wird auf das Format Punktwolke und dessen Herausforderungen beim ML eingegangen. In das Thema ML wird kurz eingeführt und auf Methoden für die punktweise semantische Segmentierung mittels *Künstlicher Neuronaler Netze* (KNN) eingegangen. Die Funktion und die Erstellung von Trainingsdaten zur Parameteroptimierung wird betrachtet. Abschließend wird ein Schema zur Qualitätsbewertung von semantisch-segmentierten Punktwolken vorgestellt.

## 2 Struktur von Punktwolken

Eine Punktwolke ist eine Ansammlung von diskreten Punkten, welche eine Vielzahl an Merkmalen besitzen. Bei Punktwolken im Zusammenhang mit Geodaten ist eines der Merkmale jedes Punktes die Lage im Raum (z. B. die x-, y- und z-Koordinate). Über diese geometrischen Merkmale stehen die einzelnen Punkte als Punktwolke in einer invarianten Beziehung. Hingegen ist die Reihenfolge, in der die Punkte gespeichert werden variant. Es kann also der 13. Punkt neben dem 100. Punkt liegen. Des Weiteren ist der Abstand zwischen den Punkten bei gemessenen Punktwolken variabel. Der Abstand wird nicht aus einem Raster der letztendlichen Punktwolke vorgegeben, sondern durch das Vermessungssystem und die Aufnahmegerometrie, sowie das zu erfassende Objekt (Form und Oberflächeneigenschaften) bestimmt. Als Aufnahmesysteme sind Laserscanner und Time of Flight (ToF) Kameras sehr verbreitet (Camuffo et al. 2022), deren Funktionsweise Luhmann et al. (2018) sehr eingehend beschrieben hat. Eingehende Untersuchungen zur geometrischen Genauigkeit der Vermessungssysteme wurde durch Tölgessy et al. 2021 und Wujanz et al. 2018 durchgeführt, die überwiegend für die Prozessschritte eins und zwei in Abb. 1 gelten. Grobe Messfehler, wie Punkte, die an einem Ort gemessen werden, an dem keine Oberfläche ist, entstehen durch Reflexionen (Phantompunkte) oder durch die Strahldivergenz an Objekträndern (Kometenschweife). Die Auswirkungen von Messsystem und Objekt auf die Punktwolke sind in Abb. 2 dargestellt. Diese sind nachteilig für



**Abb. 2:**  
Eigenschaften und Fehler bei Punktwolken aus der Aufnahme mittels eines Laserscanners

die Weiterverarbeitung mit ML-Verfahren, die eine invariante und gleichmäßige Darstellungsstruktur, wie z. B. ein Pixelraster bei digitalen Bildern, benötigen. Eine Punktwolke kann ohne diese Ordnung nicht durch eine Maschine interpretiert werden (Kastl und Hinrichs 2022), so dass i. d. R. spezielle Vorverarbeitungen durchgeführt werden müssen.

### 3 Maschine Learning

ML ist ein Teilgebiet der KI. Zu diesem Teilgebiet werden Methoden zusammengefasst, mit deren Hilfe eine Beziehung zwischen Eingabe- und Zieldaten durch eine Maschine (Computer) eigenständig erlernt werden kann (Roscher und Drees 2022). Hierfür werden die Merkmale (oder Feature) der Eingabedaten analysiert, um Muster zu identifizieren, mit denen eine Klassifizierung oder eine Vorhersage gemacht werden kann (Shukla 2018).

Die meisten dieser Methoden, die für geodätische Aufgaben genutzt werden, basieren auf der Lernstrategie des *überwachten Lernens*, bei dem für jeden Datenpunkt ein Zielwert bekannt ist. Aus der Differenz zwischen prädiziertem Wert des ML-Modells und dem Zielwert, wird ein Fehler (oder *Loss*) der ML-Methoden berechnet. Damit eine ML-Methode für die Lösung einer Aufgabe verwendet werden kann, muss das *Loss* minimal sein. Den Prozess des Optimierens zu einem möglichst kleinen *Loss*-Wert wird als Training bezeichnet. Jede ML-Methode besteht aus einer Architektur (Anordnung der mathematischen Operationen) und Hyperparametern. Hyperparameter sind Parameter, die nicht durch die Methode optimiert, sondern über a-priori-Wissen definiert werden.

