

Selbstkalibrierung mobiler Multisensorsysteme mittels geometrischer 3D-Merkmale

Zur Erlangung des akademischen Grades eines

Doktor-Ingenieurs

von der KIT-Fakultät für
Bauingenieur-, Geo- und Umweltwissenschaften,
des Karlsruher Instituts für Technologie (KIT)

genehmigte

Dissertation

von

M.Sc. Markus Hillemann

geb. in Marburg

Tag der mündlichen Prüfung:

21.02.2020

Hauptreferent:

Apl. Prof. Dr.-Ing. Boris Jutzi

Korreferent:

Prof. Dr. Stephan Nebiker

This work is licensed under a Creative Commons “Attribution-NonCommercial-ShareAlike 4.0 International” license.



Kurzfassung

Ein mobiles Multisensorsystem ermöglicht die effiziente, räumliche Erfassung von Objekten und der Umgebung. Die Kalibrierung des mobilen Multisensorsystems ist ein notwendiger Vorverarbeitungsschritt für die Sensordatenfusion und für genaue räumliche Erfassungen. Bei herkömmlichen Verfahren kalibrieren Experten das mobile Multisensorsystem in aufwändigen Prozeduren vor Verwendung durch Aufnahmen eines Kalibrierobjektes mit bekannter Form. Im Gegensatz zu solchen objektbasierten Kalibrierungen ist eine Selbstkalibrierung praktikabler, zeitsparender und bestimmt die gesuchten Parameter mit höherer Aktualität.

Diese Arbeit stellt eine neue Methode zur Selbstkalibrierung mobiler Multisensorsysteme vor, die als Merkmalsbasierte Selbstkalibrierung bezeichnet wird. Die Merkmalsbasierte Selbstkalibrierung ist ein datenbasiertes, universelles Verfahren, das für eine beliebige Kombination aus einem Posenbestimmungssensor und einem Tiefensensor geeignet ist. Die fundamentale Annahme der Merkmalsbasierten Selbstkalibrierung ist, dass die gesuchten Parameter am besten bestimmt sind, wenn die erfasste Punktwolke die höchstmögliche Qualität hat. Die Kostenfunktion, die zur Bewertung der Qualität verwendet wird, basiert auf Geometrischen 3D-Merkmalen, die wiederum auf den lokalen Nachbarschaften jedes Punktes basieren.

Neben der detaillierten Analyse unterschiedlicher Aspekte der Selbstkalibrierung, wie dem Einfluss der Systemposen auf das Ergebnis, der Eignung verschiedener Geometrischer 3D-Merkmale für die Selbstkalibrierung und dem Konvergenzradius des Verfahrens, wird die Merkmalsbasierte Selbstkalibrierung anhand eines synthetischen und dreier realer Datensätze evaluiert. Diese Datensätze wurden dabei mit unterschiedlichen Sensoren und in unterschiedlichen Umgebungen aufgezeichnet.

Die Experimente zeigen die vielseitige Einsetzbarkeit der Merkmalsbasierten Selbstkalibrierung hinsichtlich der Sensoren und der Umgebungen. Die Ergebnisse werden stets mit einer geeigneten objektbasierten Kalibrierung aus der Literatur und einer weiteren, nachimplementierten Selbstkalibrierung verglichen. Verglichen mit diesen Verfahren erzielt die Merkmalsbasierte Selbstkalibrierung bessere oder zumindest vergleichbare Genauigkeiten für alle Datensätze. Die Genauigkeit und Präzision der Merkmalsbasierten Selbstkalibrierung entspricht dem aktuellen Stand der Forschung. Für den Datensatz, der die höchsten Sensorgenauigkeiten aufweist, werden beispielsweise die Parameter der relativen Translation zwischen dem Rigid Body eines Motion Capture Systems und einem Laserscanner mit einer Genauigkeit von ca. 1 cm bestimmt, obwohl die Distanzmessgenauigkeit dieses Laserscanners nur 3 cm beträgt.

Abstract

A mobile multi-sensor system enables the efficient acquisition of spatial data of objects and the environment. The calibration of the mobile multi-sensor system is a necessary pre-processing step for sensor data fusion and for accurate spatial acquisitions. With conventional methods, experts calibrate the mobile multi-sensor system in time-consuming procedures by capturing a calibration object with a known shape. In contrast to such object-based calibrations, self-calibration is more practical, less time-consuming and determines the required parameters with greater currentness.

This thesis presents a new method for self-calibration of mobile multi-sensor systems, which is called Feature-based Self-calibration. The Feature-based Self-calibration is a data-driven, universal approach that is suitable for any combination of a pose estimation sensor and a depth sensor. The fundamental assumption of the Feature-Based Self-Calibration is that the unknown parameters are best determined when the acquired point cloud has the highest possible quality. The cost function used to evaluate this quality is based on geometric 3D-features, which in turn are based on the local neighborhoods of each point.

In addition to a detailed analysis of different aspects of the self-calibration, such as the impact of system poses on the result, the suitability of different Geometric 3D-features for self-calibration, and the convergence radius of the method, the Feature-based Self-calibration is evaluated using one synthetic and three real data sets. These data sets are recorded with different sensors and in different environments.

The experiments show the versatile applicability of the Feature-based Self-calibration with respect to sensors and environments. The results are always compared to a suitable object-based calibration from the literature and a further, reimplemented self-calibration method. Compared to these methods, the Feature-based Self-calibration achieves better or at least comparable accuracies for all data sets. The accuracy and precision of the Feature-based Self-calibration corresponds to the current state of the art. For the data set with the highest sensor accuracy, for example, the parameters of the relative translation between the rigid body of a motion capture system and a laser scanner are determined with an accuracy of approximately 1 cm, although the range measurement accuracy of the utilized laser scanner is only 3 cm.

Vorwort

Der Begriff der *Selbstkalibrierung* im Bereich der Photogrammetrie geht auf eine Publikation von Heinrich Ebner aus dem Jahre 1976 zurück [43]. Die Selbstkalibrierung steht in diesem Fall für die parametrische Beschreibung der Projektion von 3D-Punkten der realen Welt auf 2D-Punkte in einem Kamerabild. In der Photogrammetrie wird diese Aufgabe als Bestimmung der inneren Orientierung einer Kamera bezeichnet. Sie stellt eine Vorbedingung für alle Aufgaben dar, in denen ein Bezug zwischen 2D-Bildkoordinaten und 3D-Weltkoordinaten hergestellt wird. Bei herkömmlichen Kalibrierverfahren bestimmen Experten die gesuchten Parameter aus einem oder mehreren Bildern eines Kalibrierobjektes mit bekannter Form und Größe. Ein Problem dieser Verfahren ist, dass es nicht möglich ist, die Kamera simultan zur eigentlich durchzuführenden Datenerfassung zu kalibrieren. Dadurch können Veränderungen der gesuchten Parameter, die während der Datenerfassung beispielsweise durch mechanische oder thermale Einflüsse auftreten, nicht korrigiert werden, ohne die Datenerfassung zu unterbrechen. Eine Selbstkalibrierung ermöglicht hingegen, dass „sich die Kamera von selbst kalibriert“, während die eigentliche Aufgabe durchgeführt wird. Eine manuelle Kamerakalibrierung ist dadurch nicht mehr notwendig.

Mehr als vier Jahrzehnte später sind Selbstkalibrierungen von Kameras in vielen Softwareprodukten integriert. Sie sind unter anderem ein wesentlicher Bestandteil der Software zur 3D-Rekonstruktion der Umgebung aus Bildern. Agarwal et al. konnten beispielsweise nachweisen, dass die dreidimensionale Rekonstruktion der Innenstadt Roms allein auf Basis von Bildern aus dem Internet möglich ist [1]. Der Anwender muss in diesem Fall also weder vor Ort gewesen sein, noch benötigt er Vorwissen über die beteiligten Kameras oder vertieftes Wissen zur Kamerakalibrierung, um die 3D-Rekonstruktion durchzuführen.

Auch bei der Kalibrierung mobiler Multisensorsysteme bestimmen Experten die gesuchten Parameter mit herkömmlichen Verfahren durch Erfassung eines Kalibrierobjektes mit bekannter Form. Inspiriert durch Arbeiten zur Selbstkalibrierung von Kameras, wurde ein neues Verfahren zur Selbstkalibrierung mobiler Multisensorsysteme entwickelt, das in dieser Arbeit vorgestellt wird.

Inhaltsverzeichnis

Kurzfassung	iii
Abstract	v
Vorwort	vii
Abkürzungen und Symbole	xi
1 Einleitung	1
1.1 Stand der Forschung	4
1.1.1 Objektbasierte Kalibrierung	5
1.1.2 Selbstkalibrierungen	6
1.2 Einordnung der Arbeit im Rahmen der Forschung	8
1.3 Gliederung der Arbeit	11
2 Grundlagen	15
2.1 Kleinste-Quadrate-Ausgleichung	15
2.2 Ausgewählte bildbasierte Methoden zur Bestimmung der Pose und zur räumlichen Erfassung der Umgebung	17
2.2.1 Extraktion künstlicher Marker und lokaler Bildmerkmale	18
2.2.2 Bündelblockausgleichung	20
2.3 Räumliche Erfassung der Umgebung	21
2.3.1 Laserscanning	22
2.3.2 Stereo- und Mehrbildphotogrammetrie	23
2.4 Bestimmung der Pose	24
2.4.1 Globales Navigationssatellitensystem und Inertiale Messeinheit	25
2.4.2 Motion Capture System	27
2.4.3 Simultane Lokalisierung und Kartenerstellung	31
2.5 Extraktion geometrischer 3D-Merkmale zur Prozessierung von dreidimensionalen Punktwolken	37
2.5.1 Bestimmung lokaler Nachbarschaften	37
2.5.2 Bestimmung geometrischer 3D-Merkmale	38
3 Methodik der Merkmalsbasierten Selbstkalibrierung	41
3.1 Der Kern der Merkmalsbasierten Selbstkalibrierung	41
3.1.1 Berechnung der Punktwolke \mathcal{P}	42
3.1.2 Berechnung des geometrischen 3D-Merkmals	44
3.1.3 Berechnung der Kostenfunktion und Parameteroptimierung	46

3.2	Die robuste Merkmalsbasierte Selbstkalibrierung	47
3.2.1	Schwerpunktbasierte Voxelgrid-Filterung	47
3.2.2	Entfernen potentieller Ausreißer	50
3.2.3	Gewichtung mit M-Schätzer	51
3.3	Die rekursive Merkmalsbasierte Selbstkalibrierung - Multiskalenverfahren . .	51
4	Datengrundlage und Vergleichskalibrierungen	55
4.1	Methodik der Entropiebasierten Selbstkalibrierung	56
4.2	Synthetischer Indoor-Datensatz	58
4.3	Kleiner Indoor-Datensatz	60
4.4	Mittlerer Outdoor-Datensatz	64
4.5	Großer Outdoor-Datensatz	65
5	Experimente	69
5.1	Untersuchungen zur Selbstkalibrierung	69
5.1.1	Einfluss der Posen	70
5.1.2	Eignung der Kostenfunktionen	76
5.1.3	Konvergenzradius	82
5.1.4	Vergleich zwischen Einzelskala- und Multiskalenverfahren	83
5.2	Ergebnisse mit realen Daten	85
5.2.1	Kleiner Indoor-Datensatz	85
5.2.2	Mittlerer Outdoor-Datensatz	85
5.2.3	Großer Outdoor-Datensatz	88
5.3	Über die sechs Parameter der relativen Orientierung hinaus	91
6	Diskussion	95
6.1	Einfluss der Posen	95
6.2	Eignung der verschiedenen Kostenfunktionen	96
6.3	Konvergenzradius	99
6.4	Vergleich zwischen Einzelskala- und Multiskalenverfahren	100
6.5	Ergebnisse mit realen Daten	100
6.5.1	Kleiner Indoor-Datensatz	101
6.5.2	Mittlerer Outdoor-Datensatz	101
6.5.3	Großer Outdoor-Datensatz	102
7	Zusammenfassung und Ausblick	105
	Literaturverzeichnis	109

Abkürzungen und Symbole

Abkürzungen

2D	zweidimensional
3D	dreidimensional
BRIEF	Binary Robust Independent Elementary Features
DAEF	Dense Approach for Estimating the Fundamental matrix
DLT	Direkte Lineare Transformation
DMDE	Dense Monocular Depth Estimation
DOF	Degrees Of Freedom
DSO	Direct Sparse Odometry
DTAM	Dense Tracking And Mapping
DVSO	Deep Virtual Stereo Odometry
FAST	Features from Accelerated Segment Test
FPS	Frames Per Second
GNSS	Globales NavigationsSatellitenSystem
ICP	Iterative Closest Point
IMU	Inertial Measurement Unit
IPF	Institut für Photogrammetrie und Fernerkundung
iSAM	incremental Smoothing And Mapping
KIT	Karlsruher Institut für Technologie
LED	Light-Emitting Diode
LSD-SLAM	Large Scale Direct SLAM

MAP	Maximum-A-Posteriori
MCS	Motion Capture System
MLS	Mobiles LaserScanning
ORB	Oriented FAST and rotated BRIEF
PTAM	Parallel Tracking and Mapping
RADLOCC	Robust Automatic Detection in Laser Of Calibration Chessboards
RANSAC	Random Sample Consensus
ROS	Robot Operating System
RQE	Rényi quadratic entropy
SLAM	Simultaneous Localisation and Mapping
TUM	Technische Universität München
UCalMiCeL	Unified Intrinsic and Extrinsic Calibration of a Multi-Camera-System and a Laserscanner
VK	Vergleichskalibrierung

Operatoren und mathematische Symbole

$a, \mathbf{a}, \mathbf{A}$	Skalar, Vektor, Matrix
$\hat{a}, \hat{\mathbf{a}}, \hat{\mathbf{A}}$	Geschätzte Größe
$\tilde{a}, \tilde{\mathbf{a}}, \tilde{\mathbf{A}}$	Wahre Größe
$\mathbf{a}^T, \mathbf{A}^T$	Transponierter Vektor, Transponierte Matrix
\mathcal{A}	Menge
$a(\cdot)$	Funktion
Δa	Fehler bzw. Differenz
a_0	Näherungswert bzw. initialer Parameter
$\ \mathbf{a}\ _2$	L2-Norm von \mathbf{a}
$\mathbf{0}$	3×1 Nullvektor

Symbole und Variablen mit lateinischen Buchstaben

\mathbf{C}	Homogene 4×4 Transformationsmatrix, die die relative Orientierung parametrisiert
$d(\cdot)$	Funktion, die einen schwerpunkt-basierten Voxelgrid-Filter auf eine Punktwolke anwendet
e	Distanz
$f(\mathbf{x})$	Funktionaler Zusammenhang zwischen den Beobachtungen \mathbf{l} und dem Vektor der Parameter \mathbf{x}
$f_{\mathcal{F},i}(\mathbf{x}_i, \mathcal{N}_i)$	Geometrisches 3D-Merkmal für ein Merkmal aus der Menge \mathcal{F}
\mathcal{F}	Menge der wählbaren Geometrischen 3D-Merkmale
$g(\cdot)$	Funktion, die einen 3D-Punkt vom Koordinatensystem des Tiefensensors in ein übergeordnetes Koordinatensystem transformiert
$g(\mathbf{M}_i, \mathbf{C}, h(\mathbf{z}_i))$	Homogene kartesische Koordinaten des i -ten Punktes im übergeordneten Koordinatensystem
$G(\boldsymbol{\mu}, \boldsymbol{\Sigma})$	Mehrdimensionale Normalverteilung mit Erwartungswert $\boldsymbol{\mu}$ und Kovarianzmatrix $\boldsymbol{\Sigma}$
$h(\cdot)$	Funktion, die Polarkoordinaten in kartesische homogene Koordinaten transformiert
$h(\mathbf{z}_i)$	Kartesische homogene Koordinaten des i -ten Punktes im Koordinatensystem des Tiefensensors
\mathbf{I}	Identitätsmatrix
$\mathbf{J}_{\mathbf{x}}$	Jacobimatrix zum Vektor der Parameter \mathbf{x}
k	Anzahl nächster Nachbarn
\mathbf{K}_i	Matrix, die die Innere Orientierung der i -ten Kamera parametrisiert
$K(\cdot)$	Kostenfunktion
\mathbf{l}	Vektor der Beobachtungen
L	Abgerundete Anzahl der Punkte nach Entfernen von Ausreißern
$\mathbf{m}_{i,j}$	Bildpunkt, der der Abbildung des j -ten Objektpunktes im i -ten Bild entspricht
\mathbf{M}_i	Homogene 4×4 Transformationsmatrix, die die i -te Pose des Posenbestimmungssensors mit $i = 1, \dots, N$ parametrisiert (M für <i>motion</i>)

N	Anzahl der Posen und korrespondierenden Messwerten eines Tiefensensors bzw. Anzahl der Punkte in einer Punktwolke
N'	Anzahl der Punkte in einer gefilterten Punktwolke
\mathcal{N}_i	Nachbarschaft des i -ten Punktes \mathbf{x}_i , bzw. Menge der Nachbarpunkte
\mathbf{O}_i	Projektionszentrum der i -ten Kamera
\mathbf{p}_j	j -ter homogener 3D-Objektpunkt
$p(\cdot)$	Wahrscheinlichkeitsfunktion
$p(\mathbf{l} \mathbf{x})$	Maximum Likelihood Verteilung der Beobachtungen \mathbf{l} unter gegebenen Parametern \mathbf{x}
\mathbf{P}_i	Projektionsmatrix des i -ten Bildes
\mathcal{P}	Punktwolke, bzw. Menge der transformierten, rohen Messpunkte eines Tiefensensors
\mathcal{P}'	Gefilterte Punktwolke, bzw. Menge der gefilterten Punkte
$\hat{\mathbf{r}}$	3×1 Vektor der geschätzten relativen Rotation
$\tilde{\mathbf{r}}$	3×1 Vektor der wahren relativen Rotation
\mathbf{R}_i	i -te 3×3 Rotationsmatrix
S_d	Entfernungsauflösung
$S_{\Delta\phi}$	Auflösung der Phasendifferenz
$s(\mathcal{F})$	Signumfunktion für Geometrische 3D-Merkmale der Menge \mathcal{F}
t	Laufzeit
$\hat{t}_x, \hat{t}_y, \hat{t}_z$	Geschätzte relative Translation in X-, Y-, bzw. Z-Richtung
$\tilde{t}_x, \tilde{t}_y, \tilde{t}_z$	Wahre relative Translation in X-, Y-, bzw. Z-Richtung
\mathbf{t}_i	i -ter 3×1 Translationsvektor
$\hat{\mathbf{t}}$	3×1 Vektor der geschätzten relative Translation
$\tilde{\mathbf{t}}$	3×1 Vektor der wahren relative Translation
v	Ausbreitungsgeschwindigkeit elektromagnetischer Strahlung
\mathbf{x}	Vektor der Parameter
\mathbf{x}_i	i -ter Punkt einer Punktwolke
\mathbf{z}_i	i -te Messung eines Tiefensensors

Symbole und Variablen mit griechischen Buchstaben

Δt	Fehler der relativen Translation
Δr	Fehler der relativen Rotation
$\Delta\Phi$	Phasendifferenz
ζ	Schwellwert in Prozent für die Definition von Ausreißern
ζ_0	ζ für die gröbste Skala
κ	Tuning-Parameter der Huber-Funktion
λ_M	Modulationswellenlänge
$\lambda_{1,i}, \lambda_{2,i}, \lambda_{3,i}$	Eigenwerte des 3D-Strukturtenors des i -ten Punktes \mathbf{x}_i mit $\lambda_{1,i} \geq \lambda_{2,i} \geq \lambda_{3,i} \geq 0$
$\boldsymbol{\mu}$	Vektor aus Mittelwerten
π	Kreiszahl Pi
$\rho(\cdot)$	Verlustfunktion
$\rho_{i,\kappa}(r_i)$	Wert des Huber-Schätzers für das i -te Residuum r_i mit der Tuning-Konstante κ
$\boldsymbol{\Sigma}$	Kovarianzmatrix
$\hat{\phi}, \hat{\theta}, \hat{\psi}$	Geschätzter Roll-, Nick-, bzw. Gierwinkel
$\tilde{\phi}, \tilde{\theta}, \tilde{\psi}$	Wahrer Roll-, Nick-, bzw. Gierwinkel

1 Einleitung

Ein mobiles Multisensorsystem ermöglicht die effiziente, räumliche Erfassung von Objekten und der Umgebung. Durch Sensordatenfusion werden komplementäre Eigenschaften verschiedener Sensoren kombiniert und dadurch Schwächen eines Sensors mit Stärken eines anderen Sensors aufgewogen. Infolgedessen kann die Vollständigkeit, die Genauigkeit und die Zuverlässigkeit der erfassten Daten erhöht werden, was für den Einsatz eines Multisensorsystems statt eines einzelnen Sensors spricht. Durch die Montage eines Multisensorsystems auf einer mobilen Trägerplattform wie einem Flugzeug [70, 116], einem Unmanned Aerial Vehicle [79, 157], einem Fahrzeug [55, 59], einem Handwagen [140, 183], einem Rucksack [13, 115] oder einer handgehaltenen Plattform [18, 194] lässt sich die räumliche Erfassung adäquat in verschiedenen Skalen durchführen.

Eine Anwendung, bei der mobile Multisensorsysteme eingesetzt werden und die von globalem Interesse ist, ist autonomes Fahren. Autonome Fahrzeuge nutzen einen bzw. mehrere Sensoren zur Bestimmung der Position und Ausrichtung im Raum. Außerdem besitzen sie einen Tiefensensor, der zur räumlichen Erfassung der Umgebung und zur Hinderniserkennung notwendig ist. In Anbetracht einer solchen sicherheitskritischen Anwendung wie dem autonomen Fahren ist es essentiell, die Funktionstüchtigkeit und Kalibrierung der Sensoren regelmäßig zu überwachen. Vor dem Hintergrund der zunehmenden Zahl an Sensoren in diesem Bereich wird deutlich, dass die Überwachung durch Experten einen erheblichen personellen, zeitlichen und finanziellen Aufwand bedeutet. Deshalb werden vollautomatische Verfahren benötigt, die die Sensoren auf Basis der erfassten Daten selbstständig verifizieren und gegebenenfalls kalibrieren.

Eine weitere Anwendung, bei der mobile Multisensorsysteme eingesetzt werden, ist *Mobile Mapping*. Mobile Mapping Systeme werden eingesetzt, um digitale Abbilder von Umgebungen zu erstellen. In Kombination mit Methoden wie *Building Information Modeling* (de.: Gebäudedatenmodellierung) oder *Virtual Design and Construction* (de.: Virtuelle Planung und Konstruktion) ermöglichen sie einen Paradigmenwechsel in der Art und Weise wie Gebäude oder Verkehrsinfrastrukturen entworfen, gebaut, gewartet und saniert werden [13]. Abhängig von der Anwendung, müssen die erfassten Daten gewissen Genauigkeitskriterien standhalten. Um dies zu gewährleisten, sind Kalibrierverfahren notwendig, die genaue Ergebnisse erzielen.

Bei der Verwendung mobiler Multisensorsysteme zur räumlichen Erfassung der Umgebung bestehen aus methodischer Sicht drei zentrale Herausforderungen:

1. **Kalibrierung des mobilen Multisensorsystems.** Die Kalibrierung eines mobilen Multisensorsystems hat einen erheblichen Einfluss auf die Qualität der räumlichen Erfassungen der Umgebung [68] und ist ein notwendiger Vorverarbeitungsschritt für die Sensordatenfusion. Sie besteht aus der Bestimmung der *relativen Orientierung*¹ zwischen den Sensoren und aus der Bestimmung der *inneren Orientierung*¹ der einzelnen Sensoren:
 - Die relative Orientierung besteht stets aus einer räumlichen, euklidischen Transformation zwischen den Koordinatensystemen zweier Sensoren. Sie beschreibt eine relative Translation (auch als *lever-arm* bezeichnet) und eine relative Rotation (auch als *bore-sight* bezeichnet) zwischen den beiden Sensoren und hat im dreidimensionalen Raum sechs Parameter.
 - Die Parameter der inneren Orientierung unterscheiden sich dagegen abhängig vom verwendeten Sensor. Der Einfluss der Parameter der inneren Orientierung auf die räumliche Erfassung der Umgebung ist häufig geringer als der Einfluss der Pose und der relativen Orientierung. Für höchste Genauigkeitsansprüche muss die innere Orientierung jedoch berücksichtigt werden [62].
2. **Räumliche Erfassung der Umgebung.** Die räumliche, d. h. die dreidimensionale, geometrische Erfassung der Umgebung ist häufig das primäre Ziel beim Einsatz von mobilen Multisensorplattformen. Je nach Anwendung werden Tiefensensoren wie beispielsweise Laserscanner, Stereo- bzw. Multikamerasysteme oder Entfernungskameras zur räumlichen Erfassung der Umgebung eingesetzt. Die Daten dieser Sensoren werden in Form von dreidimensionalen Punktwolken dargestellt, die direkt analysiert (z. B. klassifiziert) oder zu anderen Repräsentationen weiterverarbeitet werden.
3. **Bestimmung der Pose.** Die Pose, auch als *äußere Orientierung*¹ bezeichnet, beschreibt die Position und Orientierung des mobilen Multisensorsystems im Bezug auf ein übergeordnetes Koordinatensystem. Im Falle von mobilen Plattformen wird die Pose dazu verwendet, einzelne Erfassungen der Umgebung an verschiedenen Orten räumlich miteinander in Verbindung zu bringen. Die *Posenbestimmungssensoren*, die bei mobilen Multisensorsystemen eingesetzt werden, basieren beispielsweise auf Satellitendaten oder Bildmessungen.

Die wichtigsten Einflüsse auf die Qualität der räumlichen Erfassung der Umgebung bilden dabei die Parameter, die in Tabelle 1.1 zusammengefasst sind. Der Fokus dieser Arbeit liegt auf der Bestimmung der relativen Orientierung zwischen einem beliebigen Posenbestimmungssensor und einem beliebigen Tiefensensor. Für die räumliche Erfassung der Umgebung und die Be-

¹ Die Begriffe äußere, relative und innere Orientierung sind in der Photogrammetrie gebräuchlich und beziehen sich dort stets auf Kameras. In dieser Arbeit werden sie jedoch für beliebige Sensoren verwendet. Insbesondere beschreibt die relative Orientierung hier nicht die 5-Parametertransformation mit unbekanntem Maßstab eines Stereobildpaares, sondern die räumliche, euklidische Transformation zwischen Koordinatensystemen zweier beliebiger Sensoren.

Tabelle 1.1: Wichtigste Einflüsse auf die Qualität der räumlichen Erfassung der Umgebung mit einem mobilen Multisensorsystem (verändert nach [63]). Die Parameter, die im Fokus dieser Arbeit stehen, sind fett gedruckt. N entspricht der Anzahl der Posen. *: abhängig von der Art des Tiefensensors (z. B. 2D-Laserscanner: 1, 3D-Laserscanner: 2. Die Abgrenzung zwischen einem 2D- und einem 3D-Laserscanner wird in Kapitel 2.3.1 erläutert.)

	Parameter	Anzahl
Relative Orientierung	Relative Translation	3
	Relative Rotation	3
Räumliche Erfassung	Offset der Distanzmessung	1
	Skalierung der Distanzmessung	1
	Offset der Richtungsmessung	1–2*
	Skalierung der Richtungsmessung	1–2*
Bestimmung der Pose	Translation	$3N$
	Rotation	$3N$
	Skalierung	1

stimmung der Pose wird auf Methoden aus der Fachliteratur zurückgegriffen, die dem aktuellen Stand der Technik entsprechen.

Abbildung 1.1 visualisiert den Einfluss der relativen Orientierung auf eine räumliche Erfassung der Umgebung, die mit einem mobilen Multisensorsystem erfolgte. Die räumliche Erfassung wird darin durch eine dreidimensionale Punktwolke dargestellt. Die obere Punktwolke ist mit einer ungenauen relativen Orientierung berechnet. In diesem konkreten Fall enthält die relative Rotation zwischen dem Posenbestimmungssensor und dem Tiefensensor einen Fehler von fünf Grad im Nickwinkel. Dies entspricht einem systematischen Fehler, der sich in einer verzerrten Punktwolke ausdrückt. Im Gegensatz dazu ist die untere Punktwolke mit einer genaueren relativen Orientierung berechnet. Diese Punktwolke ist visuell schärfer und approximiert die tatsächlichen Gegebenheiten in der Realität mit höherer Genauigkeit. Sie zeigt keinen erkennbaren systematischen Fehler. Abbildung 1.1 verdeutlicht, dass die relative Orientierung einen erheblichen Einfluss auf die Genauigkeit der räumlichen Erfassung hat.

In dieser Arbeit wird eine Selbstkalibrierung vorgestellt, die die relative Orientierung zwischen einem beliebigen Posenbestimmungssensor und einem beliebigen Tiefensensor automatisch bestimmt. Der MATLAB-Code dieser Selbstkalibrierung ist veröffentlicht² in der Hoffnung, die Entwicklung im Bereich der Selbstkalibrierung von mobilen Multisensorsystemen dadurch voranzutreiben.

² <https://github.com/markushillemann/FeatCalibr>




Abbildung 1.1: Punktwolken zur Visualisierung des Einflusses der relativen Orientierung. Oben: Fehlerbehaftete relative Orientierung mit einem Fehler von fünf Grad im Nickwinkel. Unten: Fehlerfreie relative Orientierung. Die fehlerbehaftete relative Orientierung ist ein systematischer Fehler, der sich in einer verzerrten Punktwolke darstellt.

1.1 Stand der Forschung

Herkömmliche Verfahren zur Bestimmung der relativen Orientierung verwenden ein spezielles künstliches Kalibrierobjekt. Diese Verfahren werden daher im Folgenden als *objektbasierte Kalibrierungen* bezeichnet. Das Kalibrierobjekt ist üblicherweise so gestaltet, dass es von allen Sensoren beobachtet werden kann, deren relative Orientierungen bestimmt werden sollen. Objektbasierte Kalibrierungen bestimmen die relative Orientierung auf Basis korrespondierender Beobachtungen des selben Kalibrierobjektes. Der Stand der Forschung im Bereich objektbasierter Kalibrierungen wird in Kapitel 1.1.1 dargelegt.

Daneben existieren *Selbstkalibrierungen* zur Bestimmung der relativen Orientierung. Die Selbstkalibrierung wird auch als *Simultankalibrierung* oder *Autokalibrierung* bezeichnet. Diese Begriffe spiegeln jeweils verschiedene Vorteile eines solchen Kalibrierverfahrens wider: (i) Der Begriff Selbstkalibrierung drückt aus, dass die Kalibrierung basierend auf den Daten durchgeführt wird, die während der eigentlichen Datenerfassung anfallen. Demzufolge müssen keine weiteren Daten eigens für die Kalibrierung erfasst werden. (ii) Der Begriff Simultankalibri-

rung fokussiert darauf, dass die Kalibrierung gleichzeitig mit der Erledigung der eigentlichen Aufgabe abläuft und nicht in einem separaten Arbeitsschritt davor oder danach stattfinden muss. Dadurch haben die bestimmten Parameterwerte die höchstmögliche Aktualität. Es können sogar Veränderungen der gesuchten Parameter, die während der Datenerfassung beispielsweise durch mechanische oder thermale Einflüsse auftreten, korrigiert werden, ohne die Datenerfassung zu unterbrechen. (iii) Der Begriff Autokalibrierung drückt aus, dass die Kalibrierung in einem automatischen Prozess durchgeführt wird, ohne dass zusätzliche manuelle Arbeitsschritte notwendig sind. Der Stand der Forschung im Bereich der Selbstkalibrierungen wird in Kapitel 1.1.2 erläutert.

Bei einer Selbstkalibrierungen ergibt sich ein geringerer Zeitaufwand gegenüber einer objektbasierten Kalibrierung, da die Notwendigkeit entfällt, ein spezielles Kalibrierobjekt herzustellen, die Umgebung mit einem Kalibrierobjekt zu präparieren und spezielle Daten zum Zwecke der Kalibrierung zu erfassen. Aus diesen Gründen ist eine Selbstkalibrierung auch praktikabler als eine objektbasierte Kalibrierung. Darüber hinaus bestimmt eine Selbstkalibrierung aktuellere Parameter, da sie simultan zur Datenerfassung durchgeführt wird und nicht in einem separaten Arbeitsschritt vor oder nach der Datenerfassung. Des Weiteren entfällt bei einer Selbstkalibrierung in der Regel der potentiell fehleranfällige Schritt der Extraktion des Kalibrierobjektes aus den Daten. Allerdings sind die Algorithmen einer Selbstkalibrierung häufig rechenintensiver, da größere Datenmengen prozessiert werden.

1.1.1 Objektbasierte Kalibrierung

Objektbasierte Kalibrierungen sind häufig für eine spezielle Kombination von zwei Sensoren ausgelegt. Die Kalibrierobjekte, die diese Verfahren verwenden, unterscheiden sich je nach verwendeter Sensorik, da sie von beiden Sensoren beobachtbar sein müssen.

Insbesondere für die Bestimmung der relativen Orientierung zwischen einer Kamera und einem Laserscanner wurden in der Fachliteratur bereits zahlreiche Kalibrierverfahren vorgestellt. Die speziellen Kalibrierobjekte, die dabei eingesetzt werden, sind so gestaltet, dass sie aufgrund ihrer Textur gut im Bild und aufgrund ihrer auffälligen Struktur gut in der Punktwolke extrahiert werden können. Sie bestehen beispielsweise aus einer dreieckigen Kalibriertafel [40], einer faltbaren Kalibriertafel [119], einem Kalibrierwürfel [86, 106], einer Kalibriertafel mit Löchern [39] oder einem komplexeren Kalibrierobjekt, das aus mehreren zusammengesetzten Ebenen besteht [106, 172]. Darüber hinaus verwenden einige Verfahren ein Schachbrettmuster [101, 193, 213, 216] oder mehrere Schachbrettermuster simultan [60]. Schachbrettmuster sind insofern praktikabel, als dass sie prinzipiell auch die Bestimmung der inneren Orientierung der Kamera ermöglichen. Durch Korrespondenzen zwischen extrahierten Bilddaten und Punkten der Punktwolke bestimmen diese Verfahren die relative Orientierung zwischen Kamera und Laserscanner. Eine Voraussetzung für all diese Verfahren ist deshalb, dass das Kalibrierobjekt zu

einem Zeitpunkt aus den Daten beider Sensoren extrahiert werden kann. Für die genannten Verfahren bedeutet dies konkret, dass die Anwendbarkeit auf Sensorsysteme begrenzt ist, bei denen die Gesichtsfelder der Kamera und des Laserscanners sich zumindest teilweise überlappen.