Schwache ML-Methoden sind z. B. *Logistische Regressionen*, *Entscheidungsbäume* oder *Support-Vektor-Maschinen*. Diese werden häufig zur Steigerung

der Prädiktionsgenauigkeit als *Ensemblemethode* verwendet. Bei den *Ensemblemethoden* werden die Prädiktionen von verschiedenen ML-Methoden kombiniert. Die verschiedenen Möglichkeiten der *Ensemblemethoden* sind anschaulich von Dietterich (2002) dargestellt worden. Schwache Lernmethoden setzen i. d. R. ein großes Expertenwissen über die Anordnung der Daten beim Lernen und dessen Merkmalen heraus (Weinmann 2015). Die Merkmale bei diesen Methoden werden direkt für das Training und die spätere Klassifizierung bzw. die Vorhersage verwendet. Wie Hackel et al. (2016) zeigen, können aus den ordinären (gemessenen) Merkmalen ergänzende Merkmale berechnet werden. Diese basieren z. B. auf Eigenwerte, Momenten oder Merkmalskombinationen. Durch diese neuen Merkmale erweitert sich der Merkmalsraum. Der Zweck dieser neuen Merkmale ist es, die Klassifizierung oder die Vorhersage eindeutiger zu machen.

### 3.1 Deep Learning

ML-Methoden mit einem sehr großen Merkmalsraum werden als *Deep Learning* (DL)-Methoden bezeichnet. Sie unterscheiden sich u. a. von schwachen ML-Methoden dadurch, dass sie die Eingabemerkmale nutzen, um „automatisch“ neue Tiefenmerkmale zu erzeugen. DL wird meistens durch die ML-Methode des *Convolutional Neural Network* (CNN), einer Unterform der KNN verwendet. CNN ist für die Klassifizierung von Rasterdaten geeignet, da sie die neuen Merkmale über eine Faltungsfunktion berechnet, die die nachbarschaftliche Merkmalsanordnung nutzt (Goodfellow et al. 2016). CNNs verarbeiten die Merkmale in zwei Schritten. Im ersten Schritt werden durch mehrere *Convolutional*-Schichten die Tiefenmerkmale erzeugt und mittels einer *Pooling*-Funktion teilweise wieder aggregiert, so dass ein Tensor von Merkmalen entsteht, der häufig mehrere hundert Dimensionen hat. Im folgenden Schritt wird eine Klassifizierungsmethode (z. B. eine *Softmax*-Funktion) implementiert, die den Merkmalstensor nutzt, um für jeden Datenpunkt eine Klasse zu bestimmen (Qi et al. 2017a).

Anwendung findet CNN überwiegend bei der Auswertung von strukturierten Massendaten, wie Bildern, Oberflächen- und Voxel-Modellen. Im geodätischen Kontext werden sie u. a. für das Detektieren von Unterwasserfauna in hydrographischen Daten (Lütjens und Sternberg 2021), für das Detektieren von Gebäuden (Dinga 2022, Roux und Dumas 2022) und Landnutzungsgrenzen (Voelsen et al. 2022) in Luftbildern, sowie bei *Scan2BIM*-Anwendungen eingesetzt (Rashdi et al. 2022).

### 3.2 Semantische Segmentierung von Punktwolken mit DL

Die semantische Segmentierung von Punktwolken ist eine Aufgabe, für die DL-Verfahren seit etwa 15 Jahren intensiv erforscht werden. Frühe und echtzeitfähige Entwicklungen überführten die Punktwolken in ein maschinell interpretierbares Datenformat. Aktuelle Arbeiten nutzen CNN-Architekturen, bei denen die variable Punkteingabe keinen Einfluss hat (Abb. 3).