Viele Mobile Mapping Systeme setzen *Globale Navigationssatellitensysteme* (GNSS) und *inertiale Messeinheiten* (engl. *Inertial Measurement Unit*, IMU) zur Bestimmung der Pose und einen Laserscanner zur räumlichen Erfassung der Umgebung ein. Die zugeordneten Kalibrierverfahren basieren ebenfalls auf korrespondierenden Beobachtungen von Kalibrierobjekten. Die Kalibrierobjekte bestehen aus Passpunkten, die mit retro-reflektierendem Material signalisiert sind [181], aus mehreren zusammengesetzten Ebenen [65, 75] oder spezielleren Geometrien wie einem halbkugelförmigen Rahmen [94]. Dieses Kalibrierobjekt muss entweder auf spezielle Art und Weise positioniert werden [65] oder die Pose des Kalibrierobjektes muss im Koordinatensystem des GNSS/IMU mit zusätzlichen Sensoren ermittelt werden [75].

1.1.2 Selbstkalibrierungen

Die *Selbstkalibrierung aus natürlichen Szenen* [165] bestimmt die relative Orientierung zwischen einer Kamera und einem 3D-Laserscanner ohne die Verwendung eines speziellen Kalibrierobjektes. Dieses semi-automatische Verfahren erfordert das manuelle Selektieren von Punktkorrespondenzen in der Punktwolke und im Bild der Kamera. Durch Minimierung eines Punktabstandsmaßes im Rahmen einer Kleinste-Quadrate-Ausgleichung können Näherungsparameter für die relative Orientierung optimiert werden. Die *Geradenbasierte Kalibrierung* [131] bestimmt ebenfalls die relative Orientierung zwischen einer Kamera und einem 3D-Laserscanner. Statt manuell selektierter Punktkorrespondenzen extrahiert sie automatisch 3D-Geradensegmente aus der Punktwolke sowie 2D-Geradensegmente aus dem Kamerabild. Aus korrespondierenden 3D-2D-Geradensegmenten berechnet eine Kleinste-Quadrate-Ausgleichung die Parameter der relativen Orientierung durch Minimierung der Summe der Distanzen zwischen ins Bild projizierten Punkten der 3D-Geradensegmente zu den korrespondierenden 2D-Geradensegmenten. Die *Raumeckenbasierte Kalibrierung* [19, 64] verwendet eine Raumecke, die aus drei orthogonalen Ebenen gebildet wird. Das Verfahren ist demzufolge auf Umgebungen beschränkt, die eine solche Raumecke enthalten. In diesem Fall besteht das zu minimierende Maß aus der Summe der Distanzen der Punkte des Laserscanners zu den detektierten Ebenen im Kamerabild.

Das *rigorose Verfahren* [174] setzt die relative Translation zwischen einem GNSS/IMU-System und einem Laserscanner als bekannt voraus und bestimmt die relative Rotation zwischen diesen Sensoren. Es umgeht die Herstellung eines speziellen Kalibrierobjektes. Stattdessen verwendet das Verfahren manuell extrahierte Oberflächen mit bekannter Form, die natürlicherweise in der Umgebung vorkommen. In der Evaluierung des rigorosen Verfahrens sind dies Dachflächen von Gebäuden sowie Fußballfelder, die als planar angenommen werden [174]. Das rigorose

Verfahren bestimmt die Lage und Ausrichtung dieser Oberflächen zusammen mit den Rotationsparametern der relativen Orientierung und einem konstanten Offset der Distanzmessung des Laserscanners. Dafür verwendet es eine Kleinste-Quadrate-Ausgleichung, die die Summe der Distanzen jedes selektierten Laserpunktes von der zugehörigen Oberfläche minimiert. Die *Multifeature-basierte Selbstkalibrierung* [30] ist eine Erweiterung des rigorosen Verfahrens, die die relative Rotation mehrerer 2D-Laserscanner eines fahrzeugbasierten Mobile Mapping Systems simultan bestimmt und zusätzlich zu Oberflächen mit bekannter Form lineare Strukturen wie Hochspannungsleitungen berücksichtigt.

Das *quasi-rigorese Verfahren* [68] ist ein Selbstkalibrierungsverfahren zur Kalibrierung eines *Airborne Laser Scanning*-Systems. Das Airborne Laser Scanning-System kann dabei aus einem beliebigen Posenbestimmungssensor und einem 2D-Laserscanner bestehen. Das Verfahren ist also nicht prinzipiell auf flugzeuggetragene Systeme beschränkt. Das quasi-rigorese Verfahren verwendet zwei überlappende Flugstreifen zur Kalibrierung und benötigt kein spezielles Kalibrierobjekt. Als Eingangsgrößen erfordert es die Punktwolken, die zu den beiden Flugstreifen gehören, die zeitlich zugeordneten Posen des GNSS/IMU-Systems und gute Näherungswerte für die relative Orientierung. Das quasi-rigorese Verfahren optimiert diese Näherungswerte durch eine Kleinste-Quadrate-Ausgleichung, indem eine Distanz zwischen den Punktwolken der beiden Flugstreifen minimiert wird. Diese Distanz berechnet das Verfahren durch eine Punkt-zu-Punkt- bzw. Punkt-zu-Flächen-Metrik, wie sie von der Registrierung von Punktwolken mit dem *Iterative Closest Point (ICP)*-Verfahren [9,31] bekannt sind. Um die Berechnung der Punkt-zu-Flächen-Metrik zu ermöglichen, vermascht eine *Triangulated Irregular Network Generation* die Punktwolke von einem der beiden Flugstreifen. Die Minimierung einer Punkt-zu-Flächen-Metrik wird auch bei *Strip-Adjustment*-Verfahren verwendet. Diese Verfahren registrieren zwei Punktwolken aus unterschiedlichen Flugstreifen und verbessern dadurch einerseits die Posenbestimmung und andererseits die Parameter der relativen Orientierung [63, 73].

Eine neuere Arbeit zeigt, dass das quasi-rigorese Verfahren auch zur Kalibrierung eines UAV-getragenen Mobile Mapping Systems eingesetzt werden kann [157]. Einige Erkenntnisse dieser Arbeit sind hilfreich für die Interpretation der Ergebnisse in Kapitel 6. Diese Erkenntnisse werden deshalb hier zusammengefasst: Für ein typisches UAV-getragenes Mobile Mapping System ist es möglich, fünf der sechs Parameter der relativen Orientierung basierend auf den erfassten Daten zu ermitteln. Dafür muss die überflogene Umgebung eine erhebliche horizontale und vertikale Ausdehnung aufweisen. Zudem muss diese Umgebung mehrfach aus unterschiedlichen Flugrichtungen und Flughöhen erfasst werden. Die vertikale Komponente der Translation kann allerdings nur bestimmt werden, indem zusätzliches Wissen über Höhen in der Umgebung eingeführt wird. Hierzu eignen sich beispielsweise horizontale Ebenen mit bekannter Höhe im Bezug zum GNSS/IMU System. Für eine detaillierte Betrachtung der Untersuchungen sei der/die Leser/in auf [157] verwiesen.

Die *Entropiebasierte Selbstkalibrierung* [124, 170] optimiert Näherungswerte für die relative Orientierung zwischen einem 3D-Laserscanner und einem beliebigen Posenbestimmungssensor mit einer Kleinste-Quadrate-Ausgleichung (siehe Kapitel 2.1). Dafür minimiert die Ausgleichung eine Kostenfunktion, die auf der Entropie der erfassten Punktwolke basiert. Diese Kostenfunktion beschreibt die Punktwolke durch eine mehrdimensionale Gauß'sche Mischverteilung. Je spitzer die Peaks der Kostenfunktion sind, desto schärfer ist die Punktwolke. Durch die Minimierung dieser Kostenfunktion optimiert die Entropiebasierte Selbstkalibrierung demnach die Parameter der relativen Orientierung, sodass die Punktwolke schärfer wird [170]. Der 3D-Laserscanner, mit dem die Entropiebasierte Selbstkalibrierung getestet wird, ist ein Eigenbau, der aus drei 2D-Laserscannern besteht, die auf einer rotierenden Plattform montiert sind [170]. Die Entropiebasierte Selbstkalibrierung wurde ebenfalls verwendet, um ein fahrzeugbasiertes Mobile Mapping System zu kalibrieren, das aus einem GNSS/IMU System, einem 3D-Laserscanner und zwei zusätzlichen 2D-Laserscannern besteht [124]. Dabei bestimmt die Entropiebasierte Selbstkalibrierung in einem ersten Schritt die relative Orientierung zwischen dem GNSS/IMU System und dem 3D-Laserscanner. In einem zweiten Schritt wird die Punktwolke des 3D-Laserscanners genutzt, um die zwei 2D-Laserscanner zu kalibrieren. Die Methode, die dafür eingesetzt wird, maximiert die Ähnlichkeit zwischen der Punktwolke des 3D-Laserscanners und den jeweiligen Punktwolken der 2D-Laserscanner. Das Maß der Ähnlichkeit ist bei dieser Methode die *Jensen-Rényi Divergence* [198]. Mit der gleichen Methode wurden die relativen Orientierungen zwischen dem 3D-Laserscanner und den zwei 2D-Laserscannern des *Oxford RobotCars* bestimmt [125].

1.2 Einordnung der Arbeit im Rahmen der Forschung

Diese Arbeit stellt eine neue Methode zur Selbstkalibrierung von mobilen Multisensorsystemen vor, die als Merkmalsbasierte Selbstkalibrierung bezeichnet wird. Die Merkmalsbasierte Selbstkalibrierung erfüllt alle folgenden Vorteile gleichzeitig:

- Vollständige Bestimmung aller sechs Parameter der relativen Orientierung.
- Universelles Verfahren, das für beliebige Posenbestimmungssensoren und Tiefensensoren geeignet ist.
- Datenbasiertes Verfahren, das bei geeigneter Wahl der Kostenfunktion keine Modellannahmen über die Umgebung trifft.
- Robust gegenüber schlechten Näherungswerten für die Parameter der relativen Orientierung durch ein Multiskalenverfahren.
- Geeignet für verschiedenste Umgebungen.

Die fundamentale Annahme, die die Merkmalsbasierte Selbstkalibrierung trifft, ist, dass die Parameter der relativen Orientierung am besten bestimmt sind, wenn die erfasste Punktwolke die höchstmögliche Qualität hat. Die Kostenfunktion, die zur Bewertung der Qualität verwendet wird, beruht auf geometrischen 3D-Merkmalen, die auf der lokalen Nachbarschaft jedes Punktes basieren.

Neben der detaillierten Analyse unterschiedlicher Aspekte der Selbstkalibrierung wie dem Einfluss der Systemposen auf das Ergebnis, der Eignung verschiedener geometrischer 3D-Merkmale für die Selbstkalibrierung und dem Konvergenzradius des Verfahrens, wird die Merkmalsbasierte Selbstkalibrierung anhand eines synthetischen und dreier realer Datensätze evaluiert. Die Datensätze wurden dabei mit unterschiedlichen Sensoren und in unterschiedlichen Umgebungen aufgezeichnet. Die Ergebnisse werden dabei stets mit einer geeigneten objektbasierten Kalibrierung aus der Literatur sowie der nachimplementierten Entropiebasierten Selbstkalibrierung [170] verglichen.

Tabelle 1.2 zeigt eine Übersicht der beschriebenen Kalibrierverfahren zur Bestimmung der relativen Orientierung. Zusätzlich zu diesen Verfahren, ist die Merkmalsbasierte Selbstkalibrierung in der Tabelle aufgelistet. Die Verfahren sind darin in objektbasierte Kalibrierungen und Selbstkalibrierungen eingeordnet und die Sensoren, mit denen das jeweilige Verfahren getestet wurde, sind aufgeführt. Die Tabelle und die folgenden Erläuterungen dienen dazu, die Merkmalsbasierte Selbstkalibrierung von den Verfahren aus der Literatur abzugrenzen.

Ein großer Teil der Verfahren ist den objektbasierten Kalibrierungen zuzuordnen. Das vorgestellte Verfahren ist dagegen eine Selbstkalibrierung und besitzt dadurch die bereits geschilderten Vorteile gegenüber objektbasierten Kalibrierungen. Viele der Verfahren sind für eine spezielle Kombination von Sensoren geeignet, wie z. B. für die Kombination aus einer Kamera und einem 2D- bzw. 3D-Laserscanner. Dagegen ist die Merkmalsbasierte Selbstkalibrierung für eine beliebige Kombination aus einem Posenbestimmungssensor (GNSS/IMU, Kamera, Stereokamera, Motion Capture System, etc.) und einem Tiefensensor (2D-/3D-Laserscanner, Stereokamera, Time-of-Flight Entfernungskamera, Entfernungskamera mit strukturierter Lichtprojektion, etc.) geeignet.

Im Gegensatz zu dem rigorosen [174] und dem Multifeature-basierten Verfahren [30] bestimmt die Merkmalsbasierte Selbstkalibrierung nicht nur die relative Rotation zwischen zwei Sensoren, sondern auch die relative Translation. Darüber hinaus treffen diese beiden Verfahren Modellannahmen über Strukturen, zu denen einzelne Punkte gehören, die gegebenenfalls verletzt werden. Bei der Merkmalsbasierten Selbstkalibrierung handelt es sich um ein datenbasiertes Verfahren, das bei geeigneter Wahl der Kostenfunktion keine Modellannahmen über die Umgebung trifft und damit ohne Anpassung für beliebige Umgebungen geeignet ist. Abschließend erfordert das rigorose Verfahren eine Extraktion der Punkte, die auf den gewählten Strukturen liegen. Gegenüber der Merkmalsbasierten Selbstkalibrierung ist dies ein zusätzlicher Prozessschritt, der potentiell fehleranfällig ist.

Tabelle 1.2: Verwandte Kalibrierverfahren zur Bestimmung der relativen Orientierung. O: Objektbasierte Kalibrierung, S: Selbstkalibrierung.

Publikation	O/S	Sensoren
Talaya, 2004 [181]	O	GNSS/IMU, 3D-Laserscanner
Gräfe, 2007 [65]; Heinz, 2015 [75]; Jung, 2015 [94]	O	GNSS/IMU, 2D-Laserscanner
Zhang, 2004 [213]; Kassir, 2010 [101]; Vasconcelos, 2012 [193]; Kong, 2013 [106]; Zhou, 2014 [216]; Hu, 2016 [86]; Li, 2016 [119]; Sim, 2016 [172]; Dong, 2017 [40]	O	Kamera, 2D-Laserscanner
Geiger, 2012 [60]	O	Kamera, Strukturierter Lichtprojektor, 3D-Laserscanner
Domhof, 2019 [39]	O	Kamera, Stereokamera, Radar, 2D-/3D-Laserscanner
Scaramuzza, 2007 [165]; Moghadam, 2013 [131]	S	Kamera, 3D-Laserscanner
Gomez-Ojeda, 2015 [64]; Briales, 2015 [19]	S	Kamera, 2D-Laserscanner
Chan, 2013 [30]	S	GNSS/IMU, mehrere 2D-Laserscanner
Skaloud, 2006 [174]; Habib, 2011 [68]; Ravi, 2018 [157]; Hebel, 2011 [73]; Glira, 2016 [63]	S	GNSS/IMU, 2D-Laserscanner
Sheehan, 2012 [170]; Maddern, 2012 [124]	S	GNSS/IMU, 2D-/3D-Laserscanner
Vorgestelltes Verfahren	S	GNSS/IMU, Kamera, Stereokamera, Motion Capture System, 2D-/3D-Laserscanner

Das quasi-rigorose Verfahren [68, 157] und die *Strip-Adjustment*-Verfahren [63, 73] minimieren eine Kostenfunktion, die aus einer Punkt-zu-Flächen-Distanz besteht. Der Punkt stammt dabei aus einer ersten Punktwolke (Streifen) und die Fläche aus einer zweiten überlappenden Punktwolke, deren Punkte vermascht wurden. Das bedeutet, dass die räumliche Erfassung in zwei sich

überlappende Streifen aufgeteilt werden muss. Der anschließende Algorithmus zur Bestimmung der relativen Orientierung ist mit der Registrierung zweier Punktwolken mit dem Iterative Closest Point (ICP)-Verfahren [9, 31] vergleichbar. Das ICP-Verfahren wird zur Feinregistrierung von Punktwolken verwendet und ist nicht robust gegenüber großen initialen Fehlregistrierungen [152]. Übertragen auf die Bestimmung der relativen Orientierung bedeutet dies, dass die Näherungswerte eine hohe Genauigkeit haben müssen, damit solche Verfahren die Parameter der relativen Orientierung verfeinern können. Darüber hinaus treffen diese Verfahren die Modellannahme, dass benachbarte Punkte Teil einer gemeinsamen Fläche sind. Diese Modellannahme wird in der Realität unter Umständen verletzt. Die Merkmalsbasierte Selbstkalibrierung verwendet eine andere Kostenfunktion zur Bewertung der Qualität einer (einzelnen) Punktwolke, die auf einem geometrischen 3D-Merkmal basiert. Bei geeigneter Wahl des geometrischen 3D-Merkmals trifft die Merkmalsbasierte Selbstkalibrierung keine Modellannahmen. Durch diese Kostenfunktion sowie ein Multiskalenverfahren ist die Merkmalsbasierte Selbstkalibrierung robust gegenüber schlechten Näherungswerten.

Die Entropiebasierte Selbstkalibrierung [124, 170] verwendet im Vergleich zur Merkmalsbasierten Selbstkalibrierung eine andere Kostenfunktion. Sie wurde für die Bestimmung der relativen Orientierung zwischen einem GNSS/IMU System und einem 3D-Laserscanner eingesetzt. Durch Verwendung der Daten des 3D-Laserscanners kann die relative Orientierung eines zusätzlichen 2D-Laserscanners bestimmt werden. Prinzipiell ist das Verfahren jedoch auch geeignet, direkt die relative Orientierung zwischen einem Posenbestimmungssensor und einem 2D-Laserscanner zu bestimmen. Die Entropiebasierte Selbstkalibrierung teilt somit die oben aufgeführten Vorteile der Merkmalsbasierten Selbstkalibrierung. Aus diesem Grund wurde sie nachimplementiert und mit den Experimenten in Kapitel 5 zusammen mit der Merkmalsbasierten Selbstkalibrierung evaluiert. Eine formale Beschreibung der Entropiebasierten Selbstkalibrierung erfolgt in Kapitel 4.1 und die Unterschiede zur Merkmalsbasierten Selbstkalibrierung werden in Kapitel 6.2 nochmals detailliert diskutiert.

1.3 Gliederung der Arbeit

Die vorliegende Arbeit ist in sieben Kapitel gegliedert:

Kapitel 2 behandelt die Grundlagen, die zum Verständnis der Methoden, die in dieser Arbeit eingesetzt werden, notwendig sind. Das Kapitel beginnt mit der Beschreibung der Kleinst-Quadrat-Ausgleichung (Kapitel 2.1). Dieses statistische Schätzverfahren bildet das mathematische Fundament der Merkmalsbasierten Selbstkalibrierung sowie vieler anderer Methoden, die für diese Arbeit relevant sind. Dazu gehören beispielsweise bildbasierte Methoden zur Posenbestimmung, sowie zur Rekonstruktion der Umgebung. Die Grundlagen für diese bildbasierten Methoden werden in Kapitel 2.2 erläutert. Die Extraktion künstlicher Marker und lokaler Bildmerkmale (Kapitel 2.2.1) und die Bündelblockausgleichung (Kapitel 2.2.2) als Spezialfall

einer Kleinste-Quadrate-Ausgleichung stellen dabei zentrale Methoden dar und werden deshalb näher beschrieben. Die in dieser Arbeit verwendeten mobilen Multisensorsysteme haben das Ziel, die Umgebung räumlich zu erfassen (Kapitel 2.3). Deshalb behandeln die Grundlagen mit dem Laserscanning (Kapitel 2.3.1) und der Stereo- bzw. Mehrbildphotogrammetrie (Kapitel 2.3.2) zwei effiziente Methoden zur räumlichen Erfassung der Umgebung. Mit einem mobilen Multisensorsystem kann die Umgebung nicht nur an einzelnen Standpunkten statisch, sondern auch von einer mobilen Plattform aus effizient dynamisch erfasst werden. Die Methoden zur Bestimmung der Pose (Kapitel 2.4) dienen dazu die einzelnen Erfassungen räumlich miteinander in Verbindung zu bringen. Das Resultat einer solchen räumlichen Erfassung mit einer mobilen Plattform ist eine dreidimensionale Punktwolke. Für viele Anwendungen bildet die Punktwolke noch nicht das finale Ergebnis, sondern wird weiter prozessiert und mit automatischen Verfahren analysiert (Kapitel 2.5). Im Kontext der Merkmalsbasierten Selbstkalibrierung werden lokale Nachbarschaften für jeden Punkt bestimmt (Kapitel 2.5.1), auf deren Basis geometrische 3D-Merkmale berechnet werden (Kapitel 2.5.2).

Kapitel 3 erläutert anschließend die Methodik der entwickelten Merkmalsbasierten Selbstkalibrierung. Nach einem groben Überblick über das Verfahren und der Erklärung des Grundprinzips, folgt anschließend die detaillierte Erläuterung und die formale Beschreibung der Methodik in einer dreigliedrigen Form:

1. Kapitel 3.1 erläutert den Kern der Merkmalsbasierten Selbstkalibrierung. Dieser besteht im Wesentlichen aus einer Kleinste-Quadrate-Ausgleichung, in der zunächst die Punktwolke aus den Rohdaten berechnet (Kapitel 3.1.1) und anschließend das geometrische 3D-Merkmal für jeden Punkt der Punktwolke bestimmt wird (Kapitel 3.1.2). Darauf basierend wird eine vereinfachte Kostenfunktion berechnet (Kapitel 3.1.3), die im Rahmen der Kleinste-Quadrate-Ausgleichung minimiert wird. Durch die Minimierung dieser Kostenfunktion werden Näherungswerte für die Parameter der relativen Orientierung zwischen einem Posenbestimmungssensor und einem Tiefensensor optimiert.
2. Kapitel 3.2 beschreibt die Vorgehensweise zur Anpassung der Methodik zu einem robusten Verfahren. Dafür wird die Punktwolke mit einem schwerpunktbasierten Voxelgrid gefiltert (Kapitel 3.2.1), potentielle Ausreißer in den Daten werden entfernt (Kapitel 3.2.2) und die Kleinste-Quadrate-Ausgleichung wird durch Verwendung eines robusten Schätzers zu einer iterativ neu gewichteten Kleinste-Quadrate-Ausgleichung erweitert (Kapitel 3.2.3).
3. Kapitel 3.3 besteht schließlich aus der Erweiterung der Methodik zu einem Multiskalenverfahren. Das Multiskalenverfahren macht die Merkmalsbasierte Selbstkalibrierung zu einem rekursiven Verfahren, das robust gegenüber schlechten Näherungswerten ist.

Kapitel 4 beschreibt die Datensätze und Vergleichsverfahren, auf Basis derer die Experimente der entwickelten Merkmalsbasierten Selbstkalibrierung durchgeführt werden. Das Kapitel bietet

zunächst eine Übersicht über die vier Datensätze, die sich in diversen Aspekten unterscheiden. Anschließend erläutert Kapitel 4.1 die Methodik der Entropiebasierten Selbstkalibrierung, die für die Evaluierung nachimplementiert wurde, da sie sich als Vergleichsverfahren zur Merkmalsbasierten Selbstkalibrierung für alle Datensätze eignet. Nach der Beschreibung des synthetischen Indoor-Datensatzes (Kapitel 4.2) folgt die Beschreibung der realen Datensätze und jeweils eines weiteren Vergleichsverfahrens, das für den entsprechenden Datensatz geeignet ist. Dafür erläutern Kapitel 4.3 – 4.5 der Größe nach die Datensätze und Vergleichsverfahren im Detail, beginnend mit dem kleinen Indoor-Datensatz (Kapitel 4.3) über den mittleren Outdoor-Datensatz (Kapitel 4.4) bis hin zum großen Outdoor-Datensatz (Kapitel 4.5).

Kapitel 5 beschreibt die Experimente zur Evaluierung der Selbstkalibrierungen. Allgemeine Untersuchungen der Selbstkalibrierungen werden in Kapitel 5.1 dargestellt. Sie bestimmen den Einfluss der Systemposen auf das Ergebnis einer Selbstkalibrierung (Kapitel 5.1.1), evaluieren verschiedene Kostenfunktionen (Kapitel 5.1.2) inklusive der Kostenfunktion der Entropiebasierten Selbstkalibrierung, ermitteln den Konvergenzradius der Merkmalsbasierten Selbstkalibrierung (Kapitel 5.1.3) und evaluieren den Nutzen des Multiskalenverfahrens im Vergleich zu der Verwendung einer einzelnen Skala (Kapitel 5.1.4). Anschließend beschreibt Kapitel 5.2 die Ergebnisse, die die Merkmalsbasierte Selbstkalibrierung auf den realen Datensätzen erzielt, wobei die Reihenfolge der Beschreibung erneut nach der Größe des Datensatzes festgelegt ist (Kapitel 5.2.1 bis 5.2.3). Die Merkmalsbasierte Selbstkalibrierung dient dazu, die Parameter der relativen Orientierung zwischen zwei Sensoren zu bestimmen. Das Verfahren, das zu diesem Zwecke entwickelt wurde, ist jedoch so generisch, dass prinzipiell auch andere systematische Fehler, die sich auf die Punktwolke auswirken, mit dem Verfahren bestimmt werden können (vgl. Tabelle 1.1). Deshalb zeigt Kapitel 5.3 beispielhaft das weiterführende Potential der Merkmalsbasierten Selbstkalibrierung. Die Methodik wird dafür so angepasst, dass statt der Parameter der relativen Orientierung ein Skalierungsfaktor für die Posen des Systems bestimmt wird. Ein solcher Skalierungsfaktor sollte dann bestimmt werden, wenn die Posen des Posenbestimmungssensors nur bis auf eine unbekannte Skalierung bekannt sind, was beispielsweise bei der bildbasierten Posenbestimmung mit einer einzelnen Kamera der Fall ist.

In Kapitel 6 werden die Ergebnisse der Experimente diskutiert. Dabei liegt der Fokus zunächst auf den Untersuchungen der Selbstkalibrierungen (Kapitel 6.1–6.4) und anschließend auf den Experimenten mit den realen Datensätzen. Diese werden analog zur Reihenfolge in Kapitel 5 diskutiert.

Die Arbeit schließt mit einer Zusammenfassung der Erkenntnisse und dem Ausblick auf zukünftige Forschungsthemen in diesem Kontext in Kapitel 7.

2 Grundlagen

Kapitel 2 gibt einen Überblick über die wichtigsten Methoden, deren Kenntnis in dieser Arbeit vorausgesetzt wird. Das Kapitel beginnt mit der Beschreibung der Kleinste-Quadrate-Ausgleichung. Dabei handelt es sich um ein statistisches Schätzverfahren, das das mathematische Fundament der Merkmalsbasierten Selbstkalibrierung sowie vieler anderer Methoden bildet, die in dieser Arbeit relevant sind. Anschließend werden Grundlagen der bildbasierten Methoden zur Posenbestimmung und zur Rekonstruktion der Umgebung beschrieben. Die mobilen Multisensorsysteme, die in dieser Arbeit verwendet werden, haben das Ziel, die Umgebung räumlich zu erfassen. Deshalb behandelt Kapitel 2.3 zwei effiziente Methoden zur räumlichen Erfassung der Umgebung: Laserscanning und Stereo- bzw. Mehrbildphotogrammetrie. Mit einem mobilen Multisensorsystem kann die Umgebung nicht nur an einzelnen Standpunkten statisch, sondern von einer mobilen Plattform aus effizient dynamisch erfasst werden. Die Methoden zur Bestimmung der Pose (Kapitel 2.4) dienen dazu, die einzelnen Erfassungen räumlich miteinander in Verbindung zu bringen. Das Resultat einer solchen räumlichen Erfassung mit einer mobilen Plattform ist eine dreidimensionale Punktwolke. Für viele Anwendungen bildet die Punktwolke noch nicht das finale Ergebnis. Stattdessen werden Punktwolken weiter prozessiert und mit automatischen Verfahren analysiert (Kapitel 2.5).

2.1 Kleinste-Quadrate-Ausgleichung

Die *Kleinste-Quadrate-Ausgleichung* ist bis heute eine der am häufigsten verwendeten statistischen Schätzverfahren [143]. Sie ist bereits zu Beginn des 19. Jahrhunderts in Publikationen von A.M. Legendre [114] und C.F. Gauß [54] erschienen. Sie bildet das mathematische Fundament für die in dieser Arbeit vorgestellten Methoden zur Selbstkalibrierung von mobilen Multisensorsystemen und wird daher im Folgenden erläutert. Tiefer gehende Betrachtungen dieses und ähnlicher Schätzverfahren können in zahlreichen Fachpublikationen eingesehen werden (z. B. [72, 112, 122, 143, 185]).

Sei \mathbf{l} der Vektor der Beobachtungen und $f(\mathbf{x})$ der funktionale Zusammenhang zwischen diesen Beobachtungen und dem Vektor der Parameter \mathbf{x} . Das übergeordnete Ziel der Kleinste-Quadrate-Ausgleichung ist es, die Parameter \mathbf{x} derart zu schätzen, dass der funktionale Zusammenhang die Beobachtungen möglichst plausibel beschreibt. Mit anderen Worten werden die Parameter derart geschätzt, dass die Wahrscheinlichkeit diese Beobachtungen zu messen maximal wird.

In der Statistik entspricht dies der Suche nach der Maximum Likelihood Verteilung $p(\mathbf{l}|\mathbf{x})$ der Beobachtungen \mathbf{l} unter gegebenen Parametern \mathbf{x} . Unter Annahme einer Gauß-Verteilung mit Kovarianzmatrix Σ kann dieser Zusammenhang durch

$$p(\mathbf{l}|\mathbf{x}) \propto \exp((\mathbf{l} - f(\mathbf{x}))^T \Sigma^{-1} (\mathbf{l} - f(\mathbf{x}))) \quad (2.1)$$

dargestellt werden. Die Likelihood-Funktion zu maximieren, ist äquivalent zur Minimierung des negativen Logarithmus der Likelihood-Funktion [176], weshalb gilt:

$$\min_{\mathbf{x}} \{-\log(p(\mathbf{l}|\mathbf{x}))\} = \min_{\mathbf{x}} \{(\mathbf{l} - f(\mathbf{x}))^T \Sigma^{-1} (\mathbf{l} - f(\mathbf{x}))\}. \quad (2.2)$$

Der Vektor der Differenzen $\mathbf{l} - f(\mathbf{x})$ entspricht dem Vektor der Residuen \mathbf{r} und das zu minimierende Maß $(\mathbf{l} - f(\mathbf{x}))^T \Sigma^{-1} (\mathbf{l} - f(\mathbf{x})) = \|\mathbf{l} - f(\mathbf{x})\|_{\Sigma}$ der Mahalanobis-Distanz. Gleichung 2.2 wird häufig als Kostenfunktion bezeichnet.

Bei den bisherigen Betrachtungen wird ein linearer funktionaler Zusammenhang zwischen Beobachtungen und Parametern vorausgesetzt, im Allgemeinen ist der funktionale Zusammenhang jedoch nicht linear. Die Linearisierung erfolgt in der Regel über eine Taylorreihenentwicklung, deren linearisiertes funktionales Modell mit Abbruch nach dem linearen Term

$$f(\mathbf{x}) = f(\mathbf{x}_0) + \mathbf{J}_x \Delta \hat{\mathbf{x}} \quad (2.3)$$

lautet, wobei die Matrix \mathbf{J}_x die partiellen Ableitungen $\frac{\partial f}{\partial \mathbf{x}}$ enthält und als Jacobimatrix bezeichnet wird. Die Funktion und die Jacobimatrix werden an der Stelle der Näherungswerte \mathbf{x}_0 ausgewertet. $\Delta \hat{\mathbf{x}} = \mathbf{x} - \mathbf{x}_0$ bezeichnet die Parameterzuschläge. Die Näherungswerte der Parameter \mathbf{x}_0 werden somit iterativ verbessert, sodass die Kostenfunktion (Gleichung 2.2) minimiert wird. Die Parameterzuschläge $\Delta \hat{\mathbf{x}}$ können durch

$$\Delta \hat{\mathbf{x}} = (\mathbf{J}_x^T \Sigma^{-1} \mathbf{J}_x)^{-1} \mathbf{J}_x^T \Sigma^{-1} \mathbf{r} \quad (2.4)$$

berechnet werden. Die Art der Berechnung der Parameterzuschläge in Gleichung 2.4 wird als *Gauß-Newton-Methode* bezeichnet.

Im Rahmen dieser Arbeit wird stets die *Levenberg-Marquardt-Methode* [118, 129] verwendet, die eine Alternative zur Gauß-Newton-Methode darstellt. Bei der Levenberg-Marquardt-Methode werden die Parameterzuschläge durch die veränderte Normalgleichung

$$\Delta \hat{\mathbf{x}} = (\mathbf{J}_x^T \Sigma^{-1} \mathbf{J}_x + \mu \mathbf{I})^{-1} \mathbf{J}_x^T \Sigma^{-1} \mathbf{r} \quad (2.5)$$

berechnet. Hierbei entspricht \mathbf{I} der Identitätsmatrix. μ rotiert den Parametervektor in Richtung des stärksten Gradientenabstiegs [176]. Wenn μ sehr klein ist, entspricht dies der Normalgleichung der Gauß-Newton Methode (vgl. Gleichung 2.4), die für gute Näherungswerte den Vorteil

der quadratischen Konvergenz aufweist. Wenn μ stattdessen sehr groß ist, entspricht dies dem *Gradientenabstiegsverfahren*, das den Vorteil hat, robust gegenüber schlechten Näherungswerten zu sein. Bei der Levenberg-Marquardt Methode werden die Parameterzuschläge nur dann übernommen, wenn dadurch der Wert der Kostenfunktion signifikant reduziert wird. Nach der Übernahme der Parameterzuschläge wird μ verkleinert. Falls sich der Wert der Kostenfunktion allerdings nicht signifikant reduziert, werden die Parameterzuschläge verworfen und μ wird stattdessen vergrößert. Durch die veränderte Normalgleichung bei der Levenberg-Marquardt Methode werden die Vorteile der Gauß-Newton Methode und des Gradientenabstiegsverfahrens kombiniert [72].