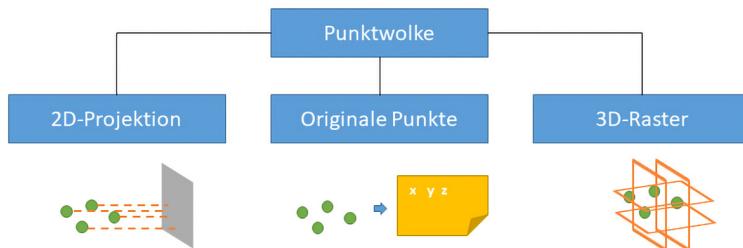


Abb. 3: DL-Methodengruppen zur semantischen Segmentierung von Punktwolken

Ein maschinell interpretierbares Datenformat sind zwei- oder dreidimensionale Raster. Zweidimensionale Datenformate sind Bilder, bei denen die Merkmale der Punkte an die Pixel übertragen werden. Je nach Anwendung sind verschiedene Projektionen von Vorteil, damit möglichst detailreiche Segmente erstellt werden können. TLS-Punktwolken eignen sich für Zylinder- und Kugelprojektionen. Projektionen der Vogelperspektive werden meist für die Navigation angewendet und (zufällige) Mehrbilderprojektionen werden für die Auswertung von Punktwolken, die durch MMS entstanden sind, verwendet. Liegen die Punkte im 2D-Bildraum vor, können CNN, wie *AlexNet* (Krizhevsky et al. 2012), *GoogLeNet* (Szegedy et al. 2014) oder *YOLO* (Redmon et al. 2016), direkt angewandt werden. Diese Netzwerkarchitekturen sind mittels großer und vielfältiger Datensätze, wie z. B. von Facebook und Google, vortrainiert, wodurch meist nach einem kurzen fachspezifischen Training eine hohe semantische Genauigkeit erreicht werden kann. Die semantischen Informationen werden dann zurückprojiziert und jeder Punkt erhält ein semantisches Merkmal. Große Nachteile dieser Methode sind, dass durch die Projektion Informationen verloren gehen und Segmente über die Dimensionsgrenzen gebildet werden. Die häufig hohe Generalisierung durch die Pixel führt dazu, dass insbesondere kleine Objekte nicht mehr (richtig) erkannt werden.

Der Nachteil der Generalisierung ist auch bei den 3D-Rastermethoden vorhanden, aber hier werden die dreidimensionalen Informationen verwendet. Bei dieser Methodengruppe wird entweder ein gleichmäßiges Voxelraster über die Punktwolke gelegt (Maturana und Scherer 2015) oder ein dichteabhängiger

*Octree* (Poux und Billen 2019) berechnet. Die Auswertung kann auch in Schichten mit 2D-CNN oder direkt mit 3D-CNN durchgeführt werden, wofür eine sehr leistungsfähige Hardwareausstattung notwendig ist. Der *Octree* führt zu einer schnelleren Auswertung, da Voxel ohne Informationen ausgeschlossen werden. Diese beiden Methodengruppen nutzen überwiegend nachbarschaftliche Informationen, um die Segmentgrenzen zu bestimmen. Die Auflösung der Segmentierung wird durch die Größe und Anzahl der Rasterzellen gesteuert.

Die dritte Methodengruppe verwendet die ungeordneten Punkte direkt für die semantische Segmentierung. Die Netzwerkarchitektur *PointNet* von Qi et al. (2017a) ist ein Pionier für diese Methodengruppe, die in viele Richtungen weiterentwickelt wurde, um insbesondere ausgedehnte und komplexere Punktwolken semantisch zu segmentieren (Qi et al. 2017b, Engelmann et al. 2017). Neben *PointNet* ist seit zwei Jahren das *RandLa-Net* (Hu et al. 2020) eines der leistungsfähigsten Modelle, das im Fokus der Forschung steht.

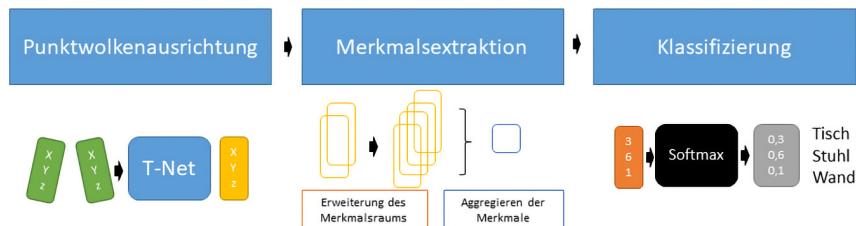


Abb. 4: Vereinfachte Darstellung der Prozessschritte von PointNet für die Semantische Segmentierung