Für den Fall, dass die Beobachtungen nicht frei von groben Ausreißern sind, können zusätzlich *robuste Schätzfunktionen* in die statistische Parameterschätzung integriert werden. Allgemein gilt eine Schätzfunktion als robust, wenn sie nahezu optimale Werte liefert, auch wenn die Beobachtungen nicht streng normalverteilt sind [143]. Im Kontext der Kleinste-Quadrate-Ausgleichung sind hier insbesondere die sogenannten M-Schätzer [88, 89] zu nennen, die aus einer Verallgemeinerung der Maximum Likelihood Methode entwickelt wurden. Dabei werden die Residuen mit einer speziellen Verlustfunktion ρ gewichtet, sodass die Schätzung robust wird. Dadurch wird die Kleinste-Quadrate-Ausgleichung zu einer iterativ neu gewichteten Kleinste-Quadrate-Ausgleichung [83]. Die Verlustfunktion, die in dieser Arbeit verwendet wird, ist die Huber-Funktion

$$\rho_{\kappa}(r_i) = \begin{cases} \frac{1}{2}r_i^2 & \text{für } r_i < \kappa \\ \kappa(|r_i| - \frac{1}{2}\kappa) & \text{sonst} \end{cases}, \quad (2.6)$$

wobei r_i das i -te Element des Vektors der Residuen \mathbf{r} ist und κ als sogenannter Tuning-Parameter der Verlustfunktion bezeichnet wird [89]. Abbildung 2.1 visualisiert einen Vergleich der Kostenfunktion der Kleinste-Quadrate-Ausgleichung $\rho(r_i) = r_i^2$ und der Huber-Funktion $\rho_{\kappa}(r_i)$.

2.2 Ausgewählte bildbasierte Methoden zur Bestimmung der Pose und zur räumlichen Erfassung der Umgebung

Im Rahmen dieser Arbeit werden bildbasierte Verfahren zur Bestimmung der Pose verwendet (Kapitel 2.4). Das verwendete Motion Capture System (Kapitel 2.4.2) greift dabei auf künstliche Marker zurück und der angewendete bildbasierte Algorithmus zur Simultanen Lokalisierung und Kartenerstellung (Kapitel 2.4.3) basiert auf lokalen Bildmerkmalen. Dieses Kapitel zielt darauf ab, einen groben Überblick über künstliche Marker und lokale Bildmerkmale zu geben und die grundlegenden Ideen zu vermitteln. Im weiteren Verlauf beschreibt Kapitel 2.2.2 die Bündelblockausgleichung, die einen Spezialfall einer Kleinste-Quadrate-Ausgleichung darstellt und eine zentrale Methode in der Photogrammetrie und Computer Vision bildet. Im Rahmen dieser Arbeit wird die Bündelblockausgleichung bei den bildbasierten Simultaneous Localiza-




Abbildung 2.1: Gegenüberstellung der Gewichtungsfunktion der Kleinste-Quadrate-Ausgleichung (grüne Strichpunktlinie) und der Huber-Funktion zur Gewichtung der Residuen in einer iterativ neu gewichteten Kleinste-Quadrate-Ausgleichung (rote Linie).

tion and Mapping-Verfahren (Kapitel 2.4.3), bei der Systemkalibrierung des Motion Capture Systems (Kapitel 2.4.2) und bei der objektbasierten Kalibrierung, die als Vergleichsverfahren für den kleinen Indoor-Datensatz herangezogen wird (Kapitel 4.3), verwendet.

2.2.1 Extraktion künstlicher Marker und lokaler Bildmerkmale

Grundsätzlich können viele verschiedene Merkmale aus Bildern extrahiert werden [207]. Dazu gehören Merkmale, die auf der Intensität, der Form oder der Textur im Bild basieren. Insbesondere die Extraktion *künstlicher Marker* oder *lokaler Bildmerkmale* bildet in vielen Aufgabenstellungen innerhalb der Computer Vision den ersten Schritt in der Verarbeitung der rohen Sensordaten einer Kamera [207]. Zu diesen Aufgabenstellungen gehören Objekterkennung, Posenbestimmung, Kamerakalibrierung, Panoramabilderstellung und die Rekonstruktion und Interpretation der Umgebung [48, 207].

Für weitere Informationen zu künstlichen Markern sei der/die Leser/in auf [168] verwiesen und für eine detaillierte Betrachtung lokaler Bildmerkmale auf [48, 74, 207].

Künstliche Marker

Die Grundidee künstlicher Marker ist, dass sich Bildregionen mit hohen Kontrasten gut extrahieren lassen [168]. Die am häufigsten verwendeten Designs sind runde [105, 137, 150] oder quadratische Marker [110, 134], die schwarz-weiß sind und dadurch hohe Kontraste im Bild aufweisen. Durch die Integrierung von Mustern wie Barcodes oder QR-Codes sind diese schwarz-weißen Marker zudem eindeutig identifizierbar. Abbildung 2.2 visualisiert beispielhaft vier schwarz-weiße Marker. Weiterhin werden aktive Marker wie Laserpointer oder




Abbildung 2.2: Typische künstliche Marker. (a) ARToolkit [110], (b) Aruco [134], (c) Eigenkreation [70] (d) QR-Code.

LED-Marker [6, 7, 109, 179] verwendet, die selbst Licht aussenden und sich dadurch von der dunkleren Umgebung separieren lassen. Alternativ dazu werden passive Marker eingesetzt, die einfallendes Licht stark reflektieren.

Der Vorteil künstlicher Marker liegt in der robusten und effizienten Extraktion mit simplen Algorithmen. Der größte Nachteil ist, dass die Umgebung oder das zu beobachtende Objekt zunächst mit den künstlichen Markern präpariert werden muss.

Lokale Bildmerkmale

Lokale Bildmerkmale, auch als *Keypoints* oder *Interest Points* bezeichnet, sind Bildregionen, die aufgrund ihres natürlichen Aussehens hervorstechen. Im Gegensatz zur Nutzung von künstlichen Markern, muss die Umgebung daher nicht präpariert werden. Allerdings ist die Extraktion lokaler Bildmerkmale i.d.R. schwieriger als die Extraktion künstlicher Marker [168].

Die Extraktion kann unterteilt werden in 1. die Detektion lokaler Bildmerkmale durch *Detektoren* und 2. die Beschreibung der lokalen Bildmerkmale auf Basis des Bildinhalts in der Nachbarschaft durch *Deskriptoren*. Detektoren und Deskriptoren können je nach Anforderung in der Anwendung beliebig miteinander kombiniert werden.

1. Die Idee bei der Detektion ist es, dass hervorstechende Bildregionen starke Änderungen der Intensität in unterschiedlichen Richtungen aufweisen. Diese Änderungen der Intensität können mit Hilfe von Ableitungen oder simplen Grauwertvergleichen detektiert werden. Auf Basis von Ableitungen arbeiten z. B. der Harris-Detektor [71] und der Shi-Tomasi-Detektor [171]. Die Berechnung der Ableitung eines Bildes ist eine verhältnismäßig zeitaufwändige Rechenoperation, binäre Grauwertvergleiche lassen sich im Vergleich dazu schneller durchführen. Daher werden für zeitkritische Anwendungen häufig Detektoren verwendet, die auf binären Grauwertvergleichen basieren wie z.B. *Features from Accelerated Segment Test* (FAST) [160] und *Adaptive and Generic corner detection based on the Accelerated Segment Test* (AGAST) [127]. Des Weiteren werden *binary*

large objects (blobs) detektiert, die entweder helle Bildregionen auf dunklem Grund oder auch dunkle Bildregionen auf hellem Grund darstellen. Der detektierte Punkt ist hierbei i.d.R. der lokale Extrempunkt innerhalb einer solche Bildregion [190]. Bekannte Beispiele für Blob-Detektoren sind *Difference of Gaussian*- (DoG) [121], *Speeded Up Robust Features* (SURF) [8] und KAZE³ [3].

2. Deskriptoren dienen dazu ein detektiertes Merkmal möglichst genau zu beschreiben, sodass der Punkt aufgrund dieser Beschreibung eindeutig identifizierbar und in anderen Bildern wieder auffindbar ist. Ein guter Deskriptor hat einen hohen Informationsgehalt über die lokale Umgebung des Merkmals, ist invariant gegenüber Bildtransformationen wie Rotationen und Skalierungen, lässt sich effizient berechnen und besitzt einen geringen Speicherplatzbedarf. Bekannte Beispiele sind *Scale Invariant Feature Transform* (SIFT) [121], *Binary Robust Independent Elementary Features* (BRIEF) [27], *Oriented FAST and Rotated BRIEF* (ORB) [161] und *Binary Robust Invariant Scalable Keypoints* (BRISK) [117].

2.2.2 Bündelblockausgleichung

Die *Bündelblockausgleichung* ist ein zentrales Verfahren, auf dem zahlreiche Methoden der Photogrammetrie und Computer Vision basieren. Die folgenden Erläuterungen basieren auf [122] und [72]. Für tiefere Betrachtungen sei der/die Leser/in auf diese Quellen verwiesen.

Sei \mathbf{p}_j der j -te homogene 3D-Objektpunkt, der im i -ten Kamerabild mit der homogenen Projektionsmatrix \mathbf{P}_i aufgezeichnet wird. Die Projektionsmatrix

$$\begin{aligned} \mathbf{P}_i &= \mathbf{K}_i \begin{bmatrix} \mathbf{I} & \mathbf{0} \end{bmatrix} \mathbf{M}_i \\ &= \mathbf{K}_i \begin{bmatrix} \mathbf{I} & \mathbf{0} \end{bmatrix} \begin{bmatrix} \mathbf{R}_i & \mathbf{t}_i \\ \mathbf{0}^T & 1 \end{bmatrix} \end{aligned} \quad (2.7)$$

enthält die vollständige Information über den geometrischen Abbildungsvorgang, d. h. die innere Orientierung \mathbf{K}_i , und die Pose \mathbf{M}_i des i -ten Bildes. \mathbf{I} bezeichnet hierbei die 3×3 Identitätsmatrix und $\mathbf{0}$ den 3×1 Nullvektor. Sei außerdem $\mathbf{m}_{i,j}$ der Bildpunkt, der der Abbildung des j -ten Objektpunktes im i -ten Bild entspricht. Die Bündelblockausgleichung soll das folgende Problem lösen: Bei gegebenen Bildpunkten $\mathbf{m}_{i,j}$, sollen die unbekannt Parameter in der Projektionsmatrix \mathbf{P}_i und die Koordinaten der Objektpunkte \mathbf{p}_j ermittelt werden, sodass die Kollinearitätsgleichungen

$$\mathbf{m}_{i,j} = \mathbf{P}_i \mathbf{p}_j \quad (2.8)$$

erfüllt sind.

³ KAZE ist keine Abkürzung, sondern der Name des Detektors.

Aufgrund von verrauschten Bildpunkten ist die Kollinearitätsgleichung in der Praxis niemals exakt erfüllt. In diesem Fall wird unter Annahme von normalverteiltem Rauschen die Maximum Likelihood Verteilung $p(\mathbf{I}|\mathbf{x})$ der Beobachtungen \mathbf{I} unter gegebenen Parametern \mathbf{x} gesucht. Die Lösung liefert eine Kleinste-Quadrate-Ausgleichung (vgl. Kapitel 2.1) durch Minimierung der Kostenfunktion

$$\min_{\mathbf{P}_i, \mathbf{p}_j} \sum_{i,j} d_r(\mathbf{P}_i \mathbf{p}_j, \mathbf{m}_{i,j}), \quad (2.9)$$

wobei $d_r(\mathbf{P}_i \mathbf{p}_j, \mathbf{m}_{i,j})$ die geometrische Bilddistanz zwischen dem projizierten Objektpunkt $\mathbf{P}_i \mathbf{p}_j$ und dem korrespondierenden, beobachteten Bildpunkt $\mathbf{m}_{i,j}$ ist [72]. Diese Bilddistanz wird auch als *Rückprojektionsfehler* bezeichnet.

Die Bündelblockausgleichung ist das genaueste und leistungsfähigste Verfahren zur Bestimmung der Posen und inneren Orientierungen der Kameras und der Objektpunktkoordinaten in der Photogrammetrie, da alle gemessenen Größen sowie alle unbekannt Parameter in einem gemeinsamen Berechnungsvorgang berücksichtigt werden [122]. Die Bündelblockausgleichung ist tolerant gegenüber fehlenden Daten [72] und ermöglicht es, individuelle Kovarianzen für jede Beobachtung anzubringen. Allerdings werden für die Bündelblockausgleichung, wie für jede Kleinste-Quadrate-Ausgleichung, gute Näherungswerte benötigt. Außerdem kann das Ausgleichungsproblem aufgrund vieler Parameter einen hohen Berechnungsaufwand haben.

2.3 Räumliche Erfassung der Umgebung

In der Photogrammetrie und Fernerkundung sowie in der Computer Vision und in der Robotik werden diverse Methoden eingesetzt, um die Umgebung räumlich zu erfassen. Diese Methoden basieren entweder auf den Daten *aktiver* oder *passiver Sensoren* [96]. *Aktive Sensoren* senden zunächst elektromagnetische Strahlung aus, die an der Oberfläche der Umgebung reflektiert wird. Durch den Empfang dieser reflektierten Strahlung, lassen sich Spezifika der bestrahlten Oberfläche ableiten. Zu den aktiven Sensoren, mit denen sich die Umgebung räumlich erfassen lässt, gehören Laserscanner, Strukturierte Lichtprojektionssensoren und *Time-of-Flight* Sensoren. Passive Sensoren dagegen empfangen elektromagnetische Strahlung, die von externen Quellen ausgestrahlt und an den Oberflächen reflektiert wird. Als passive Sensoren werden typischerweise Kameras eingesetzt, um die Umgebung räumlich zu erfassen [98], da diese eine effiziente Möglichkeit darstellen, große Datenmengen in kurzer Zeit aufzuzeichnen [14].

Laserscanning gilt als die primäre Methode zur räumlichen Erfassung der Umgebung mit Mobile Mapping Systemen [13, 154]. Neben dem Laserscanning wird die Stereo- bzw. Mehrbildphotogrammetrie zur räumlichen Erfassung eingesetzt [14]. Für die Datensätze, die in dieser Arbeit betrachtet werden, wird die räumliche Erfassung der Umgebung mittels Laserscanning durchgeführt. Die Stereo- bzw. Mehrbildphotogrammetrie ist im Kontext dieser Arbeit relevant für die verwendeten Technologien zur Bestimmung der Pose in Kapitel 2.4. Daher gibt Kapitel

2.3.1 zunächst eine Einführung ins Laserscanning, eine detaillierte Beschreibung kann in [169] eingesehen werden. Kapitel 2.3.2 beschreibt anschließend die räumliche Erfassung der Umgebung mittels Stereo- bzw. Mehrbildphotogrammetrie. Weitere Informationen hierzu können beispielsweise in [72] und [122] nachgelesen werden.

2.3.1 Laserscanning

Alle Lasermesssysteme beruhen auf einer laserbasierten Distanzmessung, die prinzipiell mit einer hohen Genauigkeit erfolgen kann. Die Distanzmessung wiederum basiert auf der präzisen Bestimmung der Laufzeit, wobei eins von zwei Verfahren eingesetzt wird [169]:

1. Pulslaufzeitverfahren. Beim Pulslaufzeitverfahren wird die Laufzeit t eines kurzen aber intensiven Laserpulses gemessen, der die Distanz vom Lasertransmitter zum Objekt und nach der Reflexion zurück zum Empfänger zurücklegt. Die Distanz e berechnet sich zu

$$e = \frac{v t}{2}, \quad (2.10)$$

wobei v die Ausbreitungsgeschwindigkeit der elektromagnetischen Strahlung ist.

2. Phasendifferenzverfahren. Bei einem kontinuierlichen amplitudenmodulierten Lasermesssystem wird mit Hilfe der Phasendifferenz die Laufzeit bestimmt. Die Distanz e wird aus der Phasendifferenz $\Delta\Phi$ zwischen transmittierter und der nach Reflexion am Objekt wieder empfangener Sinuswelle dieses Laserstrahls durch

$$e = \frac{\lambda_M \Delta\Phi}{4\pi} \quad (2.11)$$

bestimmt, wobei λ_M die Modulationswellenlänge ist. Die Entfernungsauflösung S_e kann durch

$$S_e = \frac{\lambda_M S_{\Delta\Phi}}{4\pi} \quad (2.12)$$

berechnet werden, wobei $S_{\Delta\Phi}$ die Auflösung der Phasendifferenz ist. Bei Verwendung einer einzelnen Modulationsfrequenz ist die Distanz nur unterhalb der maximalen Entfernung $e_{\max} = \lambda_M/2$ eindeutig bestimmt. Mit zeitlich variierenden Modulationsfrequenzen kann sowohl eine hohe maximale Entfernung, als auch eine hohe Entfernungsauflösung erzielt werden.

Die laserbasierte Distanzmessung, die mit einem der beiden Verfahren durchgeführt wird, liefert eine Distanz vom Instrument zum nächsten Objekt in der angezielten Richtung. Durch die Verwendung eines Scan-Mechanismus, wie beispielsweise eines rotierenden Spiegels, kann die Richtung der Distanzmessung variiert werden. Laserscanner führen auf diese Art konsekutiv Distanzmessungen entlang einer Linie durch. Daher werden Laserscanner, die einen solchen Aufbau aufweisen, als Linienscanner bzw. Zeilenscanner bezeichnet. Des Weiteren wird für ei-

nen solchen Laserscanner die Bezeichnung *2D-Laserscanner* verwendet, da aus der stationären Messung 2D-Koordinaten resultieren (Richtung und Distanz).

Um die Umgebung dreidimensional zu erfassen, variieren terrestrische Laserscanner die Richtung der Distanzmessung in einer weiteren Dimension. Dies geschieht üblicherweise durch eine zusätzliche rotierende Plattform. Typischerweise sind Terrestrische Laserscanner so aufgebaut, dass der Scan-Mechanismus die Distanzmessung vertikal und die rotierende Plattform die Distanzmessung horizontal ablenkt. Dadurch resultieren aus der Messung mit einem Terrestrischen Laserscanner 3D-Koordinaten, die aus der Vertikalrichtung, der Horizontalrichtung und der Distanz bestehen. Ein Laserscanner, der von einem stationären Standpunkt aus 3D-Koordinaten liefert, wird auch als *3D-Laserscanner* bezeichnet.

Zur dreidimensionalen Erfassung mit einem 2D-Laserscanner muss dieser auf einer mobilen Plattform mitgeführt werden. Dafür muss jedoch die Pose des 2D-Laserscanners bekannt sein. Dazu wird i. d. R. die Pose der mobilen Plattform mit einem zusätzlichen Posenbestimmungssensor ermittelt (siehe Kapitel 2.4). Zusammen mit der relativen Orientierung zwischen dem Posenbestimmungssensor und dem Laserscanner können die gemessenen 3D-Punkte in ein gemeinsames Koordinatensystem transformiert werden.

2.3.2 Stereo- und Mehrbildphotogrammetrie

Die Photogrammetrie ist ein dreidimensionales Messverfahren, bei dem eine Kamera als Sensor eingesetzt wird. Das mathematische Modell, das dabei zugrunde liegt, ist die Zentralprojektion. Das primäre Ziel der Photogrammetrie ist die räumliche Erfassung von Objekten bzw. der Umgebung auf Basis von Strahlenbündeln [122]. Durch *räumlichen Vorwärtsschnitt* mindestens zweier, korrespondierender, räumlich verschiedener Bildstrahlen lassen sich die Koordinaten eines Objektpunktes bestimmen [122]. Ein Bildstrahl ist dabei der Strahl, der durch das Projektionszentrum der Kamera und den gemessenen Bildpunkt verläuft.

Der *räumliche Vorwärtsschnitt* bestimmt die Koordinaten eines 3D-Objektpunktes \mathbf{p}_j unter gegebenen Projektionsmatrizen, d. h. unter bekannten Posen und inneren Orientierungen von N Kameras mit $N \geq 2$.

Eine Näherungslösung für die Koordinaten des Objektpunktes \mathbf{p}_j kann mit Hilfe der Direkten Linearen Transformation (DLT) bestimmt werden [72]. Ausgangspunkt ist die Kollinearitätsgleichung (vgl. Gleichung 2.8) für das i -te Bild $\mathbf{m}_{i,j} = \mathbf{P}_i \mathbf{p}_j$. Zunächst wird der homogene Skalierungsfaktor eliminiert, indem das Kreuzprodukt

$$\mathbf{m}_{i,j} \times (\mathbf{P}_i \mathbf{p}_j) = \mathbf{0} \quad (2.13)$$

gebildet wird. Mit $\mathbf{m}_i = \begin{bmatrix} u_i & v_i & 1 \end{bmatrix}^T$ ergibt sich ausgeschrieben

$$\begin{bmatrix} v_i \mathbf{P}_{i,Z3}^T \mathbf{p}_j - \mathbf{P}_{i,Z2}^T \mathbf{p}_j \\ \mathbf{P}_{i,Z1}^T \mathbf{p}_j - u_i \mathbf{P}_{i,Z3}^T \mathbf{p}_j \\ u_i \mathbf{P}_{i,Z2}^T \mathbf{p}_j - v_i \mathbf{P}_{i,Z1}^T \mathbf{p}_j \end{bmatrix} = \mathbf{0},$$

wobei $\mathbf{P}_{i,Z1}$ die erste, $\mathbf{P}_{i,Z2}$ die zweite und $\mathbf{P}_{i,Z3}$ die dritte Zeile der Projektionsmatrix \mathbf{P}_i ist.

Daraus kann eine Gleichung der Form $\mathbf{A}\mathbf{p}_j = \mathbf{0}$ gebildet werden, indem die ersten beiden Zeilen aus Gleichung 2.3.2 für jedes Bild verwendet werden. Mit $i = 1 \dots N$ ergibt sich die Matrix \mathbf{A} zu

$$\mathbf{A} = \begin{bmatrix} v_1 \mathbf{P}_{1,Z3}^T & - & \mathbf{P}_{1,Z2}^T \\ \mathbf{P}_{1,Z1}^T & - & u_1 \mathbf{P}_{1,Z3}^T \\ & \dots & \\ v_N \mathbf{P}_{N,Z3}^T & - & \mathbf{P}_{N,Z2}^T \\ \mathbf{P}_{N,Z1}^T & - & u_N \mathbf{P}_{N,Z3}^T \end{bmatrix}. \quad (2.14)$$

Die DLT bestimmt die Lösung des linearen Gleichungssystems $\mathbf{A}\mathbf{p}_j = \mathbf{0}$ mit Hilfe einer Singulärwertzerlegung. Die Lösung entspricht dem Vektor, der zum kleinsten Singulärwert von \mathbf{A} gehört [72].

Die Näherungslösung, die durch die DLT bestimmt wird, kann mit Hilfe einer Kleinste-Quadrate-Ausgleichung (vgl. Kapitel 2.1) optimiert werden. Dabei wird wie bei der Bündelblockausgleichung der Rückprojektionsfehler minimiert (vg. Kapitel 2.2.2). Allerdings werden beim Vorwärtsschnitt nur die Koordinaten der Objektpunkte und nicht auch die Posen und Parameter der inneren Orientierung optimiert.

Mit den hier beschriebenen Methoden des Laserscannings und der Stereo- bzw. Mehrbildphotogrammetrie lässt sich die Umgebung von einem Standpunkt aus räumlich erfassen. Durch Anwendung dieser Methoden in einem mobilen Multisensorsystem, lassen sich auch großräumige Umgebungen effizient erfassen. Um die einzelnen Erfassungen der Umgebung räumlich miteinander in Verbindung zu bringen, müssen zusätzlich die Posen der mobilen Multisensorplattform bestimmt werden.

2.4 Bestimmung der Pose

Die *Bestimmung der Pose* mobiler Sensorsysteme in beliebigen Umgebungen ist heutzutage eine der wesentlichen Herausforderungen in Fachbereichen wie Photogrammetrie, Computer Vision und Robotik. Weitere geläufige Terminologien für die Bestimmung der Pose sind *Lokalisierung* und *Tracking*. Die existierenden Technologien zur Bestimmung der Pose ei-

nes mobilen Multisensorsystems machen sich verschiedene physikalische Prinzipien zu Nutze. Sie verwenden elektromagnetische Strahlung (sichtbares Licht, infrarotes Licht, Laserstrahlen, Radiosignale und Magnetischen Fluss), Schall, physikalische Verbindungen, Gravitation und Massenträgheit [168]. Für jedes physikalische Prinzip gibt es spezialisierte Sensoren, die Signalstärken, Signalrichtungen, Laufzeiten oder elektromechanische Eigenschaften messen. Aus diesen Messgrößen lassen sich entweder Distanzen oder Winkel ableiten. Bei Distanzen ist die Methode zur Bestimmung der Position von einzelnen Punkten die *Trilateration* und bei Winkeln der *Vorwärtsschnitt* bzw. die *Triangulation*. Aus den bekannten Positionen von mindestens drei Punkten an einem Objekt lässt sich auch die Orientierung des Objektes und damit die vollständige Pose bestimmen [168].

Die Pose eines Objektes, auch als *äußere Orientierung* bezeichnet, beschreibt seine Position und Orientierung in Relation zu einem übergeordneten Koordinatensystem. Sie besitzt sechs Freiheitsgrade, wovon drei die Position und drei die Orientierung im Raum beschreiben. Die Pose wird üblicherweise durch eine homogene 4×4 Transformationsmatrix \mathbf{M} (M für *motion*) parametrisiert, die sich auch durch eine 3×3 Rotationsmatrix \mathbf{R} und einen 3×1 Translationsvektor \mathbf{t} darstellen lässt:

$$\mathbf{M} = \begin{bmatrix} \mathbf{R} & \mathbf{t} \\ \mathbf{0}^T & 1 \end{bmatrix}. \quad (2.15)$$

Für die im Rahmen dieser Arbeit vorgestellte Selbstkalibrierung mobiler Multisensorsysteme sind bekannte Posen des Systems eine wesentliche Voraussetzung. Die Posen dienen dazu, einzelne Erfassungen der Umgebung in ein gemeinsames Koordinatensystem zu transformieren. Für die vorgestellten Selbstkalibrierungen kann prinzipiell eine beliebige Technologie zur Bestimmung der Posen verwendet werden. Insbesondere die Genauigkeit der bestimmten Pose und potentielle systematische Fehler können sich auf das Ergebnis der Kalibrierung auswirken. Aus diesem Grund beschreibt Kapitel 2.4 diejenigen Technologien zur Bestimmung der Pose einer mobilen Multisensorplattform, die in den Experimenten zum Einsatz kommen. Der Fokus liegt dabei auf den bildbasierten Technologien (Kapitel 2.4.2 und 2.4.3), die im Rahmen der Experimente angewendet werden. Vorher gibt Kapitel 2.4.1 eine Einführung in die Bestimmung der Pose mit Hilfe von Globalen Navigationssatellitensystemen und Inertialen Messeinheiten. Diese Technologie wurde bei den veröffentlichten Datensätzen, die ebenfalls in den Experimenten benutzt werden, von den entsprechenden Arbeitsgruppen angewendet. Eine Einführung zu weiteren Technologien zur Bestimmung der Pose findet sich z. B. in [168].

2.4.1 Globales Navigationssatellitensystem und Inertiale Messeinheit

Bei einem *Globalen Navigationssatellitensystem* (GNSS) wird die Laufzeit von codierten Radiosignalen gemessen, die von Satelliten emittiert werden. Die Position der Satelliten im Orbit

sowie die aktuelle Uhrzeit sind dabei in dem Signal codiert. Ein Empfänger, der die Signale eines Satelliten empfängt, kann aus der Laufzeitmessung und der Ausbreitungsgeschwindigkeit des Signals die Distanz zwischen Satellit und Empfänger berechnen. Aus den bekannten Distanzen zwischen dem Empfänger und drei verschiedenen Satelliten ließe sich dessen Position ermitteln. Allerdings haben Empfänger in der Praxis einen Empfängeruhrfehler, der zu ungenauen Laufzeitmessungen führt, was sich auf die Positionsbestimmung auswirkt. Aus diesen Grund wird der Empfängeruhrfehler neben den drei Raumkoordinaten als vierte Unbekannte in das Gleichungssystem eingeführt. Dieses Gleichungssystem lässt sich durch den Empfang der Signale von mindestens vier Satelliten lösen. Die Genauigkeit der Positionsbestimmung, die sich dadurch erzielen lässt, kann in einem Bereich von 1 bis 100 m variieren [168].

Höhere Genauigkeiten können durch *differentielles GNSS* erzielt werden. Dabei wird ein zusätzlicher Empfänger dazu verwendet, atmosphärische Einflüsse auf das Signal zu korrigieren. Mit einem differentiellen GNSS lassen sich Genauigkeiten im Bereich von einigen Dezimetern bis wenigen Metern erreichen. Durch die Verwendung von *Real-Time Kinematics*, bei dem zusätzlich die Phase des Signals gemessen wird, kann die Genauigkeit nochmals auf wenige Zentimeter gesteigert werden.

Mit den bisher beschriebenen satellitenbasierten Verfahren lässt sich die Position eines Objektes ermitteln. Zur Bestimmung der vollständigen Pose eines Objektes, muss außerdem noch die Orientierung bestimmt werden. Dafür werden zusätzliche Sensoren benötigt. Eine Möglichkeit ist die Verwendung von mindestens drei starr miteinander verbundenen Empfängern. Durch die Positionsbestimmung jedes einzelnen Empfängers, ist die Orientierung der Empfängerkonfiguration und damit des Objektes eindeutig festgelegt. Eine weitere, häufiger verwendete Möglichkeit ist die Kombination mit einer *inertialen Messeinheit* (engl. *Inertial Measurement Unit*, IMU). Eine IMU besteht aus mehreren Inertialsensoren wie Drehratensensoren und Beschleunigungsmessern. Durch die Messung von Winkelgeschwindigkeiten und Beschleunigungen kann mit Hilfe einer IMU die Pose eines Objektes relativ zu einer vorherigen Pose berechnet werden. Die zweifache Integration der Beschleunigung lässt auf den zurückgelegten Weg und damit auf die Position schließen und die einfache Integration der Winkelgeschwindigkeit auf die Orientierung. Durch die Integration wirken sich Messfehler allerdings mit fortschreitender Messdauer quadratisch bzw. sogar kubisch auf den Positionsfehler aus [210]. Dies führt zu einer hohen Drift bei der Bestimmung der Pose allein mit einer IMU. Durch die Kombination mit den drift freien Messungen eines GNSS-Empfängers kann die Bestimmung der Pose gestützt werden.

Die Kombination aus GNSS und einer IMU ist somit sowohl kurzzeit- als auch langzeitstabil. Sie ist mit Ausnahme der Polregionen global und praktisch jederzeit verfügbar. Im Außenbereich ist sie daher die am häufigsten verwendete Technologie zur Bestimmung der Pose mobiler Multisensorsysteme. Im Innenbereich lässt sich diese Technologie allerdings nicht verwenden, da die Radiosignale keine Wände durchdringen. Daher werden im Innenbereich alternative Systeme zur Bestimmung der Pose eingesetzt.

2.4.2 Motion Capture System

Ein *Motion Capture System* (MCS) besteht aus mindestens zwei Kameras, die um ein Messvolumen herum angeordnet sind und ein Objekt innerhalb des Messvolumens beobachten. In der Praxis werden i.d.R. mehr als zwei Kameras verwendet. Vier Kameras in den Ecken eines Raumes sind eine bewährte Konfiguration [168]. Das Messprinzip eines MCS ist wie bei jeder Kamera die Messung der Richtungen zu Objektpunkten.

Grundsätzlich können MCS unterschieden werden zwischen Systemen, bei denen künstliche Marker detektiert werden [139, 155, 195] und Systemen, die auf natürlichen Merkmalen basieren [173, 182]. Künstliche Marker ermöglichen simplere Methoden und eine robustere Detektion als natürliche Merkmale [168]. Allerdings müssen die Objekte mit solchen künstlichen Markern präpariert werden, was bei natürlichen Merkmalen nicht notwendig ist.

Das MCS, das in den Experimenten zum Einsatz kommt, verwendet künstliche Marker. Aus diesem Grund beschränken sich die folgenden Beschreibungen auf die Funktionsweise eines solchen MCS.

Die Methode für die Bestimmung der Pose des Objektes mit einem MCS, das künstliche Marker verwendet, ist die Bestimmung der Position einzelner 3D-Punkte am Objekt durch einen *räumlichen Vorwärtsschnitt*. Wenn die Position mindestens dreier, starr miteinander verbundener 3D-Punkte am Objekt bestimmt werden kann, so kann auch die Orientierung dieser Punkt-konfiguration und damit des Objektes ermittelt werden. Die drei 3D-Punkte dürfen dabei nicht kollinear sein. Eine solche Punkt-konfiguration wird als *Rigid Body* bezeichnet. Abhängig von der Anordnung der 3D-Punkte des Rigid Bodys und der Implementierung kann es vorkommen, dass die Positionen von mehr als drei 3D-Punkten benötigt werden.

Die Voraussetzung für den räumlichen Vorwärtsschnitt sind bekannte Posen sowie bekannte innere Orientierungen der Kameras. Diese Größen werden häufig vorab im Rahmen einer

0. *Systemkalibrierung* mittels Bündelblockausgleichung

bestimmt [122].

Die Bestimmung der Pose des Rigid Bodys zu jedem Zeitpunkt läuft anschließend nach den folgenden Schritten ab [168]:

1. *Detektion* von Kandidaten für die einzelnen Bildpunkte des Rigid Bodys in allen Bildern
2. *Korrespondenzermittlung* zwischen den Kandidaten mittels Epipolargeometrie
3. *Räumlicher Vorwärtsschnitt* zur Bestimmung der Koordinaten aller Kandidaten
4. *Zuordnung* der Kandidaten zu 3D-Punkten des Rigid Bodys
5. *Bestimmung der Pose des Rigid Bodys* aus den Koordinaten der einzelnen 3D-Punkte

0. Systemkalibrierung

Unter einer *Systemkalibrierung* versteht man allgemein die Bestimmung sämtlicher geometrischer Parameter des gesamten Messsystems [122]. Im Falle eines MCS sind dies die Posen sowie die inneren Orientierungen aller Kameras.

Die Verfahren zur Systemkalibrierung basieren in der Regel auf Aufnahmen von Kalibrierobjekten wie Referenzleisten [123] oder Laserpointern bzw. LED-Markern [6, 7, 109, 179]. Bei Verfahren, bei denen das Kalibrierobjekt aus einem einzelnen Punkt besteht, können nur die Posen, nicht aber die inneren Orientierungen der Kameras bestimmt werden [123]. Durch die Bereitstellung von Informationen aus dem Objektraum wird es möglich, alle Parameter zu bestimmen. Ein Kalibrierobjekt, das die Minimalanforderung erfüllt, ist zum Beispiel ein Objekt, an dem zwei 3D-Punkte detektiert werden können, deren Abstand metrisch bekannt ist [123].