Die drei zentralen Prozessschritte bei *PointNet* sind: Die Punktwolkenausrichtung, die Merkmalsextraktion und die Klassifizierung (Abb. 4). Für die Ausrichtung wird bei *PointNet* eine affine Transformation verwendet, deren Transformationsparameter durch das Netz gelernt werden. Die Tiefenmerkmale werden durch ein *Multilayer Perceptron*, das als 1D-CNN-Layer implementiert ist, für jeden Punkt einzeln bestimmt. Über eine *Max-Pooling*-Funktion werden die stärksten Merkmale aller Eingabepunkte aggregiert, so dass für diese Punktmenge ein globales Merkmasset entsteht. Dieses wird mit den Punktmerkmalen kombiniert und für die Klassifizierung mit einer Funktion verwendet (Qi et al. 2017a).

## 4 Trainingsdaten

Die Netzwerkarchitektur wird der Aufgabe entsprechend entwickelt und beschreibt diese als ein mathematisches Problem mit sehr vielen Parametern. Um die Parameter der Netzwerkarchitektur so zu bestimmen, dass eine Anwendung

entwickelt werden kann, werden die Trainingsdaten benötigt, die semantische Informationen beinhalten. Trainingsdaten sind i. d. R. Punktwolken, in denen Punkte manuell ein semantisches Merkmal zugewiesen wurde, was als Annotation oder Labeling bezeichnet wird. Für diese sehr arbeitsintensive Aufgabe wurden Werkzeuge und Prozesse entwickelt, mit denen größere Datenmengen (mehrere Millionen Punkte) semantisch erweitert werden. Neben der Effizienz ist die Kontrollierbarkeit für diese Prozesse von besonderer Bedeutung, da Klassifizierungsfehler zu Anwendungsfehlern führen oder ein Erlernen der semantischen Klassen nicht mehr gegeben ist.

Große Mengen an semantischen Punktwolken werden für das autonome Fahren benötigt, so dass ein Markt für das Annotieren von Verkehrsräumen entstanden ist. Dieser wird durch Dienstleister, wie *playment.io*, *basic.ai* oder *scale.com* bedient, die wenige Informationen über die angewendeten Methoden und deren Qualität dokumentieren. Auch ist die Frage des Datenschutzes und des Datenbesitzes in diesem Zusammenhang nicht immer vollständig geklärt, so dass einige kostenpflichtige und Open Source Software (offline) in wissenschaftlichen Arbeiten vorrangig eingesetzt werden. Eine Auswahl dieser Software mit deren Segmentierungsfunktionen ist in **Tab. 1** dargestellt.

Trainingsdaten definieren die Klassen, die Qualität und die Generalisierbarkeit, mit denen die lernbaren Parameter bestimmt werden. Für die Trainingsdaten in geodätischen Anwendungen lassen sich vier zentrale Anforderungen definieren. Die Trainingsdaten stellen die semantischen Segmente

- geometrisch richtig und präzise dar,
- semantisch richtig und präzise dar,
- die benötigten Klassen dar,
- als Ergebnis eines kontrollierbaren Prozesses dar.

Zum Erfüllen dieser Anforderungen ist bei der Erstellung der Trainingsdaten ein Qualitätsmodell, wie von Barnefske und Sternberg (2022) beschreiben, anzuwenden. Das dort beschriebene Qualitätsmodell geht über die vier minimalen Anforderungen hinaus und definiert den Aufbau der Trainingsdaten für eine optimale Parameterbestimmung im Detail.

**Tab. 1:** Ausgewählte Software für das Erstellen von Trainingsdaten auf der eigenen Hardware

Softwarename	Lasso	Ansichten	Bounding Box
ReCap (Autodesk ReCap 2022)	x		x
CloudCompare (CloudCompare 2022)	x		x
SemanticKITTI (Behley et al. 2019)	x		
PCCT (Barnefske und Sternberg 2019)		x	

## 5 Qualität bei semantischen Segmentierungen

Die Qualität einer semantischen Segmentierung, die durch ein DL-Modell durchgeführt wird, wird durch die Methode, die Hyperparameter und die Trainingsdaten bestimmt. Die umfangreichen Forschungen zur Methodenwahl für die semantische Segmentierung sind z.B. im Review von Bello et al. (2020) zusammengefasst und zeigen, dass punktbasierte DL-Methoden aktuell am geeignetsten sind. Die Wahl der Hyperparameter wird meist empirisch durchgeführt. Hierfür sind Strategien entwickelt worden, um diese Einstellungen effizienter vornehmen zu können. Ein Überblick und Hilfestellungen sind im Tutorium von Passos und Mishra (2022) gegeben. Die Trainingsdaten als Einflussgröße werden in den Arbeiten von Behley et al. (2019) und Barnefske und Sternberg (2022) untersucht.

Das in Barnefske und Sternberg (2022) entwickelte Qualitätsmodell für Trainingsdaten kann auch grundlegend für die Bewertung von semantisch segmentierten Punktwolken in geodätischen Anwendungen verwendet werden. Dieses Qualitätsmodell besteht aus drei Eigenschaftsfeldern, für die zwei bis drei Eigenschaften definiert sind. Jede Eigenschaft wird durch Bewertungsparameter beschrieben, für die Zielgrößen gemäß der Aufgabe definiert werden können (Abb. 5). Die Zielgrößen können z.B. aus den Vorgaben für ein BIM genommen werden. Dabei bezieht sich dieses Qualitätsmodell nicht nur auf die semantischen Eigenschaften, sondern ermöglicht eine Analyse des Segmentierungsprozesses und beschreibt die Punktwolkeneigenschaften, die für die Nutzung der Punktwolke aus geodätischer Sicht relevant sind. Hierbei wird auch bewertet, ob ein Punktwolkensatz aufgrund seiner Beschaffenheit gut für den Prozess geeignet ist. Fragen, die hierfür beantwortet werden sind u.a.: Ist die Menge der Daten

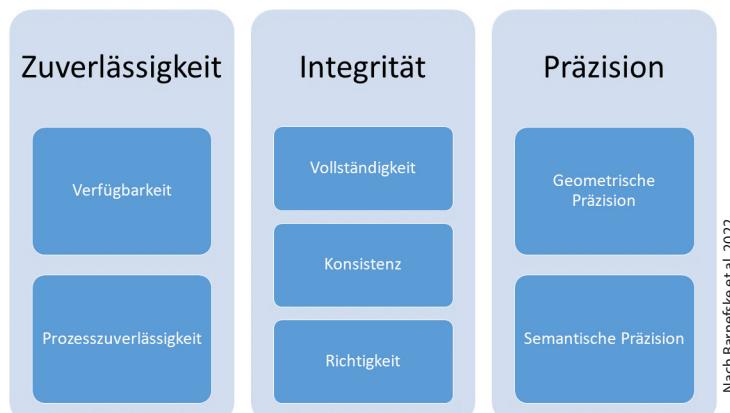
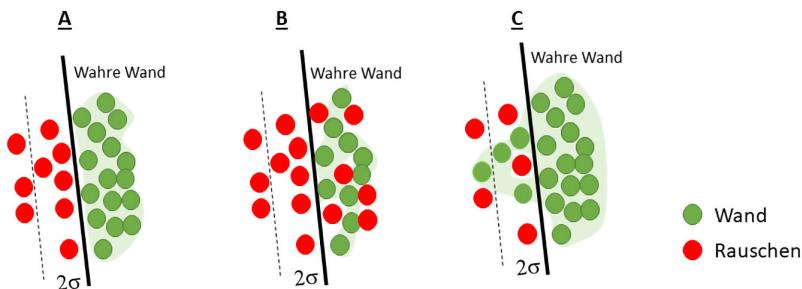


Abb. 5: Qualitätsmodell für semantisch segmentierte Punktwolken



**Abb. 6:** Ergebnisse einer semantischen Segmentierung. A: Optimales Ergebnis. B: Untererkennung der Klasse Wand. C: Übererkennung der Klasse Wand

ausreichend? Sind die Klassengrößen ähnlich? Liegen für alle Punkte semantische Informationen gemäß der Aufgabenstellung vor?