Die Kalibrierobjekte werden bei diesen Verfahren im Messvolumen bewegt und unter verschiedenen Posen aufgenommen. Die Detektion der Bildpunkte am Kalibrierobjekt führt zu einer Anzahl von Bildkoordinaten, die die Beobachtungen für eine Bündelblockausgleichung (vgl. Kapitel 2.2.2) darstellen. Die Bündelblockausgleichung bestimmt die Posen aller Kameras sowie die inneren Orientierungen, sodass das System vollständig kalibriert ist.

1. Detektion

Der erste Schritt bei der Bestimmung der Pose des Rigid Bodys ist die Detektion der verwendeten künstlichen Marker. Das MCS, das in den Experimenten eingesetzt wird [139], detektiert künstliche Marker in Form von retro-reflektierenden Kugeln. Lichtquellen nahe der Kameras des MCS senden infrarotes Licht aus, das von solchen Markern stark reflektiert wird. Die Kameras sind sensitiv für infrarotes Licht, wodurch in Bildbereichen, in denen die Marker abgebildet werden, hohe Intensitätswerte entstehen. Diese Bildbereiche lassen sich durch ein Schwellwertverfahren selektieren. Die Schwerpunkte dieser Bildbereiche werden dann als detektierte Kandidaten für einen Punkt des Rigid Bodys zurückgegeben.

2. Korrespondenzermittlung

Für die Korrespondenzermittlung zwischen den detektierten Kandidaten für 3D-Punkte des Rigid Bodys in unterschiedlichen Bildern kann die Epipolareometrie ausgenutzt werden, die in Abbildung 2.3 visualisiert ist. Dabei wird die *Epipolarebene*, die von den Projektionszentren \mathbf{O}_1 und \mathbf{O}_2 zweier Kameras und einem Bildpunkt der ersten Kamera \mathbf{m}_1 aufgespannt wird, mit der Bildebene der zweiten Kamera geschnitten. Der Schnitt dieser beiden Ebenen wird als *Epipolarlinie* bezeichnet. Der korrespondierende Bildpunkt in der zweiten Kamera \mathbf{m}_2 befindet sich unter idealen Bedingungen exakt auf dieser Epipolarlinie. Aufgrund von Messrauschen kann er allerdings auch leicht neben der Epipolarlinie liegen. Jeder Bildpunkt im zweiten Bild, der

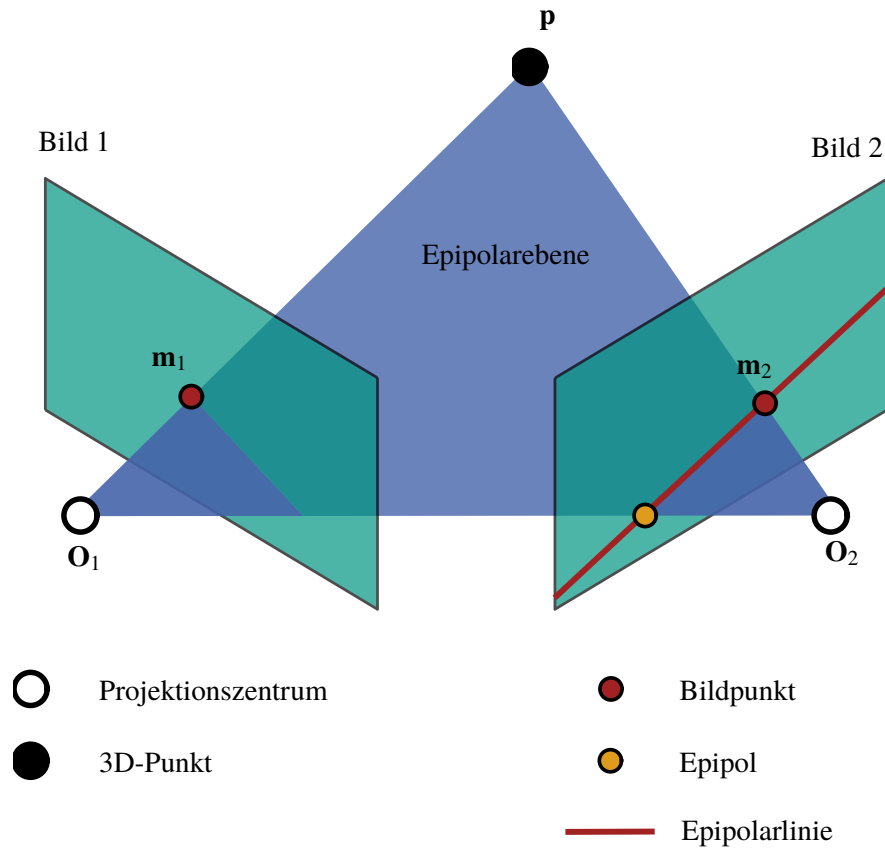


Abbildung 2.3: Epipolargeometrie.

eine kleinere Distanz zur Epipolarlinie hat als ein Schwellwert, kommt als korrespondierender Bildpunkt in Frage.

Falls es mehr als einen solchen Bildpunkt gibt, muss der korrekte Bildpunkt durch Berücksichtigung der Struktur des Objektes bestimmt werden [168]. Dafür muss jedoch zunächst der zugehörige 3D-Punkt durch Vorwärtsschnitt berechnet werden.

3. Räumlicher Vorwärtsschnitt

Im dritten Schritt werden die Koordinaten der 3D-Punkte mittels räumlichem Vorwärtsschnitt bestimmt. Dafür werden jeweils die Bilder aller Kameras verwendet, in denen der jeweilige 3D-Punkt abgebildet wird. Eine DLT (vgl. Kapitel 2.3.2) bestimmt die Näherungskordinaten der 3D-Punkte, die durch Minimierung des Rückprojektionsfehlers im Rahmen einer Bündelblockausgleichung (vgl. Kapitel 2.2.2) verbessert werden.

4. Zuordnung

In der Regel liegen von den vorangegangenen Schritten mehr Kandidaten für 3D-Punkte des Rigid Bodys vor als der Rigid Body tatsächlich 3D-Punkte hat. Die Zuordnung von Kandidaten zu 3D-Punkten des Rigid Bodys wird mit Hilfe der Struktur des Rigid Bodys bestimmt, d.h. mit Distanzen zwischen den 3D-Punkten bzw. mit Winkeln innerhalb des Polygons, das durch die 3D-Punkte aufgespannt wird. Die 3D-Punkte, die zusammen eine Struktur ergeben, die der Soll-Struktur des Rigid Bodys am ähnlichsten ist, werden als 3D-Punkte des Rigid Bodys ausgewählt [168]. Diese Soll-Struktur wird in der Praxis bei der Definition des Rigid Bodys festgelegt. Zum Abmessen der Soll-Struktur kann das MCS verwendet werden. Dabei muss der Benutzer allerdings darauf achten, dass die richtigen 3D-Punkte am Rigid Body detektiert wurden.

5. Bestimmung der Pose des Rigid Bodys

Abschließend kann die Pose des Rigid Bodys aus den Koordinaten der 3D-Punkte des Rigid Bodys bestimmt werden. Dies kann allgemein als Bestimmung einer Transformation zwischen zwei Koordinatensystemen formuliert werden. Die 3D-Punkte des Rigid Bodys liegen im Koordinatensystem des MCS vor. Das zweite Koordinatensystem wird am Rigid Body selbst definiert. Die Transformation zwischen den beiden Koordinatensystemen entspricht der Pose des Rigid Bodys relativ zum Koordinatensystem des MCS.

Die Methode nach Horn [84] verwendet für die Bestimmung dieser Transformation mindestens drei 3D-3D-Korrespondenzen zwischen 3D-Punkten im Koordinatensystem des MCS und 3D-Punkten im Koordinatensystem des Rigid Bodys. Die Position bestimmt sich bei dieser Methode durch die Differenz aus dem Schwerpunkt der 3D-Punkte im Koordinatensystem des MCS und dem Schwerpunkt der 3D-Punkte im Koordinatensystem des Rigid Bodys. Die Orientierung ergibt sich aus dem Produkt der Orientierung des Koordinatensystems des Rigid Bodys und dem Inversen der Orientierung des Koordinatensystems des MCS. Dabei ist die Orientierung des Rigid Bodys bei der Methode nach Horn für drei 3D-Punkte folgendermaßen definiert [168]:

- Die x-Achse entspricht dem Vektor vom ersten zum zweiten 3D-Punkt des Rigid Bodys.
- Die y-Achse ist orthogonal zur x-Achse und liegt in der Ebene, die durch die drei 3D-Punkte aufgespannt wird.
- Die z-Achse entspricht dem Kreuzprodukt aus x- und y-Achse.

Vor- und Nachteile eines MCS

Ein Vorteil eines MCS ist die sehr hohe erzielbare Genauigkeit. Grundsätzlich ist die Genauigkeit abhängig vom Bildmaßstab, also dem Verhältnis einer Objektstrecke zur entsprechenden

Strecke im Bild, von der Aufnahmegeometrie (Anzahl der Kameras, Schnittgeometrie der Abbildungsstrahlen) und von der Identifizierbarkeit der Messpunkte [122]. Kommerzielle Systeme erreichen unter guten Voraussetzungen Genauigkeiten im Bereich von Submillimetern für einzelne Objektpunkte [139, 195]. Die bestimmten Posen sind frei von einer Drift, die Genauigkeiten haben also keine zeitliche Abhängigkeit. Ein weiterer praktischer Vorteil ist, dass die Objekte deren Pose bestimmt werden soll, keine Onboard-Sensorik und keine Recheneinheit tragen müssen. Demzufolge werden die Objekte nicht durch Größe und Gewicht der Sensorik bzw. der Recheneinheit beeinflusst.

Die Nachteile eines MCS sind ein durch die Kameraanordnung begrenztes Messvolumen, die Notwendigkeit der Präparation der Umgebung und u.U. eine geringe Sensitivität gegenüber Orientierungsänderungen des Objektes [209]. Darüber hinaus sind das Abreißen der Sichtverbindung und eine gute Systemkalibrierung sowie Sensorsynchronisierung typische Herausforderungen bei der Verwendung eines MCS.

2.4.3 Simultane Lokalisierung und Kartenerstellung

Odometrie ist die fortlaufende Bestimmung der Pose relativ zu einem beliebigen Startpunkt, basierend auf den Sensormessungen [145]. Einige Odometrie-Verfahren berechnen dabei zusätzlich eine 3D-Rekonstruktion der Umgebung, die nur dazu verwendet wird, die inkrementelle Bestimmung der Pose zu unterstützen [168]. Die rekonstruierten Punkte werden in diesem Fall also nur berücksichtigt, solange sie beobachtet werden.

Simultane Lokalisierung und Kartenerstellung (engl. *Simultaneous Localization and Mapping*, SLAM) bestimmt ebenfalls fortlaufend die Pose relativ zu einem beliebigen Startpunkt. Im Gegensatz zu Odometrie erstellt SLAM jedoch gleichzeitig eine Karte aus den rekonstruierten Punkten. Diese kann wiederverwendet werden, sobald sich der Sensor erneut an einem zuvor bereits besuchten Ort befindet. Dieses Prinzip mündet in zwei wichtigen Konzepten moderner SLAM-Verfahren, durch die sie sich von Odometrie-Verfahren abheben:

1. **Relokalisierung:** Eine *Relokalisierung* ist die Bestimmung der Pose mit Hilfe von existierenden Punkten der Karte, nachdem die fortlaufende Bestimmung der Pose zwischenzeitlich fehlgeschlagen ist. Die Relokalisierung kann das *Kidnapped-Robot-Problem* [32] lösen, bei dem sich das Objekt bewegt hat, ohne dass die Sensoren diese Bewegung beobachtet haben.
2. **Schleifenschluss:** Ein *Schleifenschluss* detektiert Schleifen in der Trajektorie und schließt diese, sodass der Fehler in der Bestimmung der Pose, der sich seit dem letzten Besuch an einem Ort akkumuliert hat, reduziert wird. In der Regel werden die vergangenen Posen rückwirkend verbessert, sodass die Karte global konsistent wird. Ohne Schleifenschlüsse ist die Umgebung wie ein unendlicher Korridor, in dem ständig neue Regionen erkundet werden. Zwei Punkte, die in der Realität nahe beieinander liegen, können in

diesem Fall beliebig weit voneinander entfernt erscheinen. Schleifenschlüsse ermöglichen das Verständnis der tatsächlichen Topologie der Umgebung, sodass beispielsweise eine Abkürzung auf dem Weg von einem Start- zu einem Endpunkt gefunden werden kann [26].

Im Rahmen dieser Arbeit wird SLAM verwendet, um die Pose des Sensorsystems zu bestimmen. Die Karte wird dabei zur Verbesserung der Posenbestimmung, nicht aber zur räumlichen Erfassung der Umgebung genutzt.

Die Architektur eines SLAM-Systems kann in zwei Hauptkomponenten unterteilt werden: Das *Front-end* und das *Back-end* [26]. Das Front-end abstrahiert die Sensordaten in Modelle, die für Schätzungen der Unbekannten geeignet sind. Das Back-end zieht Rückschlüsse aus diesen abstrahierten Sensordaten. Diese Hauptkomponenten werden im Folgenden näher erläutert beginnend mit dem Back-end.

Das SLAM Back-end

Die Standardformulierung des SLAM Back-ends ist die einer *Maximum-a-posteriori* (MAP)-Schätzung [26]. Sei \mathbf{x} der Vektor der unbekannt Parameter. Diese unbekannt Parameter sind typischerweise die Posen des Sensorsystems und die Koordinaten der rekonstruierten Punkte in der Karte sowie in manchen Fällen zusätzliche Parameter der inneren Orientierung des Sensors bzw. der Sensoren. Die MAP-Schätzung der unbekannt Parameter $\hat{\mathbf{x}}$ entspricht der Suche nach der MAP-Verteilung $p(\mathbf{x}|\mathbf{I})$, d.h. der Verteilung der unbekannt Parameter \mathbf{x} unter gegebenen Beobachtungen \mathbf{I} :

$$\hat{\mathbf{x}} = \max_{\mathbf{x}} p(\mathbf{x}|\mathbf{I}). \quad (2.16)$$

Durch das Bayes-Theorem kann dies durch das Produkt aus der Likelihood-Verteilung $p(\mathbf{x}|\mathbf{I})$ und der a-priori Wahrscheinlichkeit der unbekannt Parameter $p(\mathbf{x})$ dargestellt werden:

$$\max_{\mathbf{x}} p(\mathbf{x}|\mathbf{I}) = \max_{\mathbf{x}} p(\mathbf{I}|\mathbf{x}) p(\mathbf{x}). \quad (2.17)$$

Im Falle, dass kein Vorwissen über die unbekannt Parameter vorhanden ist, entspricht $p(\mathbf{x})$ einer Gleichverteilung. Eine Gleichverteilung hat keine Auswirkung auf die Optimierung, weshalb darauf verzichtet werden kann [26]. In diesem Fall reduziert sich die MAP-Schätzung auf eine Maximum-Likelihood-Schätzung. Die Lösung der Maximum-Likelihood-Schätzung entspricht einer Kleinste-Quadrate-Ausgleichung (siehe Kapitel 2.1).

Diese allgemeine Formulierung des SLAM Back-ends hat große Ähnlichkeit mit der Bündelblockausgleichung (vgl. Kapitel 2.2.2). Sie weist allerdings zwei zentrale Unterschiede auf [26]:

1. Die Bündelblockausgleichung nutzt explizit die projektive Geometrie. Diese Formulierung des SLAM Back-ends hingegen verwendet eine universelle Modellierung, die für beliebige Sensoren wie z.B. Inertialsensoren, GNSS, Laserscanner, etc. geeignet ist.
2. Wie bereits in Kapitel 2.2.2 erwähnt, berücksichtigt die Bündelblockausgleichung alle Beobachtungen und alle unbekannt Parameter in einem gemeinsamen Berechnungsvorgang. Ein SLAM-Verfahren dagegen bestimmt die unbekannt Parameter schritt haltend bzw. optimalerweise in Echtzeit. Das heißt, dass zu jedem Zeitschritt neue Beobachtungen und neue unbekannt Parameter hinzukommen. Demzufolge führt ein SLAM-Verfahren die Ausgleichung inkrementell durch.

Das Ausgleichungsproblem vergrößert sich dabei mit fortschreitender Zeit bzw. Erkundung der Umgebung. Damit die Lösung trotzdem in akzeptabler Zeit erfolgt, greifen moderne SLAM-Verfahren häufig auf folgende Schlüsselkonzepte zurück:

- **Sliding Window.** Ein *Sliding Window*-Ansatz basiert auf der Annahme, dass ältere Beobachtungen nicht mehr relevant sind für die Schätzung neu hinzugekommener Parameter, da diese wahrscheinlich an einem anderen Ort aufgezeichnet wurden. Ein solcher Ansatz führt die Ausgleichung nicht mit allen unbekannt Parametern und Beobachtungen durch, sondern nur über einen zeitlich limitierten Bereich [168]. Bei einem naiven *Sliding Window*-Ansatz erstreckt sich dieser Bereich über die zuletzt aufgezeichneten Beobachtungen. Dadurch schätzt ein *Sliding Window*-Ansatz neu hinzukommende Parameter stets auf Basis der letzten Beobachtungen.
- **Faktorgraphen.** Faktorgraphen [107] nutzen aus, dass manche Beobachtungen irrelevant für die Bestimmung bestimmter Parameter sind. Dies äußert sich mathematisch betrachtet in einer spärlich besetzten Jacobimatrix. Die Struktur der spärlich besetzten Jacobimatrix bildet sich durch die Topologie des Faktorgraphen ab [26]. SLAM-Bibliotheken wie *GTSAM* [35], *iSAM* [99] oder *SLAM++* [92] und allgemeinere Optimierungsbibliotheken wie *g2o* [108] und *Ceres* [2] nutzen die Spärlichkeit der Matrizen aus und lösen so Ausgleichungsprobleme mit zehntausenden Variablen in wenigen Sekunden [26].
- **Parallelisierung.** Die Parallelisierung des Back-ends und des Front-ends, entkoppelt diese beiden Komponenten zeitlich voneinander [168]. Das Front-end läuft in Echtzeit, das Back-end aktualisiert die Karte jedoch mit einer geringeren Frequenz. Dadurch wird der Berechnungsaufwand deutlich reduziert. Der bildbasierte SLAM-Algorithmus, der dieses Konzept zuerst demonstriert hat, ist *Parallel Tracking and Mapping*, besser bekannt unter der Abkürzung PTAM [102].
- **Keyframes.** Die Idee von *Keyframes* ist es, nur nützliche Beobachtungen und Parameter in der Ausgleichung zu berücksichtigen und redundante Informationen aus der Ausgleichung zu entfernen [102]. Redundante Information wird vor allem dann aufgezeichnet, wenn der Sensor nicht bewegt wird. Keyframe-Verfahren speichern die Posen, die nicht

als Keyframes ausgewählt werden, relativ zu einem zugeordneten Keyframe. Dadurch verbessert die Ausgleichung bei einem Keyframe-Verfahren alle Posen, ohne dass alle Posen Teil des Ausgleichungsproblems sein müssen.

Filteransätze bilden eine alternative Formulierung des Back-ends, die vor allem von frühen SLAM-Algorithmen verwendet wurde. Insbesondere sind dies Ansätze, die einen *Extended Kalman Filter* [41] oder einen *Rao-Blackwellised Particle Filter* [42, 132] nutzen. Eine Einführung in die Funktionsweise der Filteransätze für SLAM und einen Überblick über die Verfahren bieten [5, 175]. Allerdings haben sich Ansätze, die auf der MAP-Schätzung basieren, als genauer und effizienter als Filteransätze herausgestellt [26].

Das SLAM Front-end

Grundsätzlich kann es in der Praxis schwierig sein, einen analytischen, funktionalen Zusammenhang (vgl. Kapitel 2.1) zwischen den rohen Sensordaten und den unbekanntem Parametern herzustellen [26]. Das Front-end bereitet die rohen Sensordaten in solchen Fällen auf, bevor sie dem Back-end zugeführt werden.

Das Front-end extrahiert relevante Merkmale aus den rohen Sensordaten, mit Hilfe derer der funktionale Zusammenhang formuliert werden kann. Das Front-end muss abhängig von den verwendeten Sensoren formuliert werden. Eine weitere Aufgabe des Front-ends ist die *Datenzuordnung*, die jede Beobachtung mit einer Untermenge der unbekanntem Parameter verknüpft. In den Ausführungen in Kapitel 2.1 wird deutlich, dass für die Lösung des Ausgleichungsproblems im Back-end stets Näherungswerte für die unbekanntem Parameter benötigt werden. Die Bestimmung der Näherungswerte ist ebenfalls Aufgabe des Front-ends [26]. Insbesondere die Bestimmung der Näherungswerte für den ersten Standpunkt, auch als Initialisierung bezeichnet, kann je nach verwendetem Sensor eine besondere Herausforderung darstellen [136].

Sensoren, die häufig für SLAM verwendet werden, sind Kameras [141, 180], Tiefenkameras [180] und Laserscanner [78, 175]. Einige Verfahren setzen Multisensorsysteme ein und kombinieren die Daten mehrerer Sensoren. Hierzu gehören insbesondere SLAM-Verfahren, die mit Stereokameras [46, 136, 199] bzw. Multikamerasystemen [52, 187] arbeiten, sowie SLAM-Verfahren, die eine Kamera und eine IMU (engl. *Visual Inertial-SLAM*) [167] verwenden.

Im Rahmen dieser Arbeit wurde ORB-SLAM2 [136] mit den Daten einer Stereokamera angewendet. Die folgenden Abschnitte beschreiben daher zunächst bildbasierte SLAM-Verfahren. Anschließend wird ORB-SLAM2 im Kontext bildbasierter SLAM-Verfahren eingeordnet.

Tabelle 2.1: Methodische Einordnung von ORB-SLAM2 im Kontext bildbasierter SLAM Verfahren. *: Dieser Name wird nicht vom Autor genutzt, sondern wird hier aus Konsistenzgründen eingeführt.

Methode	indirekt	direkt
spärlich	monoSLAM [34], PTAM [102], ORB-SLAM [135] ORB-SLAM2 [136]	DSO [45], DVSO [212]
dicht	DAEF* [192] DMDE* [156]	DTAM [142], REMODE [151], LSD-SLAM [46]

Bildbasierte SLAM-Verfahren

Die Methoden bildbasierter SLAM Verfahren lassen sich hinsichtlich zweier Charakteristika einordnen: indirekt oder direkt, spärlich oder dicht [45].

Indirekte Methoden verwenden ein Front-end, das die rohen Intensitätswerte, die von der Kamera gemessen werden, zunächst aufbereitet. Dafür extrahiert das Front-end markante Punkte aus den Bildern. Dies ermöglicht die Formulierung des funktionalen Zusammenhangs auf Basis der Koordinaten der Bildpunkte durch die Kollinearitätsgleichung (vgl. Gleichung 2.8). Bei einer indirekten, bildbasierten Methode wird im Back-end demzufolge der Rückprojektionsfehler (vgl. Gleichung 2.9) minimiert. *Direkte* Methoden überspringen die Sensordatenaufbereitung im Front-end und verwenden stattdessen die rohen Intensitätswerte im Back-end. Statt dem Rückprojektionsfehler, wird bei direkten Methoden der photometrische Fehler minimiert.

Spärliche Methoden verwenden eine limitierte Anzahl von rekonstruierten 3D-Punkten für die Karte. *Dichte* Methoden dagegen rekonstruieren für jedes Pixel im Bild einen 3D-Punkt.

Für alle vier möglichen Kombinationen der beiden Charakteristika existieren Algorithmen. Tabelle 2.1 ordnet jeder Kombination bekannte Beispiele zu.

ORB-SLAM2

ORB-SLAM2 [136] ist ein bildbasiertes SLAM-Verfahren, das sowohl mit einer Stereokamera als auch mit einer Tiefenkamera funktioniert. Für die Experimente in Kapitel 5 wird eine Stereokamera verwendet.

Grundsätzlich unterscheidet sich die Verwendung einer Stereokamera bzw. einer Tiefenkamera im Vergleich zur Verwendung einer einzelnen Kamera folgendermaßen: Die Tiefe eines Punktes ist direkt messbar und muss nicht aus mehreren Bildern trianguliert oder durch Vorwissen über

die Umgebung bestimmt werden. Aus diesem Unterschied ergeben sich vier Vorteile gegenüber einem SLAM-Verfahren mit einer einzelnen Kamera [136]: (i) Die Skalierung der Karte und der Posen ist bestimmt. (ii) Die Skalierung driftet nicht mit fortschreitender Exploration. (iii) Die Initialisierung kann direkt auf Basis der ersten Messung bestimmt werden. (iv) Das SLAM-Verfahren ist robuster gegenüber reinen Rotationen.

Wie Tabelle 2.1 zeigt, verwendet ORB-SLAM2 eine indirekte, spärliche SLAM-Methode. Im Front-end verwendet ORB-SLAM2 lokale Bildmerkmale in Form von *Oriented FAST and rotated BRIEF* (ORB) Merkmalen [161]. Die Parameter, die im Back-end durch Minimierung des Rückprojektionsfehlers optimiert werden, bestehen im Falle von ORB-SLAM2 aus den Posen und den Koordinaten der Punkte der Karte. Die inneren Orientierungen der beiden Kameras des Stereokamerasystems sowie die relative Orientierung zwischen den beiden Kameras werden von ORB-SLAM2 als bekannt vorausgesetzt. Diese Größen müssen daher im Vorfeld durch Kalibrierung bestimmt werden. ORB-SLAM2 ist ein vollwertiges SLAM-Verfahren, das in der Lage ist, Relokalisierungen und Schleifenschlüsse durchzuführen. Auch die oben beschriebenen Schlüsselkonzepte moderner SLAM-Verfahren sind in ORB-SLAM2 implementiert. Es handelt sich also bei ORB-SLAM2 um ein SLAM-Verfahren auf dem aktuellen Stand der Technik.

Vor- und Nachteile von SLAM

SLAM-Verfahren basieren nicht auf einem vorher erstellten Modell der Umgebung, sondern erzeugen mit Hilfe der Sensorik selbst ein solches Modell. Die Umgebung muss dafür also weder bekannt sein, noch präpariert werden, was einen großen Vorteil eines SLAM-Verfahrens darstellt. Im Gegensatz zu Odometrie-Verfahren ist es mit SLAM-Verfahren darüber hinaus möglich, topologische Beziehungen in der Umgebung herzustellen, wodurch zum Beispiel Abkürzungen gefunden werden können [26].

Viele SLAM-Verfahren funktionieren nur in statischen Umgebungen. Dynamische Umgebungen stellen eine besondere Herausforderung dar, da zwischen der Eigenbewegung des Sensors und der Bewegung von Objekten in der Umgebung unterschieden werden muss. Je nach verwendeter Sensorik, werden häufig zusätzliche Ansprüche an die Umgebung gestellt. Bildbasierte SLAM-Verfahren benötigen z.B. eine ausreichende Beleuchtung und genügend Textur in den Bildern. Für SLAM-Verfahren, die mit Laserscannern arbeiten, wird dagegen genügend räumliche Struktur in der Umgebung vorausgesetzt [87]. Die Fusion von Kameras und Laserscannern kann hier Abhilfe schaffen [97]. Des Weiteren sind SLAM-Verfahren trotz Schleifenschlüssen nicht gänzlich frei von einer Drift bei der Bestimmung der Pose. Dadurch wird die Pose mit voranschreitender Exploration weniger genau.

2.5 Extraktion geometrischer 3D-Merkmale zur Prozessierung von dreidimensionalen Punktwolken

Das Ergebnis der räumlichen Erfassung der Umgebung mit den in Kapitel 2.3 beschriebenen Methoden sind dreidimensionale Punktwolken. Insbesondere bei der effizienten Erfassung großräumiger Umgebungen mit einer mobilen Plattform sind die Punkte einer solchen Punktwolke in der Regel unstrukturiert, ungleichmäßig verteilt und enthalten keinerlei semantische Informationen. Die Prozessierung von Punktwolken bereitet die aufgezeichneten Punktwolken daher auf, sodass die enthaltene Information für typische Aufgaben wie Mustererkennung, Klassifikation oder Objekterkennung genutzt werden kann. Dieses Kapitel befasst sich im Speziellen mit der Extraktion geometrischer 3D-Merkmale aus den Punktwolken, da diese Merkmale für die Methodik des vorgestellten Selbstkalibrierungsverfahrens relevant sind. Die geometrischen 3D-Merkmale werden auf Basis der Punkte in einer lokalen Nachbarschaft des betrachteten Punktes beschrieben. Daher erläutert Kapitel 2.5.1 zunächst die Bestimmung der lokalen Nachbarschaften und Kapitel 2.5.2 anschließend die Extraktion geometrischer 3D-Merkmale.

2.5.1 Bestimmung lokaler Nachbarschaften

Welche Punkte in einer lokalen Nachbarschaft \mathcal{N}_i eines betrachteten 3D-Punktes $\mathbf{X}_i \in \mathbb{R}^3$ liegen, hängt von der Definition der Nachbarschaft ab. Die gängigsten Definitionen einer Nachbarschaft sind [203]:

1. **Sphärische Nachbarschaft.** Die sphärische Nachbarschaft ist definiert durch alle Punkte innerhalb einer Kugel [113]. Der Mittelpunkt dieser Kugel ist der betrachtete 3D-Punkt und der Radius der Kugel ist ein frei wählbarer Parameter.
2. **Zylindrische Nachbarschaft.** Die zylindrische Nachbarschaft ist definiert durch alle 3D-Punkte, deren Projektion in eine Ebene innerhalb eines Kreises liegen [49]. Der Mittelpunkt dieses Kreises ist die Projektion des betrachteten Punktes in die Ebene und der Radius des Kreises ist ein frei wählbarer Parameter.
3. **Nachbarschaft mit fester Anzahl.** Die Nachbarschaft mit fester Anzahl ist definiert durch die $k \in \mathbb{N}$ nächsten Nachbarn zum betrachteten 3D-Punkt [120]. Die Anzahl k der Nachbarn ist ein frei wählbarer Parameter.

Diese Definitionen der Nachbarschaft geben durch einen Radius oder die Anzahl der Nachbarn eine feste Nachbarschaftsgröße für jeden Punkt einer Punktwolke vor. Allerdings variiert die Punktdichte einer aufgezeichneten Punktwolke, insbesondere bei der Erfassung durch ein mobiles Multisensorsystem. Dadurch variiert auch die Anzahl der Punkte in einer sphärischen und zylindrischen Nachbarschaft bzw. die metrische Größe der Nachbarschaft mit fester Punktzahl. Für die Eindeutigkeit der auf Basis der Nachbarschaft abgeleiteten Informationen kann

es bei einer solchen Punktwolke zuträglich sein, eine individuelle Nachbarschaftsgröße für jeden einzelnen Punkt zu bestimmen [203]. Die Ansätze, die individuelle Nachbarschaftsgrößen für jeden Punkt bestimmen, basieren beispielsweise auf der Bestimmung der Dimensionalität (*Dimensionality-based Scale Selection*) [37] oder der Entropie in der lokalen Nachbarschaft (*Eigenentropy-based Scale Selection*) [208].

Eine Alternative zur Bestimmung individueller Nachbarschaftsgrößen sind Ansätze, die mehrere Nachbarschaftsgrößen verwenden. Solche Ansätze bestimmen für jede dieser Nachbarschaftsgrößen geometrische 3D-Merkmale und leiten so Informationen über die Geometrie auf mehreren Skalen ab [20]. Kleine Nachbarschaften eignen sich für die Analyse feiner Geometrien, während große Nachbarschaften wie Glättungsfilter wirken [149], da größere Nachbarschaften den Einfluss einzelner Punkte auf die Analyse der Geometrie verringern. Mit einem solchen Ansatz lässt sich beispielsweise das Ergebnis einer Klassifikation verbessern [144].

2.5.2 Bestimmung geometrischer 3D-Merkmale

Mit Hilfe *geometrischer 3D-Merkmale* lassen sich dreidimensionale Punktwolken automatisch analysieren. Die häufigste Anwendung in diesem Kontext ist die Klassifikation [69, 203]. Geometrische 3D-Merkmale werden aber auch zur groben Registrierung von Punktwolken [24] und zur Erkennung von Objekten innerhalb der Punktwolken [53] genutzt. Insbesondere die geometrischen 3D-Merkmale, die aus den Eigenwerten des 3D-Strukturtenors abgeleitet werden, haben sich als deskriptiv herausgestellt [203]. Da diese geometrischen 3D-Merkmale eine spezifische Eigenschaft der Punkte in einer lokalen Nachbarschaft durch einen einzelnen Wert darstellen, sind sie besonders intuitiv. Die geometrischen 3D-Merkmale *Linearität*, *Planarität* und *Sphärizität* ermöglichen es beispielsweise, die primäre Dimensionalität einer lokalen Nachbarschaft zu identifizieren.

Die lokalen Eigenschaften um einen betrachteten Punkt \mathbf{x}_i lassen sich durch geometrische 3D-Merkmale beschreiben. Insbesondere geometrische 3D-Merkmale, die auf dem 3D-Strukturtenor basieren, sind weit verbreitet. Der 3D-Strukturtenor ist die Kovarianzmatrix, die auf Basis der 3D-Koordinaten der Punkte in einer lokalen Nachbarschaft \mathcal{N}_i des betrachteten Punktes \mathbf{x}_i berechnet wird. Die drei Eigenwerte des 3D-Strukturtenors beschreiben die Ausdehnung eines 3D-Ellipsoids entlang der Hauptachsen. Seien $\lambda_{i,1}, \lambda_{i,2}, \lambda_{i,3} \in \mathbb{R}$ mit $\lambda_{i,1} \geq \lambda_{i,2} \geq \lambda_{i,3} \geq 0$ die Eigenwerte des 3D-Strukturtenors. Folgende Strukturen lassen sich intuitiv ableiten (vgl. Abbildung 2.4):

- Eine lineare (1D) Struktur ist gegeben, falls $\lambda_{i,1} \gg \lambda_{i,2} \geq \lambda_{i,3}$, da die betrachteten Punkte hauptsächlich entlang einer Hauptachse ausgedehnt sind.
- Eine planare (2D) Struktur ist gegeben, falls $\lambda_{i,1} \geq \lambda_{i,2} \gg \lambda_{i,3}$, da die Punkte hauptsächlich in einer Ebene verteilt sind.