Für die Algorithmus-Entwicklung ist das Ziel meist (nur) die semantische Genauigkeit zu steigern, so dass diese Eigenschaft durch einen Parameter, wie z. B. der *F1-Score* oder der *Intersection over Union*, gut ausgedrückt werden kann. Beim Nutzen der Punktwolke für Modelle ist es notwendig, zwischen Richtigkeit und Präzision zu unterscheiden, da je nach Klasse und Anwendung, die andere Eigenschaft relevant ist.

In Abb. 6 sind für die Klassen Wand und Rauschen drei mögliche Ergebnisse einer semantischen Segmentierung dargestellt. Ergebnis A (Abb. 6) ist der optimale Fall. Es konnten Segmente gebildet werden und alle Punkte sind der Zielklasse zugeordnet. Präzision und Richtigkeit sind hoch und die geometrische Präzision, die z. B. durch die Standardabweichung für jede zu modellierende Klasse ausgedrückt wird, ist gering. Die Wand kann aus der Punktwolke modelliert werden. Das Ergebnis B (Abb. 6) zeigt, dass einige Punkte der Klasse Rauschen fälschlicherweise der Klasse Wand zugeordnet wurden. Die Richtigkeit der Klasse Wand ist geringer, aber die Präzision und die Standardabweichung bleiben unverändert hoch. Für die Klasse Rauschen reduziert sich die Präzision. Der Verlauf der Wand kann mittels dieser segmentieren Punktwolke modelliert werden. Das Ergebnis C (Abb. 6) zeigt für die Klasse Wand eine hohe Standardabweichung und eine geringe Präzision, da viele Punkte der Klasse Rauschen als Klasse Wand erkannt wurden. Eine Modellierung der Wand ist ggf. nicht mehr möglich.

In der Anwendung von DL für die semantische Segmentierung zeigt sich, dass Klassen unterschiedlich genau bestimmt werden, so dass die Bewertung klassenweise erfolgen sollte. Das Qualitätsmodell gibt einen Rahmen für die Bewertung und Analyse semantischer Segmentierung, wie sie in der Geodäsie vorkommen. Es kann mit dem Qualitätsmodell untersucht werden, ob ein Verfahren für eine Aufgabe geeignet ist.

## 6 Fazit und Ausblick

Die KI wird als Werkzeug in der Geodäsie immer mehr genutzt. Viele Entwicklungen werden von anderen Fachdisziplinen vorangetrieben, die andere Ziele und Herausforderungen haben. Für den Geodäten bedeutet das, dass die Verfahren verstanden und diese für geodätische Aufgaben angepasst werden müssen.

Besondere Herausforderungen in der Geodäsie sind, dass die aufgenommenen Daten nie frei von Fehlern/Abweichungen sind und nicht in einer festen Ordnung vorliegen, wie sie für eine maschinelle Verarbeitung optimal wären. Hohe Anforderungen aus den Zielprodukten für die semantische und geometrische Genauigkeit bei sehr variablen zu erfassenden Objekten, erschweren die Entwicklung einer Methode, die für alle Anwendungsaufgaben geeignet ist.

Die Modellwahl, die Hyperparameter und die Trainingsdaten bieten eine große Anzahl an Parametern, die für eine erfolgreiche semantische Segmentierung bestimmt werden müssen. Viele dieser Parameter sind z. Z. noch unbekannt und müssen für ein produktives Nutzen von ML in der Geodäsie erforscht werden. Hierbei kann das vorgestellte Qualitätsmodell eine Unterstützung sein.

### Literatur

- Autodesk ReCap (2022): Youtube Channel. [www.youtube.com/user/autodeskrecap/](https://www.youtube.com/user/autodeskrecap/), letzter Zugriff 10.08.2022.
- Barnefske, E., Sternberg, H. (2019): PCCT: A Point Cloud Classification Tool To Create 3D Training Data To Adjust and Develop 3D ConvNet. Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci., XLII-2/W16, 35–40.
- Barnefske, E., Sternberg, H. (2022): Evaluating the Quality of Semantic Segmented 3D Point Clouds. Remote Sensing, MDPI AG, 14, 446.
- Behley, J., Garbade, M., Milioto, A., Quenzel, J., Behnke, S., Stachniss, C., Gall, J. (2019): SemanticKITTI: A Dataset for Semantic Scene Understanding of LiDAR Sequences. In: Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV), Seoul, Korea, 27 October–2 November 2019.
- Bello, S. A., Yu, S., Wang, C. (2020): Review: Deep Learning on 3D Point Clouds. Remote Sensing, MDPI AG, 12, 1729.
- Bender, T., Härtig, M., Jaspers, E., Krämer, M., May, M., Schlundt, M., Turianskyj, N. (2018): Building Information Modeling 11. CAFM-Handbuch, Springer Fachmedien Wiesbaden, 295–324.
- Camuffo, E., Mari, D., Milani, S. (2022): Recent Advancements in Learning Algorithms for Point Clouds: An Updated Overview. Sensors, MDPI AG, 22, 1357.
- CloudCompare (2022): 3D Point Cloud and Mesh Processing Software Open-Source Project. Version 2.12. [www.cloudcompare.org](https://www.cloudcompare.org), letzter Zugriff 10.6.2022.
- Dietterich, T. G. (2002): Ensemble learning. The Handbook of Brain Theory and Neural Networks, 2(1), 110–125.

- Dinga, G. T (2022): An Investigation of the Influences of Training Data Properties on Aerial Image Segmentation ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Copernicus GmbH, V-2-2022, 245–250.
- Engelmann, F., Kontogianni, T., Hermans, A., Leibe, B. (2017): Exploring Spatial Context for 3D Semantic Segmentation of Point Clouds. IEEE International Conference on Computer Vision Workshops (ICCV), IEEE.
- Goodfellow, I., Bengio, Y., Courville, A. (2017): Deep Learning. The MIT Press.
- Grunau, W. (2022): KI und die Potenziale für die Geodäsie – eine Bestandsaufnahme. In: Grunau, W. (Hrsg.): Künstliche Intelligenz in Geodäsie und Geoinformatik, Wichmann Verlag, Berlin Offenbach, 25–46.
- Hackel, T., Wegner, J. D. W., Schindler, K. (2016): Fast Semantic Segmentation of 3D Point Clouds with Strongly Varying Densities. ISPRS Annals of Photogrammetry, Remote Sensing & Spatial Information Sciences, 3.
- Hu, Q., Yang, B., Xie, L., Rosa, S., Guo, Y., Wang, Z., Trigoni, N., Markham, A. (2020): RandLA-Net: Efficient Semantic Segmentation of Large-Scale Point Clouds. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), IEEE.
- Kastl, F., Hinrichs, S. (2022): Die Anwendung von Deep Learning auf Punktwolken, dargestellt am Beispiel der Autobahninfrastruktur Deutschlands. In: Grunau, W. (Hrsg.): Künstliche Intelligenz in Geodäsie und Geoinformatik, Wichmann Verlag, Berlin Offenbach, 141–158.
- Krizhevsky, A., Sutskever, I., Hinton, G. E. (2012): ImageNet Classification with Deep Convolutional Neural Networks. In: Pereira, F., Burges, C., Bottou, L., Weinberger, K. (Eds.): Advances in Neural Information Processing Systems, Curran Associates, 2012, 25.
- Luhmann, T., Robson, S., Kyle, S., Boehm, J. (2013): Close-Range Photogrammetry and 3D Imaging. De Gruyter, Berlin, Germany.
- Lütjens, M., Sternberg, H. (2021): Deep Learning based Detection, Segmentation and Counting of Benthic Megafauna in Unconstrained Underwater Environments. IFAC-PapersOnLine, 54, 76–82.
- Maturana, D., Scherer, S. (2015): VoxNet: A 3D Convolutional Neural Network for Real-Time Object Recognition. In: Proceedings of the International Conference on Intelligent Robots and Systems (IROS), IEEE/RSJ, 922–928.
- Passos, D., Mishra, P. (2022): A Tutorial on Automatic Hyperparameter Tuning of Deep Spectral Modelling for Regression and Classification Tasks, Chemometrics and Intelligent Laboratory Systems. Elsevier BV, 223, 104520.
- Poux, F., Billen, R. (2019): Voxel-based 3D Point Cloud Semantic Segmentation: Unsupervised Geometric and Relationship Feature vs Deep Learning Methods. ISPRS International Journal of Geo-Information. 8(5):213.
- Qi, C. R., Su, H., Mo, K., Guibas, L. J. (2017a): PointNet: Deep learning on point sets for 3D classification and segmentation. Proceedings of the Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, 77–85.
- Qi, C. R., Yi, L., Su, H., Guibas, L. J. (2017b): PointNet++: Deep Hierarchical Feature Learning on Point Sets in a Metric Space. Advances in neural information processing systems, 5099–5108.