Abbildung 2.4: Punkte einer lokalen Nachbarschaft \mathcal{N}_i um einen betrachteten Punkt \mathbf{X}_i . Die drei Eigenwerte $\lambda_{i,1}, \lambda_{i,2}, \lambda_{i,3}$ des 3D-Strukturtenors beschreiben die Ausdehnung eines 3D-Ellipsoids entlang der Hauptachsen.

- Eine volumetrische (3D) Struktur ist gegeben, falls $\lambda_{i,1} \approx \lambda_{i,2} \approx \lambda_{i,3}$, da die Punkte eine ähnliche Ausdehnung in alle Richtungen haben.

Durch die analytische Betrachtung der Eigenwerte lassen sich also die lokalen Punktwolkencharakteristika auf Basis spezifischer, primitiver Formen beschreiben [95]. Diese primitiven Formen können dabei mit parametrischen Modellen beschrieben werden. Eine Alternative zur Beschreibung mit parametrischen Modelle bieten lokale 3D-Formmerkmale [149, 211], die die lokale Struktur um einen Punkt \mathbf{x}_i nur auf Basis der Eigenwerte des 3D-Strukturtenors beschreiben. Lokale 3D-Formmerkmale sind intuitiv und repräsentieren eine spezielle Eigenschaft der Punkte in einer Nachbarschaft durch einen einzelnen Wert. Aus diesem Grund sind diese Merkmale gut interpretierbar. Allerdings zeigen neuere Untersuchungen bezüglich der Genauigkeit und Robustheit, dass einige dieser Merkmale anfälliger gegenüber der Diskretisierung und dem Rauschverhalten in der Punktwolke sind, als andere [38].

Weitere geometrische Merkmale, die häufig verwendet werden, basieren auf Winkelstatistiken [133], Höhencharakteristiken und lokalen Planaritäten [128], Punktabständen und Höhendifferenzen [197] oder Momenten und Höhenmerkmalen [69]. Des Weiteren können 2D-Merkmale durch Projektion der 3D-Punkte in eine Ebene abgeleitet werden [203]. Darüber hinaus existieren Merkmale, die spezifische Eigenschaften der Punkte in einer Nachbarschaft extrahieren und gruppieren, z. B. in Form von Histogrammen, sodass höherdimensionale Deskriptoren für diese Punkte entstehen. Zu diesen Merkmalen gehören beispielsweise *spin image*-Deskriptoren [93], *3D-shape-context*-Deskriptoren [53], *Signature of Histograms of Orienta-*

tions-Deskriptoren [164, 184], *Fast Point Feature Histograms* [162] und Merkmale, die Oberflächenverteilungen berücksichtigen [147]. Diese Merkmale beschreiben spezifische Punkte der Punktwolke möglichst eindeutig. Durch den hochdimensionalen Deskriptor sind solche Merkmale allerdings schwer zu interpretieren. Für eine detailliertere Beschreibung sei der/die Leser/in auf die jeweiligen Publikationen bzw. eine Zusammenfassung in [203] verwiesen.

Die in Kapitel 3 vorgestellte Methode zur Selbstkalibrierung benötigt Merkmale, die eine Aussage über die Qualität einer Punktwolke treffen. Die Qualität der Punktwolke soll dabei unabhängig von den Geometrien in der Umgebung beurteilt werden, damit die Selbstkalibrierung prinzipiell in beliebigen Umgebungen funktioniert. Für diese Aufgabe eignen sich Merkmale mit hochdimensionalem Deskriptor nicht. Die Experimente in Kapitel 5.1.2 enthalten daher keine Untersuchungen solcher Merkmale. Die geometrischen 3D-Merkmale, die auf den Eigenwerten des 3D-Strukturtenors basieren, sind dagegen prinzipiell geeignet und werden in den Experimenten vollständig berücksichtigt.

3 Methodik der Merkmalsbasierten Selbstkalibrierung

Dieses Kapitel erläutert die Methodik der Merkmalsbasierten Selbstkalibrierung und basiert auf dem Journal-Beitrag

Hillemann, M.; Weinmann, M.; Mueller, M.S.; Jutzi, B.: Automatic Extrinsic Self-Calibration of Mobile Mapping Systems Based on Geometric 3D Features. *Remote Sensing* 11-16, 2019.

Die fundamentale Idee der Merkmalsbasierten Selbstkalibrierung ist, dass die Parameter der relativen Orientierung mit der höchsten Genauigkeit bestimmt sind, wenn die erfasste Punktwolke die höchste Qualität hat. Die Metrik, die dabei für die Bewertung der Qualität herangezogen wird, beruht auf einem geometrischen 3D-Merkmal (vgl. Kapitel 2.5.2). Die Merkmalsbasierte Selbstkalibrierung berechnet das geometrische 3D-Merkmal für jeden Punkt der Punktwolke aus dem zugehörigen 3D-Strukturtenor. Im Wesentlichen bildet die Summe aus den Werten des geometrischen 3D-Merkmals aller Punkte das Maß für die Qualität der gesamten Punktwolke.

Die Erläuterung der vollständigen Methodik der Merkmalsbasierten Selbstkalibrierung erfolgt in einer dreigliedrigen Form:

1. Kapitel 3.1 erläutert zunächst den Kern der Methodik.
2. Anschließend beschreibt Kapitel 3.2 die Vorgehensweise zur Erweiterung der Methodik zu einem robusten Verfahren.
3. Kapitel 3.3 erläutert abschließend die Verbesserungen der Methodik zu einem Multiskalenverfahren, das die Merkmalsbasierte Selbstkalibrierung zu einem rekursiven Verfahren macht.

3.1 Der Kern der Merkmalsbasierten Selbstkalibrierung

Abbildung 3.3 zeigt den Kern der Merkmalsbasierten Selbstkalibrierung. Die Eingangsgrößen sind die Messwerte des Tiefensensors, korrespondierende⁴ Posen des Posenbestimmungssensors und Näherungswerte für die Parameter der relativen Orientierung. Eine Kleinste-Quadrate-

⁴ Eine Synchronisierung der Sensoren wird somit vorausgesetzt.

Ausgleichung bildet die Basis der Merkmalsbasierten Selbstkalibrierung. Diese ist in Abbildung 3.3 schematisch als großes Rechteck in der Mitte dargestellt. Alle Schritte innerhalb dieses Rechtecks werden in jeder Iteration der Kleinste-Quadrate-Ausgleichung ausgeführt.

In jeder Iteration berechnet die Merkmalsbasierte Selbstkalibrierung als erstes die Punktwolke aus den Eingangsgrößen. Für jeden Punkt der Punktwolke wird anschließend das gewählte geometrische 3D-Merkmal ermittelt. Auf Basis der geometrischen 3D-Merkmale wertet die Merkmalsbasierte Selbstkalibrierung eine Kostenfunktion aus, die im Rahmen der Kleinste-Quadrate-Ausgleichung minimiert wird. Dabei werden die Parameter der relativen Orientierung inkrementell verändert, sodass die Kostenfunktion kleinere Werte annimmt. Die Iterationen werden schließlich abgebrochen, sobald die L2-Norm dieser Änderungen unter einem vorgegebenen Schwellwert liegt. Die ersten drei Schritte werden im Folgenden detailliert erläutert und formal beschrieben.

In den folgenden formalen Beschreibungen der Methodik werden zahlreiche Variablen und Bezeichnungen eingeführt. Diese werden zur Übersicht in einer Tabelle am Ende des Kapitels (Tabelle 3.1) zusammengefasst.

3.1.1 Berechnung der Punktwolke \mathcal{P}

Sei \mathbf{z}_i die i -te Richtungs- und Distanzmessung des Laserscanners, bzw. die Polarkoordinaten des i -ten Punktes im Koordinatensystem des Laserscanners. Sei weiterhin h eine Funktion, die Polarkoordinaten in kartesische homogene Koordinaten transformiert. Dann entspricht $h(\mathbf{z}_i)$ den kartesischen homogenen Koordinaten des i -ten Punktes im Koordinatensystem des Laserscanners. Sei darüber hinaus \mathbf{M}_i die i -te Pose des Posenbestimmungssensors mit $i = 1, \dots, N$, wobei N die Anzahl der Posen und korrespondierenden Messwerte des Laserscanners ist.

Seien weiterhin g eine Funktion, die $h(\mathbf{z}_i)$ vom Koordinatensystem des Laserscanners in das übergeordnete Koordinatensystem des Posenbestimmungssensors transformiert, und damit

$$g(\mathbf{M}_i, \mathbf{C}, h(\mathbf{z}_i)) = \mathbf{M}_i \mathbf{C} h(\mathbf{z}_i) \quad (3.1)$$

die homogenen kartesischen Koordinaten des i -ten Punktes im übergeordneten Koordinatensystem. Hierbei stellt \mathbf{C} eine homogene Transformationsmatrix dar, die die relative Orientierung parametrisiert und somit die gesuchten Parameter der Merkmalsbasierten Selbstkalibrierung enthält. Innerhalb der Kleinste-Quadrate-Ausgleichung verwendet die Merkmalsbasierte Selbstkalibrierung jedoch eine andere Parametrisierung für die relative Orientierung, da die homogene Transformationsmatrix \mathbf{C} mit einer Dimension von 4×4 16 Einträge aber nur sechs Freiheitsgrade besitzt. Für die Kleinste-Quadrate-Ausgleichung wird daher eine minimale Parametrisierung für die relative Orientierung verwendet, die sich durch den Translationsvektor \mathbf{t} und den Rotationsvektor \mathbf{r} darstellen lässt. Der Rotationsvektor \mathbf{r} repräsentiert dabei die

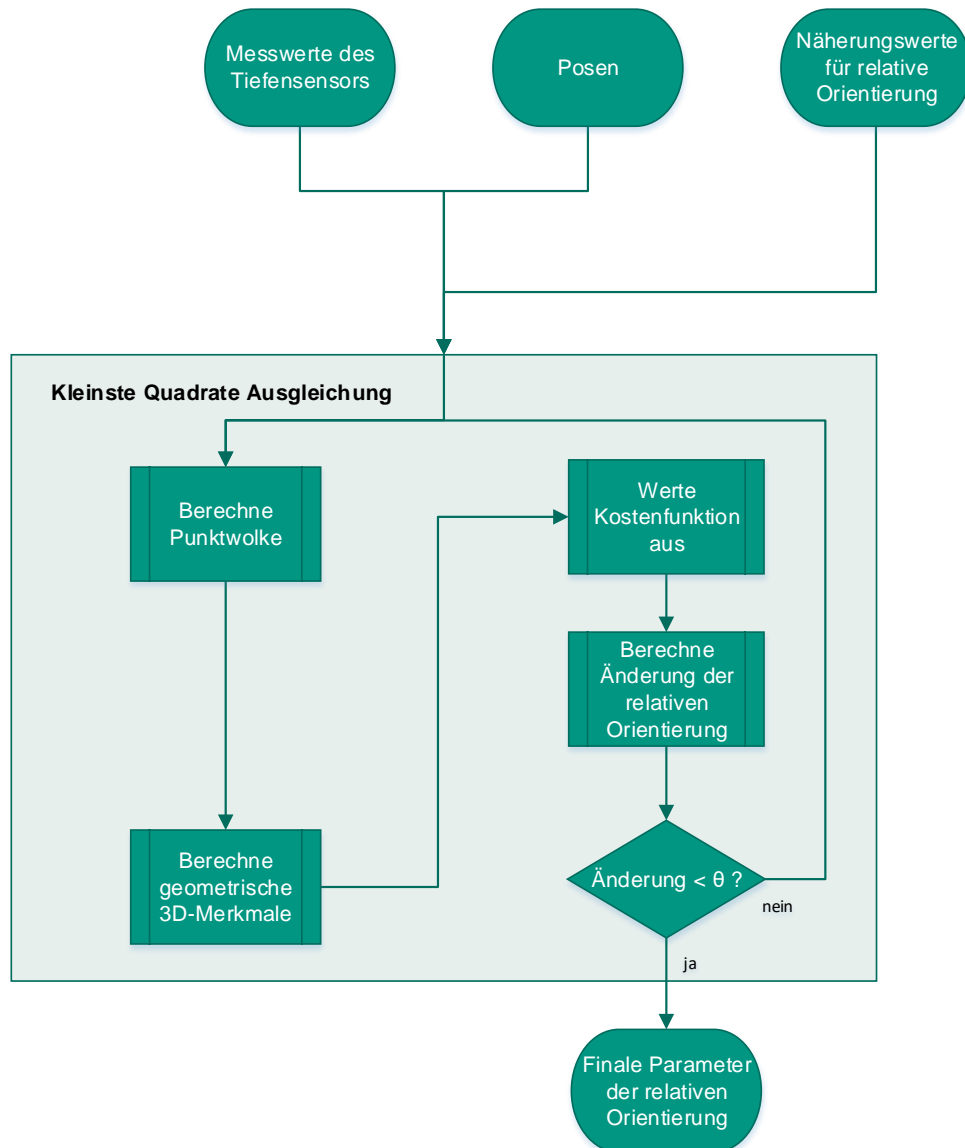


Abbildung 3.1: Vereinfachter Ablauf der Merkmalsbasierten Selbstkalibrierung. Neben den 3D-Punkten und zugehörigen Posen des Posenbestimmungssensors sind Näherungswerte der Parameter der relativen Orientierung die Eingangsgrößen für die Merkmalsbasierte Selbstkalibrierung. Die Parameter der relativen Orientierung werden im Rahmen einer Kleinste-Quadrate-Ausgleich optimiert, indem eine Kostenfunktion minimiert wird, die auf dem gewählten geometrischen 3D-Merkmal basiert.

Achs-Winkel-Parametrisierung der Rotation. Im Gegensatz zu Euler-Winkeln leidet die Achs-Winkel-Parametrisierung nicht unter dem Problem des *Gimbal-Lock* und im Gegensatz zu Quaternionen parametrisiert sie die Rotation mit der minimalen Parameterzahl. Sie ist daher gut geeignet für unbeschränkte Optimierungsaufgaben [186].

Die Punktwolke \mathcal{P} ist dann die Menge von Punkten im übergeordneten Koordinatensystem:

$$\mathcal{P} = \{g(\mathbf{M}_i, \mathbf{C}, h(\mathbf{z}_i)) \mid i \in \{1, \dots, N\}\}.$$

3.1.2 Berechnung des geometrischen 3D-Merkmals

Aus den 3D-Koordinaten der Punkte innerhalb einer Nachbarschaft \mathcal{N}_i eines betrachteten Punktes \mathbf{x}_i der Punktwolke \mathcal{P} berechnet die Merkmalsbasierte Selbstkalibrierung den 3D-Strukturtenor dieses Punktes und dessen Eigenwerte $\lambda_{1,i}$, $\lambda_{2,i}$ und $\lambda_{3,i}$ für die $\lambda_{1,i} \geq \lambda_{2,i} \geq \lambda_{3,i} \geq 0$ gilt (vgl. Kapitel 2.5.2). Die Nachbarschaft \mathcal{N}_i ist dabei durch die k nächsten Nachbarn mit den geringsten Euklidischen Distanzen zu dem betrachteten Punkt \mathbf{x}_i definiert. Die drei Eigenwerte beschreiben die Ausdehnung der Punktwolke in der Nachbarschaft \mathcal{N}_i in drei orthogonalen Raumrichtungen. Aus den Eigenwerten berechnen sich die geometrischen 3D-Merkmale Linearität $f_{L,i}$, Planarität $f_{P,i}$, Sphärizität $f_{S,i}$, Omnivarianz $f_{O,i}$, Anisotropie $f_{A,i}$, Eigenentropie $f_{E,i}$ und die Krümmungsänderung $f_{C,i}$ [149, 211]. Diese geometrischen 3D-Merkmale repräsentieren die dreidimensionale Ausdehnung der Punkte innerhalb einer Nachbarschaft auf eine interpretierbare Art und Weise. Die geometrischen 3D-Merkmale sind folgendermaßen definiert:

$$\text{Linearität} \quad f_{L,i}(\mathbf{x}_i, \mathcal{N}_i) = \frac{\lambda_{1,i} - \lambda_{2,i}}{\lambda_{1,i}} \quad (3.2)$$

$$\text{Planarität} \quad f_{P,i}(\mathbf{x}_i, \mathcal{N}_i) = \frac{\lambda_{2,i} - \lambda_{3,i}}{\lambda_{1,i}} \quad (3.3)$$

$$\text{Sphärizität} \quad f_{S,i}(\mathbf{x}_i, \mathcal{N}_i) = \frac{\lambda_{3,i}}{\lambda_{1,i}} \quad (3.4)$$

$$\text{Omnivarianz} \quad f_{O,i}(\mathbf{x}_i, \mathcal{N}_i) = \sqrt[3]{\lambda_{1,i} \lambda_{2,i} \lambda_{3,i}} \quad (3.5)$$

$$\text{Anisotropie} \quad f_{A,i}(\mathbf{x}_i, \mathcal{N}_i) = \frac{\lambda_{1,i} - \lambda_{3,i}}{\lambda_{1,i}} \quad (3.6)$$

$$\text{Eigenentropie} \quad f_{E,i}(\mathbf{x}_i, \mathcal{N}_i) = - \sum_{j=1}^3 \lambda_{j,i} \ln(\lambda_{j,i}) \quad (3.7)$$

$$\text{Krümmungsänderung} \quad f_{K,i}(\mathbf{x}_i, \mathcal{N}_i) = \frac{\lambda_{3,i}}{\lambda_{1,i} + \lambda_{2,i} + \lambda_{3,i}} \quad (3.8)$$

Um Näherungswerte für die Parameter der relativen Orientierung zu optimieren, minimiert die Merkmalsbasierte Selbstkalibrierung eine Kostenfunktion, die auf einem dieser geometrischen 3D-Merkmale basiert. Die Wahl des Merkmals entscheidet darüber, welche Metrik zur Bewertung der Qualität der Punktwolke verwendet wird.

Die Wahl der Linearität f_L führt zu der Annahme, dass die Parameter der relativen Orientierung am besten bestimmt sind, wenn lineare Strukturen in der Punktwolke tatsächlich eine große Ausdehnung in einer Raumrichtung haben, während die Ausdehnung in den anderen beiden Raumrichtungen verhältnismäßig klein ist.

In anthropogenen Umgebungen dominieren häufig planare Strukturen. Eine intuitive Bewertung der Qualität einer Punktwolke in einer solchen Umgebung ist daher, dass die Qualität hoch ist, wenn die Planarität f_P über die gesamte Punktwolke hoch ist. Die Maximierung der Planarität f_P in der Punktwolke führt zu einer ähnlichen Annahme wie die Minimierung der Distanz von Punkten zu zugehörigen Ebenen. Eine solche Minimierung ist ein typisches Prinzip von Kalibrierverfahren. In der Literatur wird dieses Prinzip allerdings stets durch die Punkt-zu-Flächen-Metrik bewertet (vgl. Kapitel 1.1).

Durch die Wahl des geometrischen 3D-Merkmals Krümmungsänderung f_K werden nicht nur planare Strukturen ausgenutzt, sondern kontinuierliche Oberflächen deren Krümmung sich wenig ändert. Die Krümmungsänderung f_K entspricht der Ausdehnung der Punkte entlang der Normalenrichtung der Fläche, die durch die beiden großen Eigenwerte $\lambda_{1,i}$ und $\lambda_{2,i}$ aufgespannt wird [163]. Statt einer planaren Fläche kann also eine Oberfläche mit beliebiger Form zu Grunde liegen. Die Qualität der Punktwolke mit Hilfe dieses geometrischen 3D-Merkmals zu bewerten, entspricht also der Annahme, dass sich die Umgebung gut durch kontinuierliche Oberflächen beliebiger Formen approximieren lässt. Im direkten Vergleich zur Planarität f_P ist diese Annahme generischer.

Die übrigen geometrischen 3D-Merkmale lassen sich nicht als Abweichungen von Geraden oder Oberflächen interpretieren, sondern beschreiben die dreidimensionale Ausdehnung der betrachteten Punkte generischer. Die geometrischen 3D-Merkmale Sphärizität f_S und Anisotropie f_A können gemeinsam interpretiert werden, da $f_A = 1 - f_S$ ist. Aus diesem Grund sind ähnliche Resultate für die Merkmalsbasierte Selbstkalibrierung zu erwarten und die Betrachtung der Anisotropie entfällt im Folgenden. Die Sphärizität f_S für die Minimierung zu wählen, entspricht der Annahme, dass die Qualität der Punktwolke dann am höchsten ist, wenn die Formen der Punktwolken in lokalen Umgebungen möglichst weit von Kugeln abweicht. Eine hohe Qualität ist also gegeben, wenn in der Punktwolke viele lineare und planare aber wenige kugelförmige Strukturen enthalten sind. Da das Verhältnis aus dem größten und dem kleinsten Eigenwert verwendet wird, bezieht sich die Sphärizität f_S auf die Form der Umgebungen, nicht aber auf das Volumen.

Im Gegensatz dazu steht das geometrische 3D-Merkmal Omnivarianz f_O . Das Produkt aus den drei Eigenwerten ist proportional zu dem Volumen des Ellipsoids, das die Punkte umschließt. Die Omnivarianz ist somit ein Maß für die lokale Kompaktheit der 3D-Punkte. Die Wahl der Omnivarianz für die Merkmalsbasierte Selbstkalibrierung führt nicht zu einer konkreten Annahme darüber, welche Form eine Punktwolke im besten Fall haben sollte. Dies unterscheidet die Omnivarianz von den bisher genannten geometrischen 3D-Merkmalen. Die Merkmalsbasierte Selbstkalibrierung mit dem geometrischen 3D-Merkmal Omnivarianz unterscheidet sich dadurch auch von allen verwandten Kalibrierverfahren mit Ausnahme der Entropiebasierten Selbstkalibrierung (vgl. Kapitel 1.1).

Das geometrische 3D-Merkmal Eigenentropie f_E verhält sich ähnlich wie das geometrische 3D-Merkmal Omnivarianz f_O , was durch Umformen von Gleichung 3.7 gezeigt werden kann. Durch Potenzieren dieser Gleichung ergibt sich

$$\exp(f_{E,i}) = \lambda_{1,i}^{\lambda_{1,i}} \lambda_{2,i}^{\lambda_{2,i}} \lambda_{3,i}^{\lambda_{3,i}}.$$

Bezogen auf die Kostenfunktion verändert die monotone Exponentialfunktion das Ergebnis nicht. Damit ergibt sich die Eigenentropie genau wie die Omnivarianz primär aus dem Produkt der drei Eigenwerte (vgl. Gleichung 3.5). Allerdings wird bei der Eigenentropie jeder Eigenwert zusätzlich mit sich selbst potenziert. Dadurch ergibt sich eine andere Gewichtung der Eigenwerte im Vergleich zur Omnivarianz. Aus diesem Grund sind für das Merkmal Eigenentropie ähnliche Ergebnisse zu erwarten wie für das Merkmal Omnivarianz. Die Experimente in Kapitel 5.1.2 zeigen, welche Gewichtung der Eigenwerte bessere Resultate erzielt.

Prinzipiell kommen alle geometrischen 3D-Merkmale für die Selbstkalibrierung in Betracht. Aus den obigen Erläuterungen geht allerdings hervor, dass die Wahl des geometrischen 3D-Merkmals einen Einfluss auf das Ergebnis der Selbstkalibrierung haben wird. Daher finden sich in Kapitel 5.1.2 Untersuchungen dazu wieder, auf Basis derer die Eignung der geometrischen 3D-Merkmale für die Merkmalsbasierte Selbstkalibrierung weitergehend diskutiert wird.

3.1.3 Berechnung der Kostenfunktion und Parameteroptimierung

Das Ziel der Merkmalsbasierten Selbstkalibrierung ist es, die Parameter der relativen Orientierung zu schätzen, indem eine Kostenfunktion K , die auf einem gewählten geometrischen 3D-Merkmal basiert, minimiert wird. Aus Gleichungen 3.2 – 3.8 bzw. den zugehörigen Ausführungen wird ersichtlich, dass die geometrischen 3D-Merkmale Sphärizität, Omnivarianz, Eigenentropie und Krümmungsänderung kleine Werte annehmen müssen, damit die Qualität der Punktwolke hoch wird. Die geometrischen 3D-Merkmale Linearität, Planarität und Aniso-

tropie müssen allerdings maximiert werden, damit die Qualität der Punktwolke hoch wird. Für eine einheitliche Darstellung der Methodik sei daher zunächst eine Signumfunktion s mit

$$s(\mathcal{F}) = \begin{cases} 1 & \text{für } \mathcal{F} \in \{S, O, E, K\} \\ -1 & \text{für } \mathcal{F} \in \{L, P\} \end{cases}$$

definiert. Damit ergibt sich für alle geometrischen 3D-Merkmale eine gemeinsame Darstellung für die Kostenfunktion K als Summe der quadrierten geometrischen 3D-Merkmale über alle N Punkte der Punktwolke \mathcal{P} :

$$K(\mathbf{C} | \mathbf{M}, h(\mathbf{z})) = s(\mathcal{F}) \sum_{i=1}^N (f_{\mathcal{F},i}(g(\mathbf{M}_i, \mathbf{C}, h(\mathbf{z}_i)), \mathcal{N}_i))^2. \quad (3.9)$$

3.2 Die robuste Merkmalsbasierte Selbstkalibrierung

Abbildung 3.2 visualisiert den Ablauf der robusten Merkmalsbasierten Selbstkalibrierung. Die ergänzten Schritte im Vergleich zur vereinfachten Methodik sind in blau dargestellt (vgl. Abbildung 3.1). Die Eingangsgrößen der robusten Merkmalsbasierten Selbstkalibrierung sind um einen Parameter erweitert, der die Größe eines Voxelgrid-Filters darstellt. Nach der Berechnung der Punktwolke wird diese mit einem schwerpunktbasierten Voxelgrid-Filter gefiltert. Nachdem anschließend die geometrischen 3D-Merkmale auf der gefilterten Punktwolke berechnet wurden, werden Punkte, die potentiell Ausreißer darstellen, entfernt. Die übrigen Punkte werden zudem mit einem robusten M-Schätzer gewichtet. Diese ergänzten Schritte werden im Folgenden näher erläutert und in der formalen Beschreibung der Merkmalsbasierten Selbstkalibrierung eingebunden.

3.2.1 Schwerpunktbasierte Voxelgrid-Filterung

In der Regel weist die Punktwolke \mathcal{P} eine heterogene Punktdichte auf. Regionen, die während der Erfassung eine geringe Distanz zum Tiefensensor haben, werden mit einer hohen Punktdichte erfasst, wohingegen weiter entfernte Regionen mit einer geringeren Punktdichte aufgezeichnet werden. Darüber hinaus sorgt eine ungleichmäßige Bewegung des mobilen Multisensorsystems für eine heterogene Punktdichte. Dadurch entstehen bei der Erfassung variierende Diskretisierungen der Umgebung. Die Diskretisierung wirkt sich allerdings auf die Robustheit der geometrischen 3D-Merkmale aus [38].

Eine gängige Vorgehensweise, um dieser Herausforderung zu begegnen, ist die Verwendung eines Voxelgrid-Filters, der für eine homogene Punktdichte sorgt [69]. Der Voxelgrid-Filter, den die Merkmalsbasierte Selbstkalibrierung verwendet, ersetzt alle Punkte innerhalb eines Voxels durch den Schwerpunkt dieser Punkte. Dadurch wird die Geometrie der Punktwolke

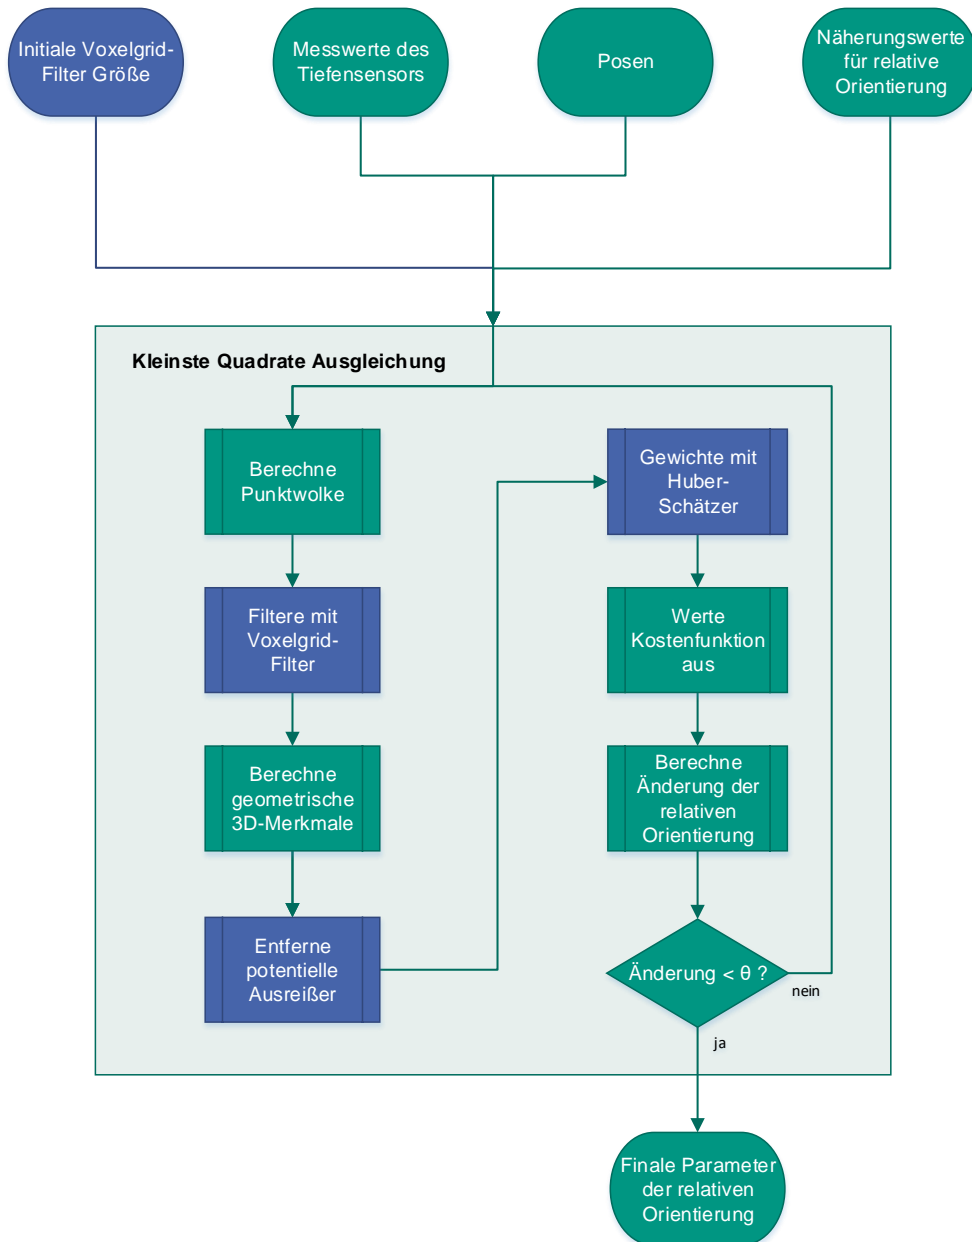


Abbildung 3.2: Erweiterter Ablauf der Merkmalsbasierten Selbstkalibrierung. Die ergänzten Schritte sind in blau dargestellt und dienen der Robustheit des Verfahrens.

mit hoher Genauigkeit approximiert. Außerdem wirken sich kleine Änderungen der relativen Orientierung auch auf die Schwerpunkte in der gefilterten Punktwolke aus, was essentiell für die Kleinste-Quadrate-Ausgleichung ist.

Sei $d(\mathcal{P})$ eine Funktion, die eine schwerpunktbasierte Voxelgrid-Filterung durchführt. Dann ist $\mathcal{P}' = d(\mathcal{P})$ die gefilterte Punktwolke. Dadurch ändert sich die Kostenfunktion aus Gleichung 3.9 zu

$$\mathcal{K} = s(\mathcal{F}) \sum_{i=1}^{N'} (f_{\mathcal{F},i}(\mathbf{x}_i, \mathcal{N}_i))^2 \text{ mit } \mathbf{x}_i \in \mathcal{P}' \text{ und} \quad (3.10)$$

$$\mathcal{P}' = d(\{g(\mathbf{M}_i, \mathbf{C}, h(\mathbf{z}_i)) \mid i \in \{1, \dots, N\}\}). \quad (3.11)$$

Da die Filterung die ursprünglichen Koordinaten der Punkte in der originalen Punktwolke \mathcal{P} verändert, hängt die Kostenfunktion nun nur noch implizit von den gesuchten Parametern der relativen Orientierung ab, die in der Matrix \mathbf{C} parametrisiert sind. Aus diesem Grund ist die Formulierung der Kostenfunktion zweigeteilt. Die Parameter der relativen Orientierung wirken sich allerdings noch immer explizit auf die Berechnung der gefilterten Punktwolke \mathcal{P}' aus und wirken dadurch auf die Kostenfunktion.

Gängige Alternativen zur schwerpunktbasierten Voxelgrid-Filterung sind die Mittelpunktbasierte Voxelgrid-Filterung und die zufällige Voxelgrid-Filterung. Analog zur Vorgehensweise der schwerpunktbasierten Voxelgrid-Filterung werden bei der mittelpunktbasierten Voxelgrid-Filterung alle Punkte innerhalb eines Voxels durch den Mittelpunkt dieses Voxels und bei der zufälligen Voxelgrid-Filterung alle Punkte durch einen zufällig gewählten Punkt innerhalb des Voxels ersetzt. Diese Alternativen sind weniger rechenintensiv als die schwerpunktbasierte Voxelgrid-Filterung. Allerdings stellen die mit diesen Alternativen gefilterten Punktwolken ungenauere Approximationen der Geometrie dar.

Die schwerpunktbasierte Voxelgrid-Filterung hat drei zusätzliche Vorteile für die Merkmalsbasierte Selbstkalibrierung:

1. Durch die Filterung werden kleine Objekte in der Punktwolke mit umliegenden Punkten geglättet. Dadurch wird der Einfluss dieser kleinen Objekte herunter gewichtet, was einen größeren Konvergenzradius der Kleinste-Quadrate-Ausgleichung erwarten lässt (vgl. Kapitel 5.1.4).
2. Durch die Filterung wird die Genauigkeit der Punkte im Vergleich zu den rohen Messpunkten erhöht, da die Schwerpunktbildung für eine Glättung sorgt und dadurch zufällige Fehler reduziert.
3. Durch die Filterung wird die Rechenzeit der Merkmalsbasierten Selbstkalibrierung reduziert, da das geometrische 3D-Merkmal für weniger Punkte berechnet wird als bei der ungefilterten Punktwolke.