- Rashdi, R., Martínez-Sánchez, J., Arias, P., Qiu, Z. (2022): Scanning Technologies to Building Information Modelling: A Review. *Infrastructures*, 7, 49.
- Redmon, J., Divvala, S., Girshick, R., Farhadi, A. (2016). You only look once: Unified, real-time object detection. In: Proceedings of the IEEE conference on computer vision and pattern recognition 779–788.
- Roscher, R., Drees, L. (2022): Einführung in die künstliche Intelligenz und das maschinelle Lernen. In: Grunau, W. (Hrsg.): Künstliche Intelligenz in Geodäsie und Geoinformatik, Wichmann Verlag, Berlin Offenbach, 15–24.
- Roux, M., Dumas, L. (2022): Building Segmentation Based on Stereo Information from Satellite Images. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Copernicus GmbH, V-2-2022, 299–306.
- Shukla, N. (2018): Machine Learning with Tensorflow Manning Pub.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., Rabinovich, A. (2014): Going Deeper with Convolutions. In: Proceedings of the IEEE conference on computer vision and pattern recognition, 1–9.
- Tölgessy, M., Dekan, M., Chovanec, L., Hubinský, P. (2021): Evaluation of the Azure Kinect and Its Comparison to Kinect V1 and Kinect V2. *Sensors*, MDPI AG, 21, 413.
- Voelsen, M., Teimouri, M., Rottensteiner, F., Heipke, C. (2022): Investigating 2D and 3D Convolutions for Multitemporal Land Cover Classification Using Remote Sensing Images. *ISPRS Ann. Photogramm. Remote Sens. Spatial Inf. Sci.*, V-3-2022, 271–279.
- Weinmann, M., Jutzi, B., Hinz, S., Mallet, C. (2015): Semantic point cloud interpretation based on optimal neighborhoods, relevant features and efficient classifiers. *ISPRS Journal of Photogrammetry and Remote Sensing*, Elsevier BV, 105, 286–304.
- Wujanz, D., Burger, M., Tschirschowitz, F., Nietzschnmann, T., Neitzel, F., Kersten, T. (2018): Determination of Intensity-Based Stochastic Models for Terrestrial Laser Scanners Utilising 3D-Point Clouds. *Sensors*, MDPI AG, 18, 2187.

## Kontakt

Eike Barnefske, M.Sc.  
HafenCity Universität Hamburg  
Henning-Voscherau-Platz 1, 20457 Hamburg  
[eike.barnefske@hcu-hamburg.de](mailto:eike.barnefske@hcu-hamburg.de)

Prof. Dr.-Ing. Harald Sternberg  
HafenCity Universität Hamburg  
Henning-Voscherau-Platz 1, 20457 Hamburg  
[harald.sternberg@hcu-hamburg.de](mailto:harald.sternberg@hcu-hamburg.de)

Multisensorstechnologie ist aus dem (geodätischen) Alltag nicht mehr wegzudenken und zeichnet sich durch vielfältige Einsatzmöglichkeiten in Praxis und Forschung aus.

Dieser Tagungsband spannt einen weiten Bogen und zeigt die Vielfalt der Multisensorstechnologie auf: Es geht um die Qualität, Auswertung und Anwendungen von Multisensorsystemen z.B. bei Infrastrukturmaßnahmen oder in der Hydrographie. Hierbei werden sowohl Grundlagen behandelt als auch aktuelle (A)nwendungen und (Z)ukunfts-technologien vorgestellt.



9 783957 863225

Schriftenreihe des DVW  
Band 103 / 2022  
Printversion: 28,80 Euro  
PDF: kostenfrei  
[www.geodesie.info](http://www.geodesie.info)