3.2.2 Entfernen potentieller Ausreißer

Wie in Kapitel 3.1.2 erläutert, kann die Wahl des geometrischen 3D-Merkmals dazu führen, dass implizit Modellannahmen getroffen werden. Beispielsweise wird bei der Wahl der Planarität die Modellannahme getroffen, dass die Punktwolke die Realität dann am besten approximiert, wenn alle Punkte lokal planar sind. Punkte, die in der Realität zu Vegetation gehören, würden diese Modellannahme verletzen, da die zugrundeliegende Geometrie nicht planar ist. Solche Punkte können daher für die Merkmalsbasierte Selbstkalibrierung mit der Planarität als Ausreißer betrachtet werden.

Daher enthält die robuste Merkmalsbasierte Selbstkalibrierung einen Schritt, der potentielle Ausreißer entfernt. Dieser Schritt sortiert die Punkte in jeder Iteration nach dem Wert des geometrischen 3D-Merkmals und behält nur die ζ Prozent der Werte, die die Modellannahmen potentiell weniger verletzen. Im Falle der Planarität werden beispielsweise diejenigen Punkte aussortiert, bei denen die Planarität sehr niedrig ist, da diese potentiell zur Vegetation gehören.

Das Entfernen potentieller Ausreißer wird darüber hinaus aus einem algorithmischen Grund durchgeführt: Die Voxelgrid-Filterung kann dafür sorgen, dass sich die Anzahl der Punkte und damit der Beobachtungen für die Kleinste-Quadrate-Ausgleichung zwischen zwei Iterationen ändert. Für gewöhnlich ist die Punktwolke zum Beispiel zu Beginn weniger kompakt. Aufgrund der gleichmäßigen Abtastung durch den Voxelgrid-Filter, resultiert für eine solche gefilterte Punktwolke eine größere Anzahl an Punkten, als für eine kompaktere gefilterte Punktwolke. Herkömmliche Algorithmen für die Kleinste-Quadrate-Ausgleichung setzen jedoch eine konstante Anzahl an Beobachtungen zwischen den einzelnen Iterationen voraus. Um einen solchen herkömmlichen Algorithmus verwenden zu können, nutzt die Merkmalsbasierte Selbstkalibrierung nur eine Untermenge der Punkte, die aus ζ Prozent der Punkte besteht. Sofern ζ klein genug ist, wird der Kleinste-Quadrate-Ausgleichung dadurch stets eine gleichbleibende Anzahl an Punkten zugeführt.

Nach Entfernen potentieller Ausreißer ergibt sich die Kostenfunktion der Merkmalsbasierten Selbstkalibrierung zu

$$\mathcal{K} = s(\mathcal{F}) \sum_{i=1}^L (f_{\mathcal{F},i}(\mathbf{x}_i, N_i))^2 \text{ mit } \mathbf{x}_i \in \mathcal{P}' \quad \text{mit} \quad (3.12)$$

$$\mathcal{P}' = d(\{g(\mathbf{M}_i, \mathbf{C}, h(\mathbf{z}_i)) \mid i \in \{1, \dots, N\}\}) \quad (3.13)$$

wobei $L = \lceil \zeta N' \rceil$ mit $\zeta \in]0, 1]$ die abgerundete Anzahl der Punkte nach Entfernen potentieller Ausreißer ist.

3.2.3 Gewichtung mit M-Schätzer

Je nach Wahl des Parameters ζ und der Umgebung, in der die Daten erfasst werden, kann es vorkommen, dass nach dem Entfernen immer noch Ausreißer in den Daten vorhanden sind. Um die Parameter der relativen Orientierung dennoch robust zu schätzen, verwendet die Merkmalsbasierte Selbstkalibrierung zusätzlich einen M-Schätzer [89]. Dadurch wird die Kleinste-Quadrate-Ausgleichung zu einer *iterativ neu gewichteten Kleinste-Quadrate-Ausgleichung* [83] (vgl. Kapitel 2.1). Die Merkmalsbasierte Selbstkalibrierung greift auf den Huber-Schätzer

$$\rho_\kappa(r) = \begin{cases} \frac{1}{2}r^2 & \text{für } r < \kappa \\ \kappa(|r| - \frac{1}{2}\kappa) & \text{andernfalls} \end{cases} \quad (3.14)$$

zurück, wobei κ der sogenannte Tuning-Parameter ist [89]. Der Huber-Schätzer gewichtet niedrige Werte für das geometrische 3D-Merkmal quadratisch und hohe Werte, die potenzielle Ausreißer darstellen, linear.

Dadurch ergibt sich die finale Kostenfunktion für die iterativ neu gewichtete Kleinste-Quadrate-Ausgleichung zu

$$\mathcal{K} = s(\mathcal{F}) \sum_{i=1}^L \rho_\kappa(f_{\mathcal{F},i}(\mathbf{x}_i, \mathcal{N}_i)) \text{ mit } \mathbf{x}_i \in \mathcal{P}' \quad \text{mit} \quad (3.15)$$

$$\mathcal{P}' = d(\{g(\mathbf{M}_i, \mathbf{C}, h(\mathbf{z}_i)) \mid i \in \{1, \dots, N\}\}). \quad (3.16)$$

3.3 Die rekursive Merkmalsbasierte Selbstkalibrierung - Multiskalenverfahren

Die Punktdichte in lokalen Umgebungen der Punktwolke hat einen großen Einfluss auf die Genauigkeit und den Konvergenzradius der Merkmalsbasierten Selbstkalibrierung (siehe Kapitel 5.1.4)). Ist die Punktdichte hoch und sind die Näherungswerte der Parameter der relativen Orientierung ungenau, so konvergiert die Ausgleichung häufig zu einem lokalen Minimum. Ist die Punktdichte geringer, so ist der Konvergenzradius der Merkmalsbasierten Selbstkalibrierung größer, aber das Ergebnis ist ungenauer. Aus diesem Grund verwendet die Merkmalsbasierte Selbstkalibrierung ein Multiskalenverfahren, dessen Ziel ein großer Konvergenzradius sowie ein genaues Ergebnis ist.

Abbildung 3.3 zeigt den vollständigen Ablauf der Merkmalsbasierten Selbstkalibrierung inklusive des Multiskalenansatzes. Die ergänzten Schritte des Multiskalenverfahrens sind in rot dargestellt.

Die Skala einer Punktwolke ist im Multiskalenverfahren über die Kantenlänge der Voxel des Voxelgrid-Filters definiert. Sobald die Kleinste-Quadrate-Ausgleichung zu einer Lösung kon-

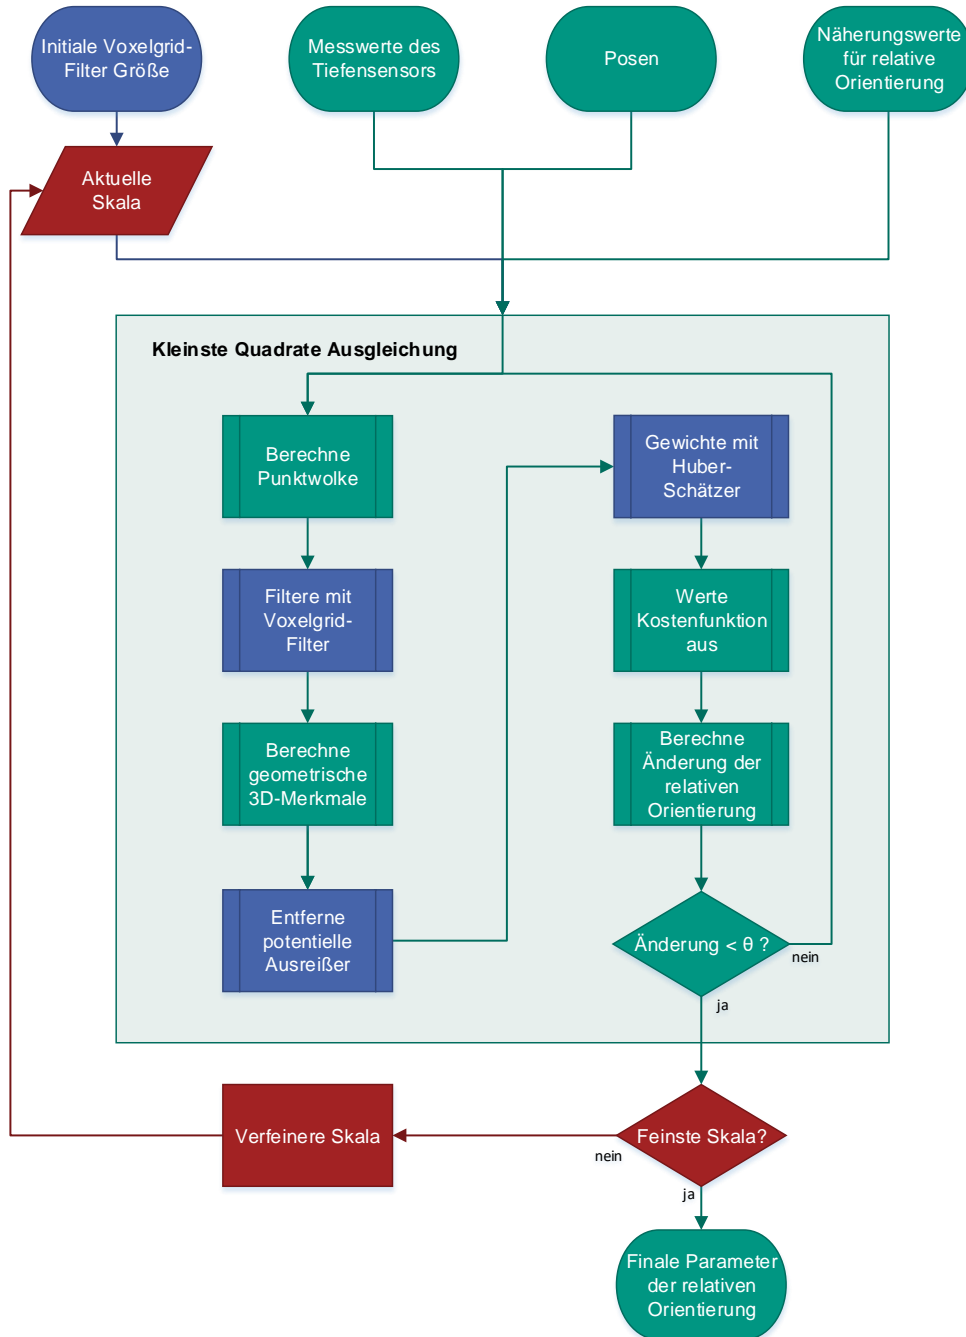


Abbildung 3.3: Vollständiger Ablauf der Merkmalsbasierten Selbstkalibrierung. Die Schritte des Multiskalenverfahrens sind in rot dargestellt. Die Kleinste-Quadrate-Ausgleichung wird rekursiv in mehreren Skalen durchgeführt. Nachdem eine feste Anzahl an Skalen durchlaufen wurde, bricht die Merkmalsbasierte Selbstkalibrierung die Rekursion ab und die finalen Parameter der relativen Orientierung liegen vor.

vergiert, verfeinert die Merkmalsbasierte Selbstkalibrierung das Voxelgrid und führt eine weitere Kleinste-Quadrate-Ausgleichung auf der feineren Punktwolke durch. Durch die sukzessive Verfeinerung der Punktwolke, liegen der Kleinste-Quadrate-Ausgleichung Beobachtungen von immer kleineren Umgebungen vor, da die Anzahl der betrachteten Punkte gleich bleibt. Das bedeutet, dass die Merkmalsbasierte Selbstkalibrierung auf einer groben Skala primär große Strukturen wie etwa den Boden oder Wände berücksichtigt und auf feineren Skalen immer kleinere Strukturen. Nachdem eine feste Anzahl an Skalen durchlaufen wurde, bricht die Merkmalsbasierte Selbstkalibrierung die Rekursion ab und die finalen Parameter der relativen Orientierung liegen vor.

Die Experimente in Kapitel 5.1.4 dienen dazu, die in diesem Kapitel getroffenen Aussagen zu belegen und das Multiskalenverfahren gegenüber der Verwendung einer einzelnen Skala zu evaluieren.

Tabelle 3.1: Formale Bezeichnungen der Methodik alphabetisch sortiert.

\mathbf{C}	die homogene Transformationsmatrix, die die relative Orientierung parametrisiert
d	Funktion, die einen schwerpunktbasieren Voxelgrid-Filter auf eine Punktwolke anwendet
$f_{F,i}(\mathbf{x}_i, \mathcal{N}_i)$	geometrisches 3D-Merkmal
\mathcal{F}	Menge der wählbaren geometrischen 3D-Merkmale
g	Funktion, die $h(\mathbf{z}_i)$ vom Koordinatensystem des Laserscanners in ein übergeordnetes Koordinatensystem transformiert
$g(\mathbf{M}_i, \mathbf{C}, h(\mathbf{z}_i))$	homogene kartesische Koordinaten des i -ten Punktes im übergeordneten Koordinatensystem
h	Funktion, die Polarkoordinaten in kartesische homogene Koordinaten transformiert
$h(\mathbf{z}_i)$	kartesische homogene Koordinaten des i -ten Punktes im Koordinatensystem des Laserscanners
k	Anzahl nächster Nachbarn
κ	Tuning-Parameter der Huber-Funktion
K	Kostenfunktion, die im Rahmen der Kleinste-Quadrate-Ausgleichung minimiert wird
$\lambda_{1,i}, \lambda_{2,i}, \lambda_{3,i}$	Eigenwerte des 3D-Strukturtenors eines Punktes \mathbf{x}_i mit $\lambda_{1,i} \geq \lambda_{2,i} \geq \lambda_{3,i} \geq 0$
L	abgerundete Anzahl der Punkte nach Entfernen von Ausreißern
\mathbf{M}_i	die i -te Pose des Posenbestimmungssensors mit $i = 1, \dots, N$

N	Anzahl der Posen und korrespondierenden Messwerte des Laserscanners bzw. Anzahl der Punkte in der Punktwolke
N'	Anzahl der Punkte in der gefilterten Punktwolke
\mathcal{N}_i	Nachbarschaft des Punktes \mathbf{x}_i
\mathcal{P}	Punktwolke bestehend aus der Menge an transformierten, rohen Messpunkten
\mathcal{P}'	gefilterte Punktwolke
$\rho_\kappa(r_i)$	Wert des Huber-Schätzers für das i -te Residuum r_i mit der Tuning-Konstante κ
$s(\mathcal{F})$	Signumfunktion nach Gleichung 3.1.3
\mathbf{x}_i	Punkt der Punktwolke \mathcal{P}'
\mathbf{z}_i	i -te Richtungs- und Distanzmessung des Laserscanners, bzw. Polarkoordinaten des i -ten Punktes im Koordinatensystem des Laserscanners
ζ	Schwellwert in Prozent für die Definition von Ausreißern
ζ_0	ζ für die größte Skala

4 Datengrundlage und Vergleichskalibrierungen

Die vier Datensätze, die in dieser Arbeit verwendet werden, weisen alle unterschiedliche Charakteristiken auf, wovon Tabelle 4.1 die wichtigsten im Hinblick auf eine Selbstkalibrierung aufführt. Die beiden Indoor-Datensätze enthalten ausschließlich anthropogene Objekte, während die beiden Outdoor-Datensätze auch Vegetation enthalten. Die Posengenauigkeiten, die in Tabelle 4.1 angegeben ist, stellen die Herstellerangaben dar, bzw. im Falle des großen Outdoor-Datensatzes die Genauigkeiten von ORB-SLAM2 auf der betrachteten Sequenz des KITTI-Datensatzes [136]. Die tatsächlichen Genauigkeiten können bei allen realen Datensätzen leicht abweichen. Durch die Evaluierung mit diesen vier Datensätzen kann die Eignung der Merkmalsbasierten Selbstkalibrierung hinsichtlich verschiedener Sensorik und deren Genauigkeiten sowie der Größe und Beschaffenheit der Umgebung getestet werden.

Dieses Kapitel erläutert neben den Datensätzen, die in den Experimenten verwendet werden, auch die Vergleichskalibrierungen, die zur Evaluierung der Merkmalsbasierten Selbstkalibrierung herangezogen werden. Wie die Beschreibung des Stands der Forschung in Kapitel 1.1 darlegt, sind die existierenden Verfahren zur Bestimmung der relativen Orientierung häufig

Tabelle 4.1: Gegenüberstellung der verwendeten Datensätze. *: Für die Untersuchungen zur Kostenfunktion in Kapitel 5.1.2.

Datensatz	Synthetischer Indoor-Datensatz	Kleiner Indoor-Datensatz	Mittlerer Outdoor-Datensatz	Großer Outdoor-Datensatz
In-/Outdoor	Indoor	Indoor	Outdoor	Outdoor
Ausmaße der Punktwolke	10 m × 10 m × 5 m	ca. 8 m × 5 m × 2,5 m	ca. 250 m × 250 m × 25 m	ca. 450 m × 300 m × 5 m
Umgebung	Leerer Raum	Labor	Häuserblock mit Innenhof	Wohngebiet
Trägerplattform	simuliert	handgehalten	fahrzeugbasiert	fahrzeugbasiert
Posenbestimmungssensor	simuliert	MCS	GNSS/IMU	Stereokamera
Tiefensensor	2D-Laserscanner	2D-Laserscanner	3D-Laserscanner	3D-Laserscanner
Posengenauigkeit	fehlerfrei* bzw. 2 cm; 0,1°	0,03 cm; 0,05°	5 cm; 0,02°	70 cm/100m, 0,25°/100m
Distanzmessgenauigkeit	fehlerfrei* bzw. 3 cm	3 cm	5 cm	5 cm

auf spezielle Sensoren ausgelegt und verwenden ein Kalibrierobjekt. Die Experimente werden im Hinblick auf eine hohe Transparenz und Reproduzierbarkeit der Ergebnisse mit öffentlichen Datensätzen durchgeführt. Aus diesem Grund ist es nicht möglich, für die Evaluierung zusätzliche Daten mit den Sensorsystemen zu erfassen. Dadurch ist die Zahl der verwendbaren Vergleichskalibrierungen eingeschränkt. In den Experimenten werden für jeden Datensatz jeweils zwei weitere Vergleichskalibrierungen aus der Literatur zur Evaluierung der Merkmalsbasierten Selbstkalibrierung herangezogen. Eine dieser Vergleichskalibrierungen ist nur für den jeweiligen Datensatz geeignet, auf dem es verwendet wird. Die andere Vergleichskalibrierung ist für alle Datensätze die Entropiebasierte Selbstkalibrierung [124, 170]. Die Entropiebasierte Selbstkalibrierung kann ohne die Erfassung weiterer Daten angewendet werden und ist für alle Sensoren, die in den Datensätzen verwendet werden, geeignet. Aus diesem Grund wurde die Entropiebasierte Selbstkalibrierung nachimplementiert und zur Evaluierung verwendet.

Kapitel 4.1 erläutert zunächst die Entropiebasierte Selbstkalibrierung und liefert eine formale Beschreibung dieses Verfahrens. Darauf folgend beschreibt Kapitel 4.2 den synthetischen Datensatz. Anschließend erfolgt die Beschreibung der realen Datensätze und der jeweils geeigneten Vergleichskalibrierungen, beginnend mit dem kleinen Indoor-Datensatz (Kapitel 4.3) über den mittleren Outdoor-Datensatz (Kapitel 4.4) bis hin zum großen Outdoor-Datensatz (Kapitel 4.5).

4.1 Methodik der Entropiebasierten Selbstkalibrierung

Die *Entropiebasierte Selbstkalibrierung* [124, 170] optimiert Näherungswerte für die relative Orientierung mit einer Kleinsten Quadrate Ausgleichung (siehe Kapitel 2.1), indem eine Kostenfunktion minimiert wird, die auf der Entropie der erfassten Punktwolke basiert. Diese Kostenfunktion beschreibt die Punktwolke durch eine mehrdimensionale Gauß'sche Mischverteilung. Je spitzer die Peaks dieser mehrdimensionalen Gauß'schen Mischverteilung sind, desto schärfer ist die Punktwolke. Durch die Minimierung dieser Kostenfunktion optimiert die Entropiebasierte Selbstkalibrierung demnach die Parameter der relativen Orientierung, sodass die Punktwolke schärfer wird [170].

Ausgangspunkt für die Entropiebasierte Selbstkalibrierung sind Posen des Posenbestimmungssensors, korrespondierende Richtungs- und Distanzmessungen des Laserscanners und Näherungswerte für die relative Orientierung. Sei

- N die Anzahl der Posen und korrespondierenden Messwerte des Laserscanners,
- \mathbf{M}_i die i -te Pose des Posenbestimmungssensors mit $i = 1, \dots, N$,

\mathbf{z}_i	die i -te Richtungs- und Distanzmessung des Laserscanners, bzw. die Polarkoordinaten des i -ten Punktes im Koordinatensystem des Laserscanners,
\mathbf{C}	die homogene Transformationsmatrix, die die relative Orientierung parametrisiert,
h	eine Funktion, die Polarkoordinaten in kartesische homogene Koordinaten transformiert,
$h(\mathbf{z}_i)$	die kartesischen homogenen Koordinaten des i -ten Punktes im Koordinatensystem des Laserscanners und
$G(\boldsymbol{\mu}, \boldsymbol{\Sigma})$	eine mehrdimensionale Normalverteilung mit Mittelwert $\boldsymbol{\mu}$ und Kovarianzmatrix $\boldsymbol{\Sigma}$.

Seien weiterhin g eine Funktion, die $h(\mathbf{z}_i)$ vom Koordinatensystem des Laserscanners in ein übergeordnetes Koordinatensystem transformiert und damit

$$g(\mathbf{M}_i, \mathbf{C}, h(\mathbf{z}_i)) = \mathbf{M}_i \mathbf{C} h(\mathbf{z}_i) \quad (4.1)$$

die homogenen kartesischen Koordinaten des i -ten Punktes im übergeordneten Koordinatensystem. Dann kann die Kostenfunktion der Entropiebasierten Selbstkalibrierung durch

$$f_{RQE}(\mathbf{C} | \mathbf{M}, \mathbf{z}) = - \sum_{i=1}^N \sum_{j=1}^N G(g(\mathbf{M}_i, \mathbf{C}, h(\mathbf{z}_i)) - g(\mathbf{M}_j, \mathbf{C}, h(\mathbf{z}_j)), \boldsymbol{\Sigma}) \quad (4.2)$$

ausgedrückt werden. Die mehrdimensionale Normalverteilung G kann als Gewichtung interpretiert werden. Je kleiner die Punktdistanz ist, desto höher ist das Gewicht. Diese Gewichtung stellt demzufolge eine kontinuierliche Form der Nachbarschaft dar. Die Kostenfunktion in Gleichung 4.2 besteht somit aus der Summe von gewichteten paarweisen Punktdifferenzen. Die Entropiebasierte Selbstkalibrierung optimiert die Parameter der relativen Orientierung, indem sie diese Kostenfunktion in einer Kleinsten Quadrate Ausgleichung minimiert. Für eine Herleitung der Kostenfunktion aus der *Rényi quadratic entropy* (RQE), die einen Spezialfall der *Rényi Entropie* [159] darstellt, sei der Leser auf [170] verwiesen.

Für die Kovarianzmatrix $\boldsymbol{\Sigma}$ setzen die Autoren die Kovarianzen zu Null und verwenden die gleiche Varianz σ^2 für jede Dimension, sodass $\boldsymbol{\Sigma} = \sigma^2 \mathbf{I}$ [170]. Damit berechnet sich die mehrdimensionale Normalverteilung G durch

$$G(\mathbf{x}_i - \mathbf{x}_j, \sigma^2) = \frac{1}{(2\pi\sigma^2)^{D/2}} \exp \left\{ -\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2\sigma^2} \right\}, \quad (4.3)$$

wobei D die Dimension der Koordinaten ist, in diesem Fall $D = 3$. Dadurch hat die Entropiebasierte Selbstkalibrierung einen einzelnen freien Parameter σ , der an das Sensorsystem

bzw. den Datensatz angepasst werden muss. Die Autoren empfehlen basierend auf empirischen Untersuchungen σ so zu wählen, dass es der zu erwartenden Genauigkeit eines 3D-Punktes bei einem kalibrierten System entspricht. Dementsprechend kann σ auch als a-priori Wissen über die Genauigkeit eines 3D-Punktes interpretiert werden. Die Entropiebasierte Selbstkalibrierung verwendet einen konstanten Wert für σ für die Kostenfunktion und somit für die gesamte Punktwolke.

Durch Einsetzen von Gleichung 4.3 in Gleichung 4.2 und mit $D = 3$ ergibt sich die finale Kostenfunktion der Entropiebasierten Selbstkalibrierung:

$$f_{RQE}(\mathbf{C} | \mathbf{M}, \mathbf{z}) = - \sum_{i=1}^N \sum_{j=1}^N \frac{1}{(2\pi\sigma^2)^{3/2}} \exp \left\{ - \frac{\|g(\mathbf{M}_i, \mathbf{C}, h(\mathbf{z}_i)) - g(\mathbf{M}_j, \mathbf{C}, h(\mathbf{z}_j))\|^2}{2\sigma^2} \right\}. \quad (4.4)$$

Für eine bessere Vergleichbarkeit verwendet die implementierte Entropiebasierte Selbstkalibrierung genau wie die Merkmalsbasierte Selbstkalibrierung diskrete Nachbarschaften anstatt alle paarweisen Punktdistanzen zu berücksichtigen (vgl. Gleichung 4.4 und Gleichung 3.15). In Analogie zu diskreten Nachbarschaften sorgt bei Verwendung aller paarweisen Punktdistanzen die Gewichtung der Kosten durch die Mehrdimensionale Normalverteilung G dafür, dass der Einfluss mit zunehmender Punktdistanz reduziert wird. Große Punktdistanzen haben einen vernachlässigbaren Einfluss auf die gesamten Kosten. Deshalb ist durch die Verwendung diskreter Nachbarschaften keine signifikante Änderung des Ergebnisses zu erwarten [170]. Die Verwendung diskreter Nachbarschaften sorgt bei der Entropiebasierten Selbstkalibrierung für eine Reduzierung der Rechenkomplexität von $O(N^2)$ zu $O(kN \log(N))$, wobei N die Anzahl der Punkte in der Punktwolke ist und k die Größe der Nachbarschaft [170]. Der Parameter σ der Entropiebasierten Selbstkalibrierung wird für alle Untersuchungen von optimistischen Annahmen über die Punktgenauigkeit bis hin zu pessimistischen Annahmen variiert. In den Experimenten werden nur die jeweils besten Ergebnisse gezeigt.

4.2 Synthetischer Indoor-Datensatz

Die synthetischen Daten stammen aus einer Simulation mit ROS⁵ (Robot Operating System) und Gazebo⁶. Diese Software erlaubt es beliebige Umgebungen, Sensoren bzw. Sensorkonfigurationen und Systemposen zu simulieren.

Die Umgebung, die beim synthetischen Datensatz erfasst wird, ist ein geschlossener Raum mit einer Ausdehnung von $10 \text{ m} \times 10 \text{ m} \times 5 \text{ m}$, der in Abbildung 4.1a dargestellt ist. Der simulierte Laserscanner ist ein 2D-Laserscanner nach Vorbild des *Hokuyo UTM-30LX-EW*. Der *Hokuyo*

⁵ <http://www.ros.org/>

⁶ <http://gazebosim.org/>

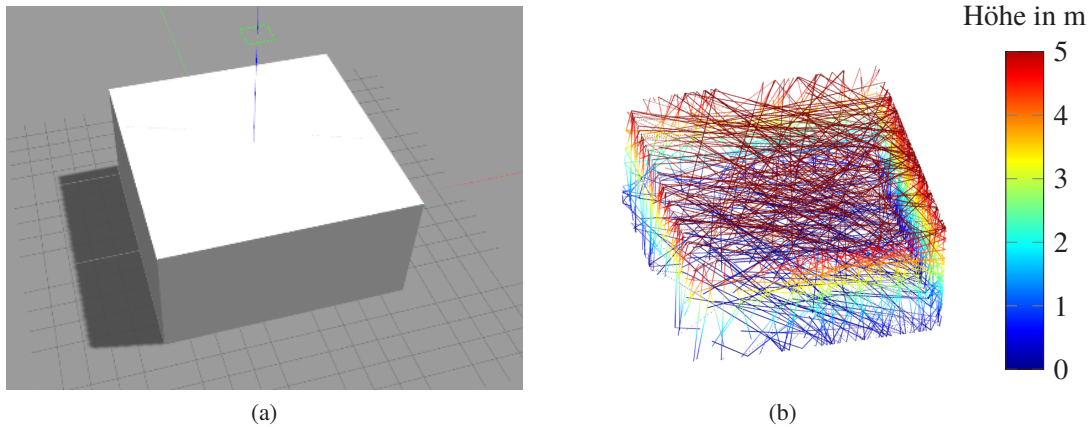


Abbildung 4.1: Synthetischer Indoor-Datensatz. (a) Umgebung, (b) Punktwolke der simulierten Daten.

UTM-30LX-EW ist einer der am häufigsten verwendeten Laserscanner auf mobilen Plattformen, da er leichtgewichtig und verhältnismäßig preisgünstig ist. Der Laserscanner besitzt einen Öffnungswinkel von 270° , erfasst 1080 Punkte pro Scan-Zeile und hat eine Distanzmessgenauigkeit von 3 cm.

Der Laserscanner ist starr mit einer simulierten Trägerplattform verbunden. Für die räumliche Erfassung der Umgebung werden zufällige Posen der Trägerplattform innerhalb des geschlossenen Raumes simuliert. Dadurch entsteht eine große Positions- und Blickwinkelvariation.

Der synthetische Datensatz besteht aus zehn räumlichen Erfassungen mit dieser Sensorkonfiguration. Jede dieser räumlichen Erfassungen besteht aus 100 Posen und 100 zugehörigen Zeilen des Laserscanners. Das Ergebnis einer dieser räumlichen Erfassungen ist in Abbildung 4.1b dargestellt. Die Abbildung visualisiert die Punktwolke nach Berechnung mit der wahren relativen Orientierung.

Die Näherungswerte für die Parameter der relativen Orientierung sind gegenüber den wahren, simulierten Parametern um 5° für jeden Winkel und um 5 cm für jede Richtung verfälscht. Da die wahren Parameter der relativen Orientierung für die simulierten Daten bekannt sind, erfolgt die Evaluierung durch die Betrachtung der Abweichungen der geschätzten Parameter von den wahren Parametern. Zur besseren Interpretierbarkeit wird die L2-Norm $\|\cdot\|_2$ der relativen Translation und der relativen Rotation betrachtet. Der Fehler der relativen Orientierung beschreibt sich somit durch den

$$\text{Fehler der relativen Translation: } \Delta d = \|\hat{\mathbf{t}} - \tilde{\mathbf{t}}\|_2 \quad (4.5)$$

und den

$$\text{Fehler der relativen Rotation: } \Delta r = \|\hat{\mathbf{r}} - \tilde{\mathbf{r}}\|_2. \quad (4.6)$$

Hierbei ist $\hat{\mathbf{t}} = (\hat{t}_x \ \hat{t}_y \ \hat{t}_z)^T$ die geschätzte und $\tilde{\mathbf{t}} = (\tilde{t}_x \ \tilde{t}_y \ \tilde{t}_z)^T$ die wahre relative Translation und $\hat{\mathbf{r}} = (\hat{\phi} \ \hat{\theta} \ \hat{\psi})^T$ die geschätzte und $\tilde{\mathbf{r}} = (\tilde{\phi} \ \tilde{\theta} \ \tilde{\psi})^T$ die wahre relative Rotation in der Achs-Winkel-Parametrisierung.

4.3 Kleiner Indoor-Datensatz

Der kleine Indoor-Datensatz ist ein selbst erfasster Datensatz, der aus den Daten eines 2D-Laserscanners und eines MCS besteht. Bei dem 2D-Laserscanner handelt es sich um einen *Hokuyo UTM-30LX-EW*. Dieser Laserscanner weist die gleichen Spezifikationen auf wie der Laserscanner, der für den synthetischen Datensatz simuliert wird (vgl. Kapitel 4.2). Die Distanzmessgenauigkeit des Laserscanners ist spezifiziert mit ± 3 cm für Distanzen bis zu 10 m und mit ± 5 cm für Distanzen zwischen 10 m und 30 m. Ein MCS der Firma *Optitrack*, das aus acht Kameras besteht, die an den Wänden des Raumes befestigt sind (siehe Abbildung 4.2a), bestimmt die Posen eines *Rigid Body*s, der starr mit dem 2D-Laserscanner verbunden ist. Das Ziel der Merkmalsbasierten Selbstkalibrierung auf dem kleinen Indoor-Datensatz ist also die Bestimmung der relativen Orientierung zwischen einem 2D-Laserscanner und einem Rigid Body. Tabelle 4.3 fasst die Spezifikationen der Sensoren des kleinen Indoor-Datensatzes zusammen.

Die Umgebung, die in diesem Datensatz erfasst wird, besteht aus einer Büroumgebung mit den Ausmaßen von ca. $8 \text{ m} \times 5 \text{ m} \times 2,5 \text{ m}$. Der Datensatz besteht aus insgesamt 2618 verschiedenen Posen und zugehörigen Zeilen des 2D-Laserscanners, was zu einer Punktwolke mit ca. 2,8 Millionen Punkten führt, die in Abbildung 4.2b visualisiert ist.

Da es im Gegensatz zum synthetischen Indoor-Datensatz für den kleinen Indoor-Datensatz nicht möglich ist, die wahren Parameter der relativen Orientierung mit übergeordneter Genauigkeit zu bestimmen, wird das Ergebnis der Merkmalsbasierten Selbstkalibrierung mit den Ergebnissen einer objektbasierten Kalibrierung und der Entropiebasierten Selbstkalibrierung (vgl. Kapitel 5.1.1) verglichen.

Diese objektbasierte Kalibrierung läuft in drei Schritten ab, wobei der erste und der zweite Schritt im Anschluss näher erläutert werden:

1. Bestimmung der relativen Orientierung zwischen einem 2D-Laserscanner und einer Kamera.
2. Bestimmung der relativen Orientierung zwischen einer Kamera und einem Rigid Body
3. Berechnung der relativen Orientierung zwischen einem 2D-Laserscanner und einem Rigid Body durch Verkettung der relativen Orientierungen aus den ersten beiden Schritten.

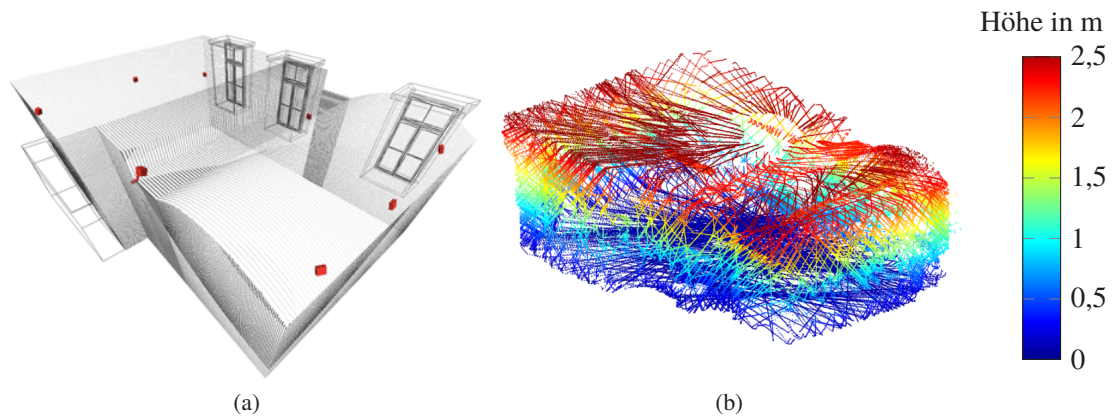


Abbildung 4.2: Kleiner Indoor-Datensatz. (a) Umgebung mit den Kameras des MCS in rot, (b) Punktwolke der erfassten Daten.

Tabelle 4.3: Spezifikationen der Sensoren des Small-Scale Indoor Datensatzes. *: in einer Distanz zwischen 0,1 und 10 m

Laserscanner	
Hokuyo UTM-30LX-EW	
Öffnungswinkel	270°
Winkelauflösung	0,25°
Anzahl an Laserpulsen pro Zeile	1080
Wellenlänge	$\lambda = 905 \text{ nm}$
Maximale Messdistanz	30 m
Distanzmessgenauigkeit*	$\pm 3 \text{ cm}$
Gewicht (ohne Kabel)	210 g
Motion Capture System	
8 × OptiTrack Prime 17 W	
Bildgröße	1664 px × 1088 px
Sensorelementgröße	5,5 μm × 5,5 μm
Bildwiederholungsrate	30–360 FPS
Latenz	2,8 ms
Shutter	Global
Verschlusszeit (bei 360 FPS)	2,5 ms

1. Bestimmung der relativen Orientierung zwischen einem 2D-Laserscanner und einer Kamera

Die hier beschriebene Methode zur Bestimmung der relativen Orientierung zwischen einem 2D-Laserscanner und einer Kamera basiert auf dem Konferenzbeitrag

Hillemann, M.; Jutzi, B.: UCalMiCeL - Unified Intrinsic and Extrinsic Calibration of a Multi-Camera-System and a Laserscanner. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences 4–17, 2017.

An dem Multisensorsystem des kleinen Indoor-Datensatzes sind zusätzlich zu den beschriebenen Sensoren drei Kameras montiert, die starr mit dem 2D-Laserscanner verbunden sind. Eine dieser Kameras wird für die hier beschriebene Methode verwendet.

Die Bestimmung der relativen Orientierung zwischen dem 2D-Laserscanner und dieser Kamera basiert auf UCalMiCeL (*Unified Intrinsic and Extrinsic Calibration of a Multi-Camera-System and a Laserscanner*) [79]. Abbildung 4.3 stellt eine Übersicht über die wichtigsten Schritte der Methodik dar. UCalMiCeL verwendet ein planares Schachbrett, das manuell im überlappenden Gesichtsfeld der statischen Kamera und des statischen 2D-Laserscanners bewegt und dabei N -mal unter variierenden Blickwinkeln von beiden Sensoren erfasst wird. Die innere Orientierung der Kamera bestimmt UCalMiCeL mit einem üblichen schachbrettbasierten Verfahren [166, 189, 214]. Die relative Orientierung zwischen Laserscanner und Kamera bestimmt UCalMiCeL durch korrespondierende Beobachtungen beider Sensoren vom Schachbrett. Dafür bestimmt UCalMiCeL einerseits die Posen des Schachbrettes im Koordinatensystem der Kamera, indem es in jedem Bild die Schachbrettpunkte extrahiert und anschließend Ebenen durch die extrahierten Punkte schätzt. Andererseits extrahiert UCalMiCeL die Punkte, die zu dem Schachbrett gehören, in den Zeilen des 2D-Laserscanners. Durch diese extrahierten Punkte wird mit Hilfe des RANSAC-Verfahrens [51] und einer verfeinernden Ausgleichung ein Geradensegment geschätzt. Eine Methode zur Registrierung einer Menge von Liniensegmenten zu einer Menge von Ebenen in 3D [193] liefert Näherungswerte für die Parameter der relativen Orientierung. Abschließend optimiert UCalMiCeL diese Näherungswerte in einer Kleinsten Quadrate Ausgleichung durch Minimierung der Punkt-zu-Flächen-Distanzen. Die Punkte entsprechen dabei den extrahierten Punkten in den Zeilen des Laserscanners und die Flächen den Schachbrettebenen.

2. Bestimmung der relativen Orientierung zwischen einer Kamera und einem Rigid Body

Die hier beschriebene Methode zur Bestimmung der relativen Orientierung zwischen einer Kamera und einem Rigid Body ist im Rahmen des Konferenzbeitrags

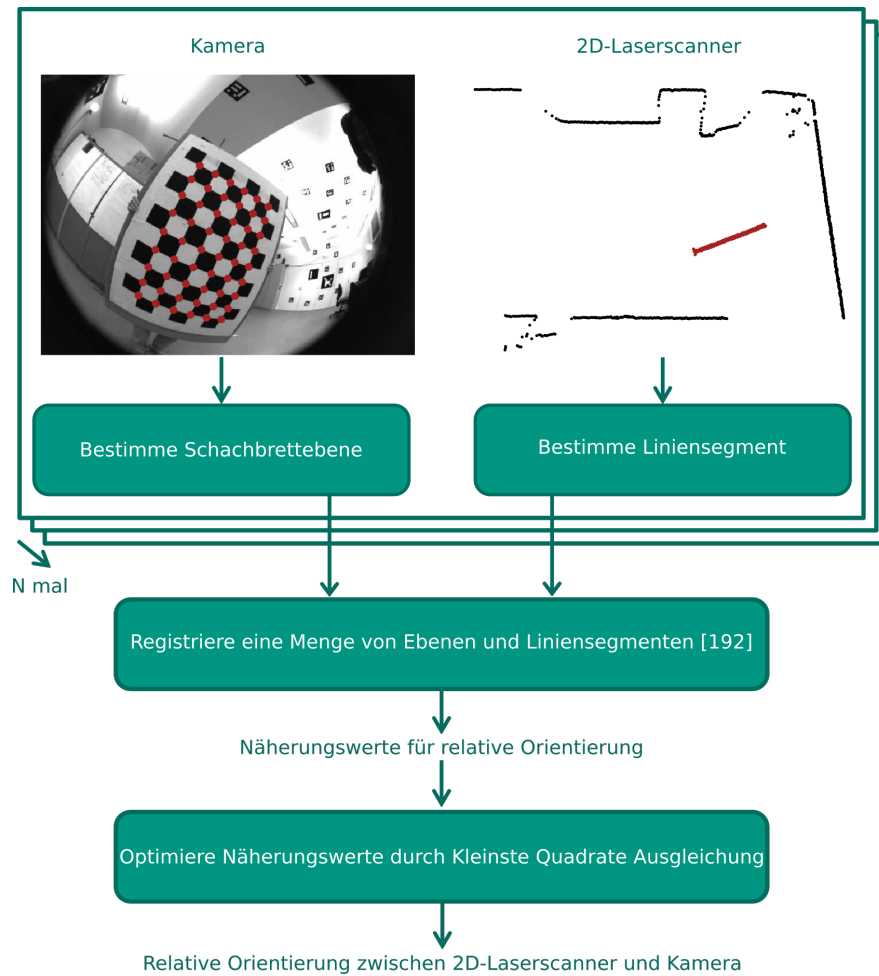


Abbildung 4.3: Bestimmung der relativen Orientierung zwischen einem 2D-Laserscanner und einer Kamera mit UCalMiCeL. Abbildung verändert nach [79].

Hübner, P.; Weinmann, M.; Hillemann, M.; Jutzi, B.; Wursthorn, S.: Combining Independent Visualization and Tracking Systems for Augmented Reality. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences 42–2 , 2018.

veröffentlicht.

Diese Methode basiert ebenfalls auf korrespondierenden Beobachtungen eines Schachbrettes durch eine Kamera und ein MCS. Das Schachbrett ist zusätzlich mit retro-reflektierenden Markern ausgestattet. Die relative Orientierung zwischen diesen retro-reflektierenden Markern und den Schachbrettpunkten wurde im Vorfeld durch manuelle Messungen mit dem MCS ermittelt. Dadurch können die 3D-Schachbrettpunkte im Koordinatensystem des MCS angegeben werden.

Für die Bestimmung der relativen Orientierung zwischen der Kamera und dem Rigid Body, der starr mit der Kamera verbunden ist, werden nun einerseits die 3D-Schachbrettpunkte und ande-

rerseits die Pose des Rigid Bodies mit dem MCS ermittelt. Aus 2D-3D-Korrespondenzen der 2D-Bild- und der 3D-Schachbrettpunkte bestimmt ein *perspective-n-point*-Algorithmus [104, 215] eine näherungsweise Kamerapose im Koordinatensystem des MCS. Dadurch ist sowohl eine näherungsweise Kamerapose als auch die Pose des Rigid Body im Koordinatensystem des MCS bekannt. Die relative Orientierung zwischen der Kamera und dem Rigid Body lässt sich durch Verkettung der Rigid Body-Pose und der inversen näherungsweise Kamerapose berechnen.

Die objektbasierte Selbstkalibrierung ermittelt die relative Orientierung auf diese Art nicht nur einmal, sondern mehrfach, wobei das Schachbrett manuell im gesamten Gesichtsfeld der statischen Kamera bewegt und dabei unter verschiedenen Blickwinkeln erfasst wird. Eine Kleinste Quadrate Ausgleichung ermittelt aus der Redundanz eine optimale relative Orientierung durch Minimierung der Summe aller Rückprojektionsfehler [90].

4.4 Mittlerer Outdoor-Datensatz

Der mittlere Outdoor-Datensatz besteht aus dem öffentlich verfügbaren *MLS 1 – TUM City Campus*-Datensatz [55]. Er wurde durch fahrzeugbasiertes Mobile Mapping in der Innenstadt von München erzeugt.

Der verwendete 3D-Laserscanner ist ein *Velodyne HDL-64E*. Er besteht aus 64 Zeilenscannern, die in einem kompakten Gehäuse angeordnet sind. Diese Zeilenscanner sind dabei auseinander gefächert, wodurch ein vertikales Gesichtsfeld von $26,8^\circ$ entsteht. Durch Rotation des Gehäuses entsteht zusätzlich ein horizontales Gesichtsfeld von 360° . Der *Velodyne HDL-64E* hat eine Reichweite von 120 m und eine Distanzmessgenauigkeit von 5 cm (1σ). Die vertikale Winkelauflösung beträgt $0,4^\circ$ und die horizontale Winkelauflösung $0,09^\circ$. Der Laserscanner misst bis zu ca. 1,3 Millionen Punkte pro Sekunde [57]. Der *Velodyne HDL-64E* ist unter einem Gierwinkel von ca. 25° gegenüber der Fahrtrichtung und unter einem Nickwinkel von ca. 45° nach vorne auf dem Dach eines Kleinbusses montiert [55].

Zur Posenbestimmung wurde das GNSS/IMU System *Applanix POS LV* eingesetzt. Die *Applanix POS LV* liefert Posen mit einer Wiederholrate von 200 Hz. Laut Herstellerangaben liegt die Genauigkeit der Posenstimmung bei 3,5 cm für die horizontale Lage und bei 5 cm für die Höhe sowie bei $0,008^\circ$ für den Roll- und den Nickwinkel und $0,02^\circ$ für den Gierwinkel. Die tatsächlichen Genauigkeiten liegen in der Praxis jedoch häufig deutlich darunter [17].

Die Aufgabe der Merkmalsbasierten Selbstkalibrierung besteht demzufolge bei diesem Datensatz aus der Bestimmung der relativen Orientierung zwischen einem GNSS/IMU System und einem 3D-Laserscanner.

Die Punktwolken des 3D-Laserscanners sind bei dem *MLS 1 – TUM City Campus*-Datensatz bereits mit Hilfe der relativen Orientierung in das Koordinatensystem des Posenbestimmungssensors transformiert. Die Publikationen, die mit dem Datensatz in Verbindung stehen, enthalten

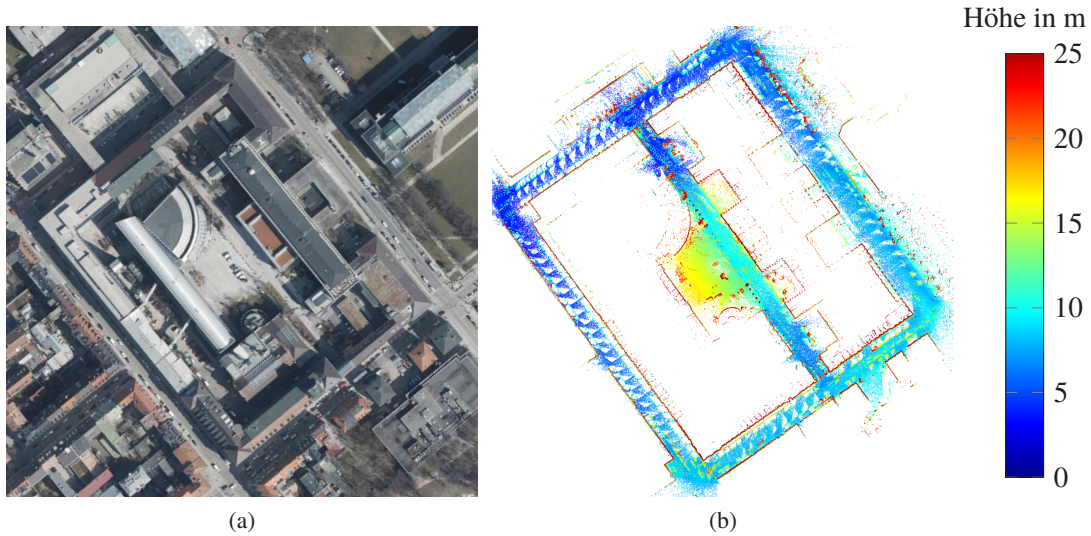


Abbildung 4.4: Mittlerer Outdoor-Datensatz. (a) Luftbild der Umgebung (Datenquelle: dl-de/by-2-0: Landeshauptstadt München – Kommunalreferat – GeodatenService – www.geodatenservice-muenchen.de), (b) Ausgedünnte Punktwolke der erfassten Daten.

keine näheren Informationen zu den durchgeführten Kalibrierungen, eine manuelle Beurteilung auf Basis der Punktwolke deutet jedoch darauf hin, dass diese eine hohe Qualität aufweisen.

4.5 Großer Outdoor-Datensatz

Der große Outdoor-Datensatz besteht aus einem Teil des öffentlich verfügbaren *KITTI-Datensatzes* [59]. Der *KITTI-Datensatz* wurde in und um Karlsruhe mit einem Multisensorsystem erfasst, das auf einem Fahrzeug montiert ist. Der große Outdoor-Datensatz erstreckt sich über mehrere Straßen und hat dadurch die größten Ausmaße der vier Datensätze. Neben Straßen, Fassaden und anderen Fahrzeugen enthält der große Outdoor-Datensatz auch die meiste Vegetation (siehe Abbildung 4.5).

Der Datensatz enthält die Daten einer Navigationseinheit, die aus einem GNSS-Empfänger und einer IMU besteht, eines 3D-Laserscanners sowie einer Stereokamera. Der 3D-Laserscanner ist, genau wie beim mittleren Outdoor-Datensatz, ein *Velodyne HDL-64E* mit den in Kapitel 4.4 angegebenen Spezifikationen.

Obwohl in beiden Fällen der gleiche 3D-Laserscanner verwendet wurde, unterscheiden sich die Datensätze deutlich in der Art und Genauigkeit der Posenbestimmung. Die Experimente verwenden die Stereokamera und ORB-SLAM2 [136] anstatt des hoch genauen GNSS/IMU Systems für die Posenbestimmung. Die montierte Stereokamera hat eine Basislinie von ca. 54 cm. Jede einzelne Kamera hat einen 1/2" CCD-Sensor, eine Auflösung von 1,4 Megapixeln bei einer Pixelgröße von $3,75 \mu\text{m}$. Durch die Verwendung eines *Global Shutter* werden alle

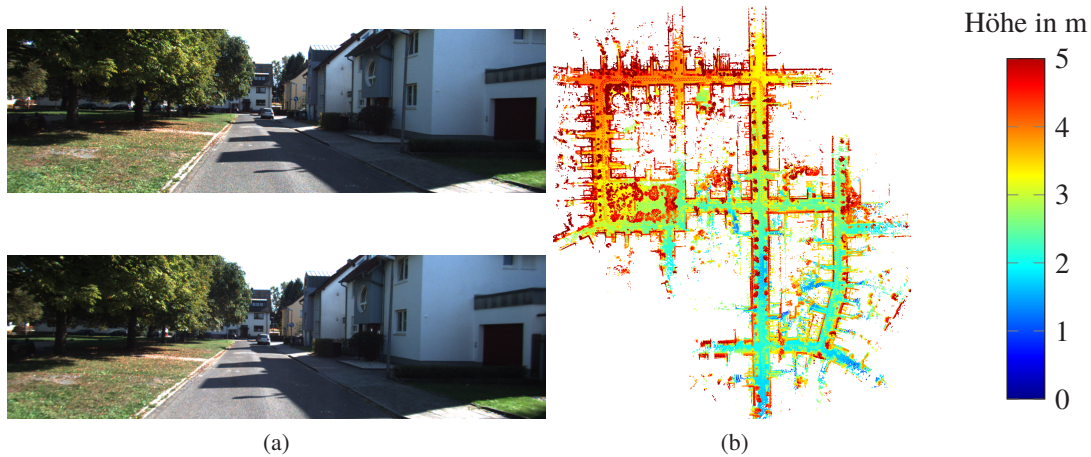


Abbildung 4.5: Großer Outdoor-Datensatz. (a) Bildpaar der Stereokamera. (b) Ausgedünnte Punktwolke der erfassten Daten.

Sensorelemente gleichzeitig ausgelesen [57]. Bei ORB-SLAM2 handelt es sich um ein Posenbestimmungsverfahren, das fortlaufend die Pose relativ zur vorangegangenen Pose bestimmt. Demzufolge sind die geschätzten Posen nur lokal konsistent und kleine Ungenauigkeiten akkumulieren sich mit der zurückgelegten Strecke (vgl. Kapitel 2.4.3). Allerdings ist ORB-SLAM2 in der Lage, Schleifen zu schließen, wodurch die Ungenauigkeiten in der Posenbestimmung deutlich reduziert werden. Für die Genauigkeit der Posenbestimmung kann auf dem gesamten KITTI-Datensatz von einer Translationsgenauigkeit von 1,15% und einer Rotationsgenauigkeit von $0,0027^\circ$ ausgegangen werden [58]. Bei der verwendeten Sequenz betragen die Genauigkeiten 0,7 m und $0,25^\circ$ auf 100 m [136] und sind somit geringer als bei den anderen Datensätzen.

Bei den Experimenten mit dem großen Outdoor-Datensatz ist somit das Ziel, die Parameter der relativen Orientierung zwischen einer Stereokamera und einem 3D-Laserscanner zu bestimmen.

Die für diese Experimente verwendeten Daten bestehen aus einem Teil der ersten von insgesamt 22 Sequenzen des KITTI-Datensatzes. Dieser Teil enthält jede dritte der ersten 1650 Posen und der zugehörigen Punktwolken. Dadurch werden zwei Dinge gewährleistet: Erstens wird die Datenmenge reduziert, wodurch der zeitliche Berechnungsaufwand begrenzt wird, und zweitens enthält die Trajektorie auf diese Art noch eine Schleife, die von ORB-SLAM2 zur Verbesserung der Posenbestimmung verwendet wird. Zusätzlich zu der Reduzierung der Anzahl der Posen und der zugehörigen Punktwolken, werden Punkte zufällig aus den übrigen Punktwolken herausgefiltert, um die Datenmenge nochmals zu verkleinern.

Für die Evaluierung der Ergebnisse liegen dem Datensatz die Parameter der relativen Orientierung aus einer Vergleichskalibrierung bei. Die Näherungswerte für die Kalibrierungen entsprechen verfälschten Parametern der relativen Orientierung aus der Vergleichskalibrierung. Dabei ist jeder Rotationswinkel um 5° und jeder Translationsparameter um 5 cm verfälscht.

Die quantitative Evaluierung der Ergebnisse enthält den Vergleich der Parameter der relativen Orientierung der Vergleichskalibrierung mit den Parametern, die aus den beiden Selbstkalibrierungen resultieren. Darüber hinaus dienen Punktwolken, die auf Basis der Ergebnisse der drei verschiedenen Kalibrierungsmethoden berechnet wurden, einem qualitativen Vergleich der Ergebnisse.

Bei der Vergleichskalibrierung des großen Outdoor-Datensatzes handelt es sich um ein semi-automatisches Verfahren, das in zwei Schritten abläuft:

1. **Bestimmung grober Parameter der relativen Orientierung** mit Hilfe der *Automatic Single-Shot Calibration of Range and Camera Sensors* [56]. Diese Objektbasierte Kalibrierung detektiert mehrere Schachbretter aus einem Bild der Kamera und separat aus der korrespondierenden Punktwolke eines 3D-Laserscanners. Anschließend werden Hypothesen über die relative Orientierung der Sensoren generiert, indem zufällig Schachbretter aus dem Bild zu Schachbrettern aus der Punktwolke zugeordnet und registriert werden. Die besten Hypothesen werden anschließend verfeinert und verifiziert.
2. **Verfeinerung der groben Parameter der relativen Orientierung** mit Hilfe einer manuellen Prozedur. Bei dieser Prozedur werden manuell korrespondierende Punkte im Bild und in der Punktwolke gewählt. Die Verfeinerung geschieht durch die Minimierung der Summe der Rückprojektionsfehler zwischen den Bildpunkten und den korrespondierenden, ins Bild projizierten Punkten der Punktwolke [59].

Die Genauigkeit der Kalibrierung nach dem ersten Schritt des Verfahrens ist in [56] angegeben. Der Median des Rotationsfehlers beträgt ca. 10° mit einer Präzision von ca. 8° . Der Median des Translationsfehlers liegt bei ca. 0,2 m mit einer Präzision von ca. 0,3 m. Die Genauigkeit nach der manuellen Verfeinerung im zweiten Schritt des Verfahrens ist nicht angegeben.

5 Experimente

Dieses Kapitel beschreibt die Experimente, auf Basis derer die entwickelte Merkmalsbasierte Selbstkalibrierung evaluiert wird. Die Untersuchungen der Selbstkalibrierung werden in Kapitel 5.1 dargestellt. Anschließend beschreibt Kapitel 5.2 die Ergebnisse, die die Merkmalsbasierte Selbstkalibrierung auf den realen Datensätzen erzielt, wobei die Reihenfolge analog zu Kapitel 4 nach der Größe des Datensatzes festgelegt ist (Kapitel 5.2.1–5.2.3).

Die bis dahin beschriebene Merkmalsbasierte Selbstkalibrierung dient dazu, die Parameter der relativen Orientierung zwischen zwei Sensoren zu bestimmen. Das Verfahren, das zu diesem Zwecke entwickelt wurde, ist allerdings generisch, sodass prinzipiell auch andere systematische Fehler, die sich in der Punktwolke zeigen, mit dem Verfahren bestimmt werden können. Deshalb zeigt Kapitel 5.3 beispielhaft das weiterführende Potential der Merkmalsbasierten Selbstkalibrierung. Die Methodik wird dafür so angepasst, dass statt der Parameter der relativen Orientierung ein Skalierungsfaktor für die Posen des Systems bestimmt wird. Ein solcher Skalierungsfaktor sollte dann bestimmt werden, wenn die Posen des Posenbestimmungssensors nur bis auf eine unbekannte Skalierung bekannt sind, was beispielsweise für die bildbasierte Posenbestimmung mit einer einzelnen Kamera der Fall ist.

5.1 Untersuchungen zur Selbstkalibrierung

Die Untersuchungen der Merkmalsbasierten Selbstkalibrierung fokussieren auf vier Fragestellungen:

1. Welchen Einfluss haben die Posen des Systems auf das Ergebnis der Merkmalsbasierten Selbstkalibrierung und was ist eine optimale Bewegungskonfiguration für die Selbstkalibrierung (Kapitel 5.1.1)?
2. Wie gut eignen sich die verschiedenen Kostenfunktionen für die Merkmalsbasierte Selbstkalibrierung (Kapitel 5.1.2)?
3. Wie groß ist der Konvergenzradius der Merkmalsbasierten Selbstkalibrierung (Kapitel 5.1.3)?
4. Wie ist das Ergebnis des Multiskalenansatzes im Vergleich zu dem Durchlauf auf einer einzelnen Skala hinsichtlich des Konvergenzradius und der Genauigkeit (Kapitel 5.1.4)?

5.1.1 Einfluss der Posen

Die Untersuchungen in diesem Kapitel analysieren den Einfluss der Posen auf das Ergebnis der Selbstkalibrierung. Dafür werden zunächst theoretische Betrachtungen aus der Literatur wiedergegeben und anschließend durch Experimente mit der Entropiebasierten Selbstkalibrierung auf dem mittleren Outdoor-Datensatz gestützt.

Die Untersuchungen in diesem Kapitel wurden in dem Konferenzbeitrag

Hillemann, M.; Meidow, J.; Jutzi, B.: Impact of Different Trajectories on Extrinsic Self-Calibration for Vehicle-based Mobile Laser Scanning Systems. *ISPRS International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences XLII-2/W16*, 1–2, 2019.

veröffentlicht.

Theoretische Betrachtungen

Den Autoren der Entropiebasierten Selbstkalibrierung zufolge ist es für eine genaue Bestimmung aller sechs Parameter der relativen Orientierung mit einem Selbstkalibrierungsverfahren erforderlich, dass die verwendeten Posen des Sensorsystems Variationen in allen sechs Freiheitsgraden aufweisen [124]. Die Trajektorie besitzt demzufolge im optimalen Fall Translationen in drei orthogonalen Raumrichtungen sowie Rotationen um alle drei Raumachsen.

Bezogen auf flugzeugbasiertes bzw. UAV-basiertes Laserscanning existieren in der Literatur differenziertere Betrachtungen bezüglich der Anforderungen an die Posen [67, 157]. Auf Basis dieser Betrachtungen wird eine minimale Flugkonfiguration definiert, mit der alle Parameter der relativen Orientierung bestimmt werden können [157]. Dafür wird zunächst der Einfluss jedes Parameters der relativen Orientierung auf die Punktwolke analysiert. Bei den Betrachtungen wird angenommen, dass das Koordinatensystem des Posenbestimmungssensors und das Koordinatensystem des Laserscanners parallel ausgerichtet sind und jeweils eine Achse in Bewegungsrichtung zeigt, die zweite senkrecht dazu und die dritte nach oben. Dadurch lässt sich die relative Orientierung bezüglich der Bewegungsrichtung ausdrücken. Sie besteht aus einer relativen Translation in Bewegungsrichtung, senkrecht zur Bewegungsrichtung und in vertikaler Richtung sowie einer relativen Rotation um den Roll-, den Nick- und den Gierwinkel. Tabelle 5.1 fasst die Auswirkungen der Parameter der relativen Orientierung auf die Punkte der Punktwolke zusammen und führt jeweils Beobachtungen auf, durch die der jeweilige Parameter in der Punktwolke sichtbar und dadurch bestimmbar wird.

Als Konsequenz werden Voraussetzungen für die Bewegung und die Umgebung definiert, die genügend geometrische Bedingungen zur Bestimmung aller Parameter der relativen Orientierung bewirken [157]: Das mobile Multisensorsystem sollte mehrere dreidimensionale Objekte

Tabelle 5.1: Auswirkungen der Parameter der relativen Orientierung auf die Punkte der Punktwolke und Lösungsvorschlag für die Kalibrierung nach [157].

Parameter der relativen Orientierung	Auswirkung auf die Punkte	Lösung
Relative Translation in Bewegungsrichtung	Verschiebung in Bewegungsrichtung	Erfassung vertikaler Objekte, die senkrecht zur Bewegungsrichtung stehen aus entgegengesetzten Bewegungsrichtungen
Relative Translation senkrecht zur Bewegungsrichtung	Verschiebung senkrecht zur Bewegungsrichtung	Erfassung vertikaler Objekte, die parallel zur Bewegungsrichtung stehen, aus zwei entgegengesetzten Bewegungsrichtungen
Relative Translation in vertikaler Richtung	Verschiebung in vertikaler Richtung	Erfassung horizontaler Objekte einmal von oben und ein weiteres Mal mit einem auf dem Kopf stehenden Sensorsystem von unten. Unpraktikabel.
Relative Rotation um den Rollwinkel	Verschiebung in vertikaler Richtung und senkrecht zur Bewegungsrichtung	Erfassung von Objekten mit variierenden Höhen im Bezug auf die Höhe des Sensorsystems
Relative Rotation um den Nickwinkel	Verschiebung in vertikaler Richtung und in Bewegungsrichtung	Erfassung von Objekten mit variierenden Höhen im Bezug auf die Höhe des Sensorsystems
Relative Rotation um den Gierwinkel	Verschiebung in und senkrecht zur Bewegungsrichtung	Zweimalige Erfassung aus der gleichen Bewegungsrichtung von mindestens zwei vertikalen Objekten mit deutlichem horizontalen Abstand zueinander

mit unterschiedlichen vertikalen Abständen zum Sensor und horizontalen Abständen zueinander unter mindestens drei parallelen Bewegungen erfassen, wovon zwei die gleiche und eine die umgekehrte Bewegungsrichtung hat. Außerdem muss zusätzlich Wissen über vertikale Abstände der Objekte vom Posenbestimmungssensor eingeführt werden, damit die relative Translation in vertikaler Richtung in der Praxis bestimmbar wird [157].

Experimente

Für die Experimente zum Einfluss der Posen wird die relative Orientierung mit der Entropiebasierten Selbstkalibrierung viermal auf dem mittleren Outdoor-Datensatz bestimmt, wobei jedes



Abbildung 5.1: Überblick der untersuchten Trajektorien auf dem mittleren Outdoor-Datensatz. Unidirektionale Trajektorie (grüne Strichpunktlinie), orthodirektionale Trajektorie (rote Strichlinie), bidirektionale Trajektorie (blaue, durchgezogene Linie), multidirektionale Trajektorie (gelbe, gepunktete Linie) (Datenquelle: dl-de/by-2-0: Landeshauptstadt München – Kommunalreferat – GeodatenService – www.geodatenservice-muenchen.de).

Mal andere Posen zugrunde liegen. Abbildung 5.1 visualisiert die vier Trajektorien zu diesen Posen.

1. Die grüne Strichpunktlinie repräsentiert eine *unidirektionale* Trajektorie, wie sie bei einer Geradeausfahrt entsteht.
2. Die rote Strichlinie repräsentiert die Trajektorie, wie sie beim Abbiegen an einer orthogonalen Ecke entsteht. Diese Trajektorie wird als *orthodirektionale* Trajektorie bezeichnet.

3. Die blaue durchgezogene Linie repräsentiert eine *bidirektionale* Trajektorie und stellt eine Hin- und Rückfahrt auf dem gleichen Weg dar.
4. Die gelbe gepunktete Linie stellt eine kurvige Trajektorie, dar, wie sie beispielsweise bei einem Wendemanöver auf begrenztem Raum entsteht. Diese Trajektorie wird als *multidirektionale* Trajektorie bezeichnet.

Bei der bidirektionalen und der multidirektionalen Trajektorie ist die Fahrt über eine flache Rampe enthalten, sodass sich die Höhe der Sensorik im Bezug auf den Boden ändert. Alle Trajektorien mit Ausnahme der bidirektionalen Trajektorie bestehen aus der selben Anzahl an Posen. Die bidirektionale Trajektorie besteht nur aus einem Drittel dieser Anzahl, da der mittlere Outdoor-Datensatz keine längere Hin- und Rückfahrt auf dem gleichen Weg enthält. Die zurückgelegte Wegstrecke unterscheidet sich jedoch aufgrund von unterschiedlichen Geschwindigkeiten.

Die Näherungswerte der relativen Orientierung haben einen Fehler von +1 m für jeden Parameter der relativen Translation und $+3^\circ$ für jeden Winkel der relativen Rotation. Für belastbare Ergebnisse und um die Präzision des Verfahrens zu evaluieren, werden alle Ergebnisse jeweils 20 mal mit einer unterschiedlichen, zufällig gewählten Untermenge an Messpunkten des Laserscanners durchgeführt.

Da der Einfluss der Rotationsparameter auf die Punkte größer ist als der Einfluss der Translationsparameter, wird die Entropiebasierte Selbstkalibrierung rekursiv in drei Schritten durchgeführt:

1. Ausgleichung der drei Parameter der relativen Rotation.
2. Ausgleichung der Parameter der relativen Translation unter Berücksichtigung der Ergebnisse aus Schritt 1.
3. Ausgleichung aller Parameter der relativen Orientierung mit den Näherungswerten aus Schritt 1 und Schritt 2.

Abbildung 5.2a zeigt ein Foto, das im Innenhof der Technischen Universität München entstanden ist. Dieses Bild wurde zu einem anderen Zeitpunkt als die räumliche Erfassung des mittleren Outdoor-Datensatzes aufgezeichnet und dient hier als visuelle Unterstützung für die Interpretation der Abbildungen 5.2b-f, die die qualitativen Ergebnisse der Kalibrierungen zeigen. Die Abbildung zeigt die Punktwolken des Innenhofs basierend auf fünf unterschiedlichen relativen Orientierungen. Die Farbe jedes Punktes visualisiert seine vertikalen Koordinatenwerte. Zur Vergleichbarkeit ist immer der gleiche Teil der Punktwolke dargestellt, auch wenn die Daten, die zur Kalibrierung verwendet werden, teilweise aus anderen Bereichen der Punktwolke stammen (vgl. Abbildung 5.1). Abbildung 5.2b zeigt die qualitativen Ergebnisse der Vergleichskalibrierung. Die Ergebnisse der Entropiebasierten Selbstkalibrierung mit den unterschiedlichen Trajektorien sind in Abbildungen 5.2c-f dargestellt (c unidirektional, d orthodirektional, e bidi-




Abbildung 5.2: Qualitative Ergebnisse nach Kalibrierung mit verschiedenen Trajektorien. (a) Foto, (b) Vergleichskalibrierung (c) unidirektionale Trajektorie, (d) orthodirektionale Trajektorie, (e) bidirektionale Trajektorie, (f) multidirektionale Trajektorie. Die Punktwolken in c und d wirken verzerrt, während sich die Punktwolken in e und f visuell kaum von der Vergleichskalibrierung in b unterscheiden.

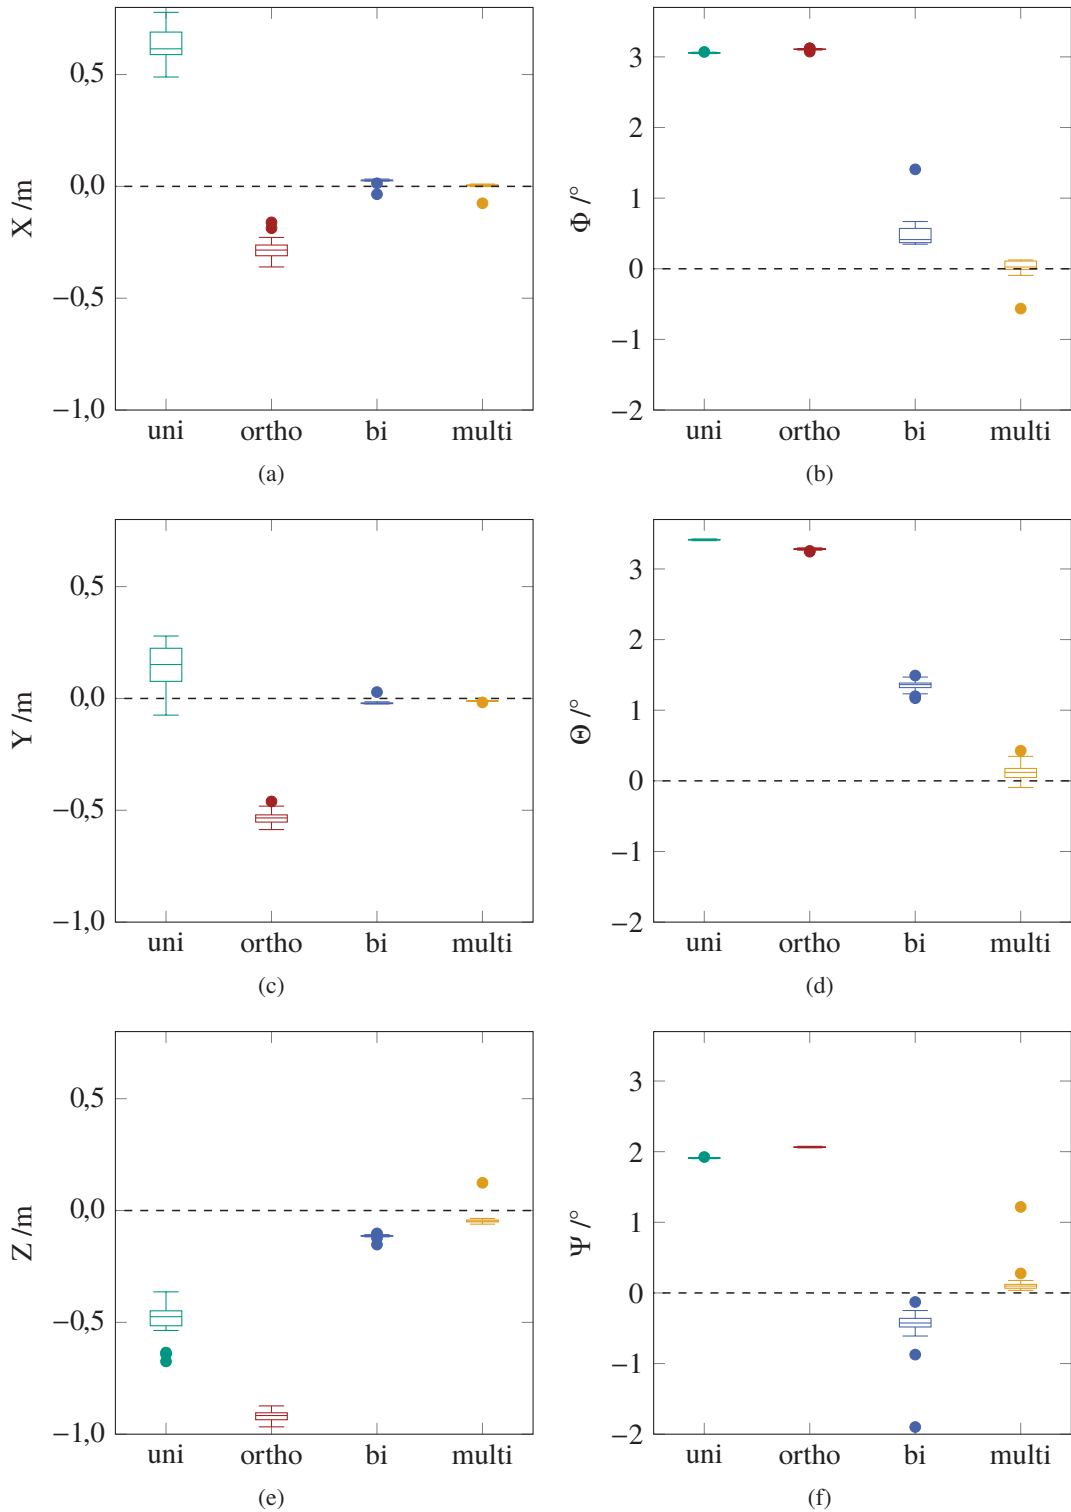


Abbildung 5.3: Quantitative Ergebnisse nach Kalibrierung mit verschiedenen Trajektorien. (a,c,e) Parameter der relativen Translation, (b,d,f) Parameter der relativen Rotation jeweils für die vier verschiedenen Trajektorien. Φ bezeichnet den Roll-, Θ den Nick- und Ψ den Gierwinkel. Die Ergebnisse der Vergleichskalibrierung sind als gestrichelte Linie dargestellt.

rektional, f multidirektional). Die Ergebnisse für die unidirektionale und die orthodirektionale Trajektorie in Abbildungen 5.2c und d wirken verzerrt, was beispielsweise an den Fenstern des Gebäudes im Hintergrund oder auch an dem Mast im Vordergrund deutlich zu erkennen ist. Dagegen sehen die Ergebnisse mit der bidirektionalen und der multidirektionalen Trajektorie in Abbildung 5.2e und f dem Ergebnis der Vergleichskalibrierung in Abbildung 5.2b sehr ähnlich. Die Qualität zwischen diesen drei Punktwolken ist visuell nicht unterscheidbar.

Abbildung 5.3 zeigt die quantitativen Ergebnisse für die vier Trajektorien für jeden Parameter der relativen Orientierung. Die Parameter der relativen Translation sind in Abbildung 5.3a,c und e dargestellt und die Parameter der relativen Rotation in Abbildung 5.3b,d und f. Φ bezeichnet den Rollwinkel, Θ den Nickwinkel und Ψ den Gierwinkel. Die Ergebnisse der Vergleichskalibrierung sind als gestrichelte Linie dargestellt.

Die Ergebnisse zeigen einen erheblichen Einfluss der Trajektorie auf das Ergebnis der Kalibrierung. Die Kalibrierungen mit der unidirektionalen und der orthodirektionalen Trajektorie weisen Fehler von bis zu einigen Dezimetern und mehreren Grad auf. Diese Kalibrierungen verschlechtern die Näherungswerte für den Roll- und den Nickwinkel. Die Kalibrierung mit der bidirektionalen Trajektorie liefert im Vergleich zur uni- und orthodirektionalen Trajektorie um einen Faktor von ca. 4,5 bis 30 kleinere Fehler für die Parameter der relativen Translation und um einen Faktor von ca. 2,5 bis 6 kleinere Fehler für die Parameter der relativen Rotation. Die Kalibrierung mit der multidirektionalen Trajektorie liefert nochmals eine signifikante Verbesserung für die Parameter der relativen Rotation um bis zu Faktor 10 im Vergleich zur bidirektionalen Trajektorie. Die Präzision liegt bei der Bestimmung der Rotationsparameter mit der uni- und der orthodirektionalen Trajektorie bei ca. $0,01^\circ$, während die Abweichung zur Vergleichskalibrierung bei ca. 2 bzw. 3° liegt.

Eine Diskussion dieser Ergebnisse erfolgt in Kapitel 6.1.

5.1.2 Eignung der Kostenfunktionen

Die folgenden Experimente dienen dazu, die Eignung der verschiedenen Kostenfunktionen für die Merkmalsbasierte Selbstkalibrierung zu evaluieren. Dafür wird die Merkmalsbasierte Selbstkalibrierung mit allen Kostenfunktionen jeweils für die 10 simulierten räumlichen Erfassungen des synthetischen Datensatzes durchgeführt. Zusätzlich zu den Kostenfunktionen, die auf geometrischen 3D-Merkmalen basieren, erfolgen die Experimente ebenfalls mit der Kostenfunktion der Entropiebasierten Selbstkalibrierung (vgl. Kapitel 5.1.1). Abbildung 5.4 zeigt die Ergebnisse dieser Experimente.

Die Merkmalsbasierte Selbstkalibrierung, die das geometrische 3D-Merkmal Linearität f_L verwendet, liefert geschätzte Parameterwerte, die sich nur sehr geringfügig von den Näherungswerten unterscheiden. Die zugehörigen Fehler dieser Parameter sind deutlich höher als die der Merkmalsbasierten Selbstkalibrierungen bei Verwendung eines anderen geometrischen

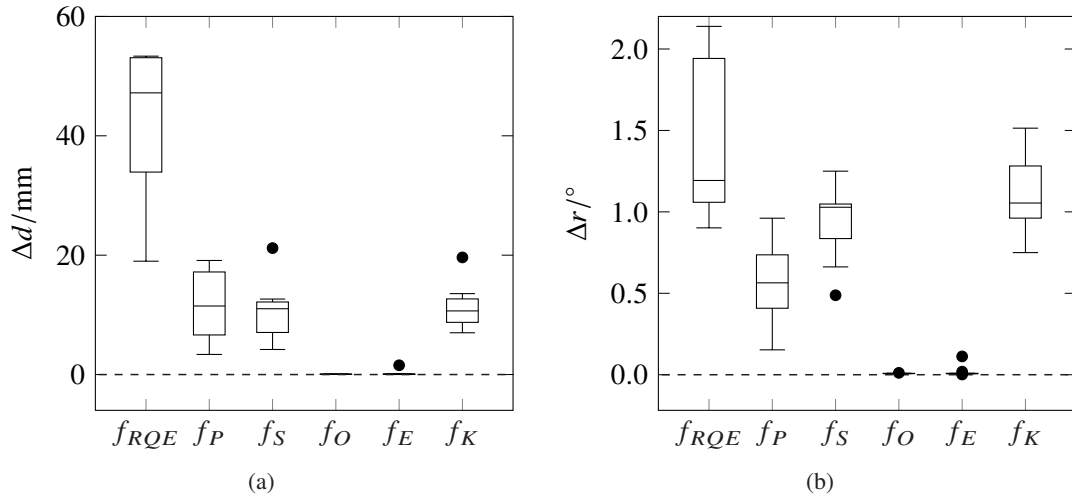


Abbildung 5.4: Fehler der relativen Translation (a) und Fehler der relativen Rotation (b) nach Kalibrierung mit der Entropiebasierten Selbstkalibrierung f_{RQE} und der Merkmalsbasierten Selbstkalibrierung basierend auf der Planarität f_P , der Sphärizität f_S , der Omnivarianz f_O , der Eigenentropie f_E und der Krümmungsänderung f_K für die synthetischen Daten. Die Linearität f_L hat sich als ungeeignet für die Merkmalsbasierte Selbstkalibrierung herausgestellt und ist aus Visualisierungsgründen nicht dargestellt. Die Omnivarianz f_O und die Eigenentropie f_E führen zu deutlich kleineren Fehlern im Vergleich zur Kostenfunktion der Entropiebasierten Selbstkalibrierung f_{RQE} und den anderen geometrischen 3D-Merkmalen.

3D-Merkmalen. Zur Visualisierung mit einer geeigneten Achsenskalierung stellt Abbildung 5.4 das geometrische 3D-Merkmal Linearität f_L nicht dar. Die übrigen Kostenfunktionen führen zu kleineren Fehlern im Vergleich zur Kostenfunktion der Entropiebasierten Selbstkalibrierung f_{RQE} . Der kleinste Fehler resultiert aus der Merkmalsbasierten Selbstkalibrierung mit der Omnivarianz f_O .

Die Distanzmessungen des Laserscanners und die simulierten Posen, die dieser Untersuchung zugrunde liegen, enthalten keine zufälligen Fehler. Dadurch kann der Einfluss der Kostenfunktionen unter idealen Voraussetzungen bewertet werden. Um diese Ergebnisse anhand von realen Daten zu verifizieren, wird die Eignung der verschiedenen Kostenfunktionen im Folgenden mit dem kleinen Indoor-Datensatz erneut getestet.

Die Näherungswerte für die Parameter der relativen Orientierung, die in die Selbstkalibrierung eingehen, stammen aus den resultierenden Werten der objektbasierten Vergleichskalibrierung aus Kapitel 4.3. Diese Werte sind allerdings um 5° für jeden Parameter der relativen Rotation und 5 cm für jeden Parameter der relativen Translation verfälscht.

Wie in Kapitel 2.5.2 bereits erwähnt, sind manche geometrische 3D-Merkmale robuster gegenüber Rauschen als andere [38]. Deshalb werden die Untersuchungen bezüglich der Eignung der Kostenfunktionen, die zunächst auf Basis von synthetischen Daten ermittelt wurden, mit Hilfe von realen Daten verifiziert. Abbildungen 5.5 und 5.6 visualisieren Seitenansichten der resultierenden dreidimensionalen Punktwolken. Die Farbe jedes Punktes stellt jeweils den Wert

des geometrischen 3D-Merkmals dar. Die Summe dieser mit dem Huber-Schätzer gewichteten Werte wird jeweils von der Merkmalsbasierten Selbstkalibrierung minimiert (vgl. Gleichung 3.15). Die Punktwolken in der linken Spalte der Abbildungen wurden mit dem Ergebnis der objektbasierten Vergleichskalibrierung berechnet. Für eine bessere visuelle Vergleichbarkeit sind diese Punktwolken ebenfalls gemäß dem jeweiligen geometrischen 3D-Merkmal eingefärbt. Das bedeutet, dass sich die Punktwolken in der linken Spalte lediglich durch die farbliche Darstellung unterscheiden. Die Punktwolken in der rechten Spalte stellen qualitative Ergebnisse der Entropiebasierten Selbstkalibrierung und der Merkmalsbasierten Selbstkalibrierungen basierend auf den verschiedenen geometrischen 3D-Merkmalen dar. Es ergeben sich also insgesamt acht verschiedene Punktwolken, von denen eine in sieben verschiedenen Einfärbungen dargestellt ist. Für die Farbkodierung sind die Werte der geometrischen 3D-Merkmale auf den Wertebereich von Null bis Eins skaliert.

Abbildung 5.5 zeigt, dass die relativen Orientierungen, die die Merkmalsbasierten Selbstkalibrierung basierend auf den geometrischen 3D-Merkmalen Linearität f_L (Abbildung 5.5d) und Planarität f_P (Abbildung 5.5f) bestimmt hat, ungenau sind. In diesen Fällen konvergiert die Kleinste-Quadrate-Ausgleichung zu einem lokalen Minimum, das in der Nähe der Näherungswerte liegt. Die Punktwolken die nach der Merkmalsbasierten Selbstkalibrierung basierend auf der Sphärizität f_S (Abbildung 5.5h), der Omnivarianz f_O (Abbildung 5.6b), der Eigenentropie f_E (Abbildung 5.6d) und der Krümmungsänderung f_K (Abbildung 5.6f) resultieren, sehen visuell schärfer aus, als die der objektbasierten Vergleichskalibrierung (Abbildungen 5.5 a,c,e,g und Abbildungen 5.6 a,c,e) und die der Entropiebasierten Selbstkalibrierung (Abbildung 5.5b).

Zwei Metriken dienen im Folgenden dazu, die visuellen Eindrücke aus den Abbildungen 5.5 und 5.6 zu quantifizieren. Die erste Metrik besteht aus dem Median der Werte der verschiedenen Kostenfunktionen der Selbstkalibrierungen, berechnet nach Kalibrierung mit den acht getesteten Verfahren. Die zweite Metrik besteht aus durchschnittlichen Distanzen der Punkte zu ausgleichenden Ebenen, die in manuell definierten, planaren Regionen der Punktwolke bestimmt werden. Diese Metrik wird im Folgenden als mittlere Punkt-zu-Ebene-Distanz bezeichnet.

Tabelle 5.2 zeigt die erste Metrik für die getesteten Kalibrierungen. Je kleiner der Wert ist, desto besser bewertet das jeweilige Maß die Punktwolke. Der kleinste Wert in jeder Spalte ist fett dargestellt. Mit Ausnahme des Medians der Linearität \bar{f}_L sind die Mediane am kleinsten für die Merkmalsbasierte Selbstkalibrierung basierend auf der Omnivarianz f_O . Darüber hinaus zeigt die Tabelle, dass die Merkmalsbasierte Selbstkalibrierung basierend auf der Sphärizität f_S , der Omnivarianz f_O , der Eigenentropie f_E und der Krümmungsänderung f_K in allen Spalten zu kleineren Werten führt als die Objektbasierte Kalibrierung und die Entropiebasierte Selbstkalibrierung. Die erste Metrik unterstützt somit die qualitativen Ergebnisse.

Für die zweite Metrik, die mittlere Punkt-zu-Ebene-Distanz, werden manuell sechs planare Regionen in der Punktwolke definiert. Eine davon befindet sich am Boden (Ebene 1), eine

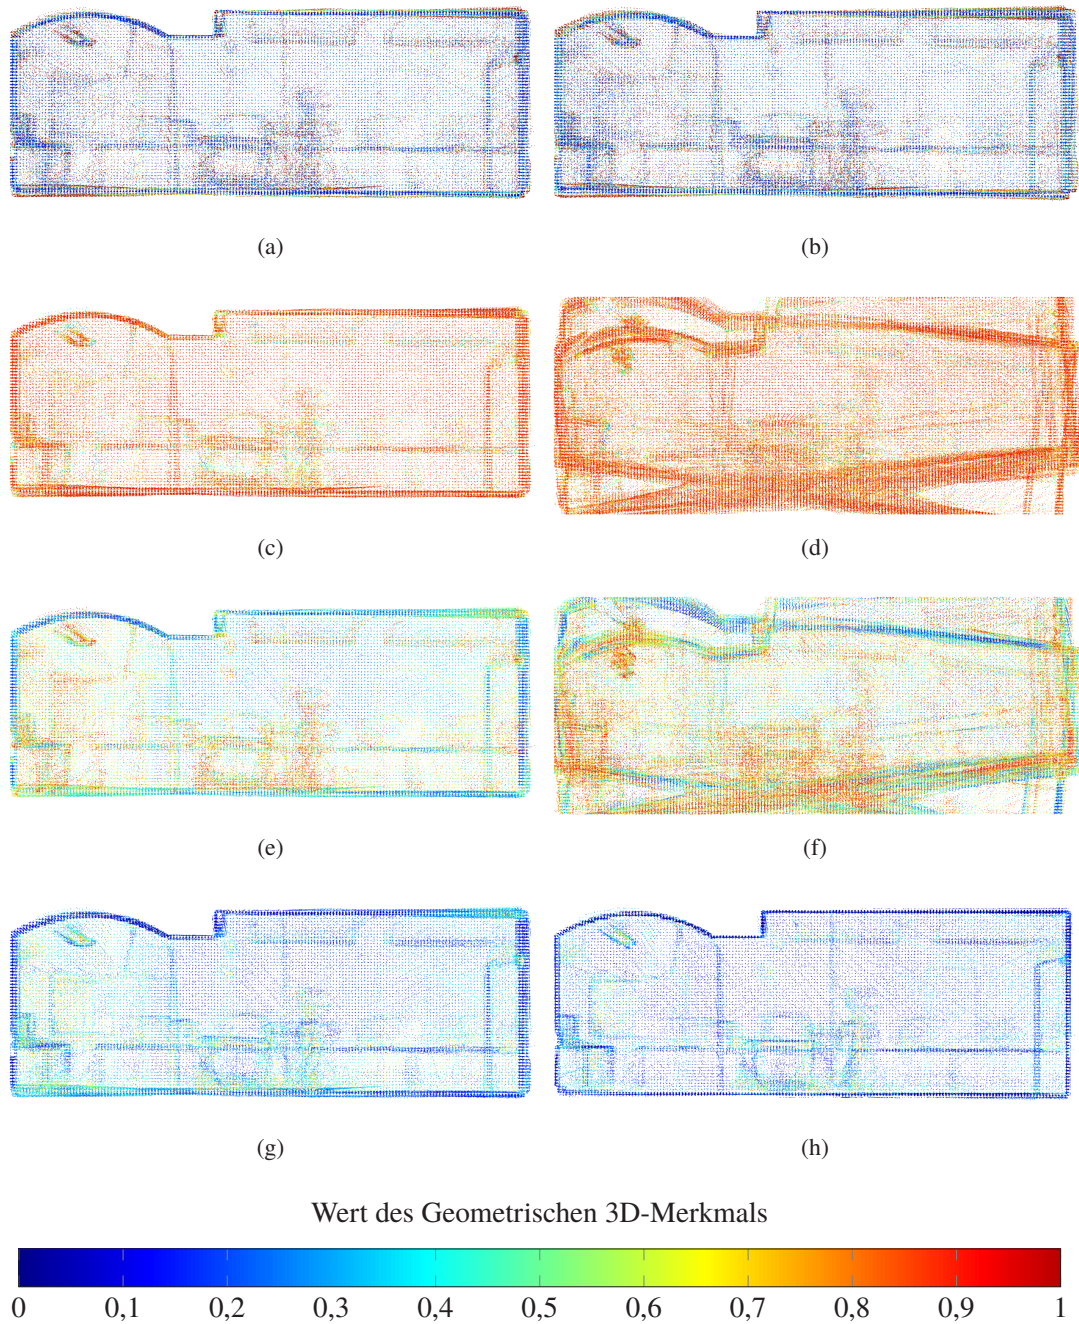


Abbildung 5.5: Punktwolken nach Kalibrierung mit der objektbasierten Vergleichskalibrierung (5.5a, 5.5c, 5.5e, 5.5g), der Entropiebasierten Selbstkalibrierung (5.5b) und der Merkmalsbasierten Selbstkalibrierung basierend auf der Linearität f_L (5.5d), der Planarität f_P (5.5e) und der Sphärizität f_S (5.5g) für den kleinen Indoor-Datensatz. Die Farbe jedes Punktes entspricht dem Wert des Merkmals, das von der zugehörigen Selbstkalibrierung verwendet wird. Die Punktwolken in der linken Spalte sind zur besseren Vergleichbarkeit ebenfalls eingefärbt. Für die objektbasierte Kalibrierung spielen die Merkmale jedoch keine Rolle.

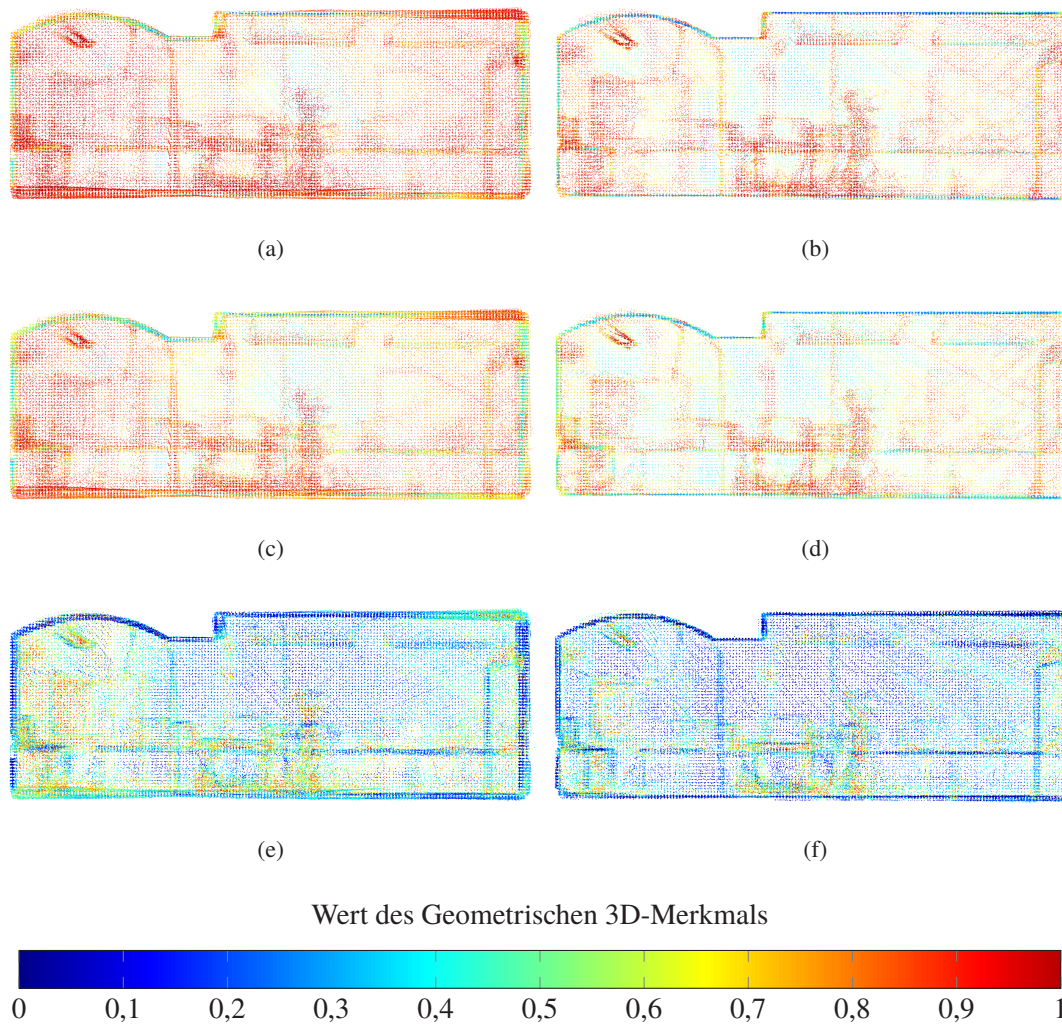


Abbildung 5.6: Punktwolken nach Kalibrierung mit der objektbasierten Vergleichskalibrierung (5.6a, 5.6c, 5.6e) und der Merkmalsbasierten Selbstkalibrierung basierend auf der Omnivarianz f_O (5.6b), der Eigenentropie f_E (5.6d) und der Krümmungsänderung f_K (5.6f) für den kleinen Indoor-Datensatz. Die Farbe jedes Punktes entspricht dem Wert des Merkmals, das von der zugehörigen Selbstkalibrierung verwendet wird. Die Punktwolken in der linken Spalte sind zur besseren Vergleichbarkeit ebenfalls eingefärbt. Für die objektbasierte Kalibrierung spielen die Merkmale jedoch keine Rolle. Die Ergebnisse der Merkmalsbasierten Selbstkalibrierung basierend auf diesen geometrischen 3D-Merkmalen führen zu schärferen Punktwolken als die der objektbasierten Vergleichskalibrierung.

an der Decke (Ebene 2) und jeweils eine an jeder Wand des Raumes (Ebenen 3 bis 6). Für jede dieser planaren Regionen wird jeweils eine ausgleichende Ebene geschätzt. Die mittlere Punkt-zu-Ebene-Distanz berechnet sich aus dem Mittelwert der Distanzen der einzelnen Punkte zu der zugehörigen ausgleichenden Ebene. Diese Metrik kann anschaulich als durchschnittliche Wandstärke interpretiert werden.

Tabelle 5.3 zeigt die mittleren Punkt-zu-Ebene-Distanzen. Erneut erzielt die Merkmalsbasierte Selbstkalibrierung basierend auf der Sphärizität f_S , der Omnivarianz f_O , der Eigenentropie f_E und der Krümmungsänderung f_K bessere Resultate als die Objektbasierte Kalibrierung und die

Tabelle 5.2: Mediane der Entropie \bar{f}_{RQE} und der geometrischen 3D-Merkmale $\bar{f}_L, \dots, \bar{f}_K$ berechnet nach Durchführung der verschiedenen Kalibrierungen. VK bezeichnet die objektbasierte Vergleichskalibrierung und RQE die Entropiebasierte Selbstkalibrierung. Kleinere Werte bewerten die Punktwolke als besser. Der kleinste Wert in jeder Spalte ist fett dargestellt. \times : Kalibrierung fehlgeschlagen. Die Entropiebasierte Selbstkalibrierung führt zu höheren Werten als die objektbasierte Vergleichskalibrierung. Die Merkmalsbasierte Selbstkalibrierung basierend auf der Sphärizität f_S , der Omnivarianz f_O , der Eigenentropie f_E und der Krümmungsänderung f_K führt in allen Spalten zu kleineren Werten als die objektbasierte Vergleichskalibrierung und die Entropiebasierte Selbstkalibrierung. Insgesamt betrachtet, führt die Merkmalsbasierte Selbstkalibrierung unter Verwendung der Omnivarianz f_O zu den kleinsten Werten und somit zu den besten Ergebnissen.

Verfahren	\bar{f}_{RQE}	\bar{f}_L	\bar{f}_P	\bar{f}_S	\bar{f}_O	\bar{f}_E	\bar{f}_K
VK	0,161	0,842	0,389	0,215	0,275	0,734	0,106
RQE	0,205	0,845	0,450	0,268	0,288	0,787	0,129
f_L	\times	\times	\times	\times	\times	\times	\times
f_P	\times	\times	\times	\times	\times	\times	\times
f_S	0,092	0,826	0,281	0,087	0,217	0,546	0,047
f_O	0,082	0,830	0,264	0,072	0,205	0,514	0,039
f_E	0,088	0,828	0,271	0,079	0,211	0,529	0,042
f_K	0,095	0,826	0,283	0,090	0,220	0,552	0,048

Tabelle 5.3: Mittlere Punkt-zu-Ebene-Distanzen für planare Regionen der Punktwolke (in mm). \times : Kalibrierung fehlgeschlagen. VK bezeichnet die objektbasierte Vergleichskalibrierung, RQE die Entropiebasierte Selbstkalibrierung und $f_L - f_K$ die Merkmalsbasierte Selbstkalibrierung mit dem jeweiligen geometrischen 3D-Merkmal. Die beste Wert in jeder Spalte ist fett gedruckt.

Verfahren	Ebene 1	Ebene 2	Ebene 3	Ebene 4	Ebene 5	Ebene 6
VK	14,1	21,7	13,6	15,1	14,5	22,8
RQE	14,3	33,0	17,0	25,0	28,4	26,3
f_L	\times	\times	\times	\times	\times	\times
f_P	\times	\times	\times	\times	\times	\times
f_S	7,1	11,4	9,5	7,5	9,9	6,7
f_O	6,3	8,3	7,7	7,4	10,7	6,6
f_E	10,2	8,3	8,1	9,3	10,1	8,0
f_K	8,6	11,2	7,8	7,9	11,6	9,7

Entropiebasierte Selbstkalibrierung. Für fünf der sechs Ebenen erzielt die Merkmalsbasierte Selbstkalibrierung basierend auf der Omnivarianz f_O die kleinste mittlere Punkt-zu-Ebene-Distanz.

Kapitel 6.2 diskutiert die Ergebnisse der Experimente zur Eignung der verschiedenen Kostenfunktionen.

5.1.3 Konvergenzradius

Ausgleichungen benötigen gute Näherungswerte, damit die Kostenfunktion zum globalen Minimum konvergiert. Eine wichtige Frage in diesem Kontext ist, welche Genauigkeit die Näherungswerte haben müssen, bzw. wie groß der Konvergenzradius des Verfahrens ist. Je kleiner der Konvergenzradius ist, desto genauer müssen die Näherungswerte sein. Die Größe des Konvergenzradius ist von praktischer Relevanz, da sie darüber entscheidet, ob ein zusätzliches Verfahren eingesetzt werden muss, um die Näherungswerte zu bestimmen, oder ob eine grobe Abschätzung der Näherungswerte ausreichend ist.

Um den Konvergenzradius der Merkmalsbasierten Selbstkalibrierung zu bestimmen, werden Untersuchungen mit Näherungswerten mit variierender Genauigkeit mit dem synthetischen Indoor-Datensatz durchgeführt. Für diese Untersuchung werden die Posen und Distanzmessungen mit normalverteiltem Rauschen versehen. Die synthetischen Daten sind dadurch noch immer eine Vereinfachung der Realität. Dennoch lassen sich die Ergebnisse besser auf reale Multisensorsysteme übertragen. Die Posen sind in Anlehnung an einen Visual Inertial-SLAM




Abbildung 5.7: Ergebnisse der Merkmalsbasierten Selbstkalibrierung mit dem geometrischen 3D-Merkmal Omnivarianz in Abhängigkeit von der Genauigkeit der Näherungswerte der (a) relativen Translation Δd_0 und (b) relativen Rotation Δr_0 für den synthetischen Indoor-Datensatz. Für $\Delta d_0 \leq 2,2$ m bzw. $\Delta r_0 \leq 30^\circ$ liegen die Fehler nach Kalibrierung im Bereich von Submillimetern und Subgrad. Für größere Ungenauigkeiten der Näherungswerte steigen die Fehler nach Kalibrierung auf mehrere Meter und Grad.

auf dem Stand der Technik mit 2 cm und $0,1^\circ$ verrauscht (vgl. [36] ⁷). Die Distanzmessungen werden in Anlehnung an den 2D-Laserscanner, der beim kleinen Indoor-Datensatz zum Einsatz kommt, mit $\sigma = \pm 3$ cm verrauscht. Die Merkmalsbasierte Selbstkalibrierung verwendet für diese Untersuchungen das geometrische 3D-Merkmal Omnivarianz, da dieses Merkmal in den Untersuchungen die besten Ergebnisse liefert (vgl. Kapitel 5.1.2).

Abbildung 5.7 zeigt die Fehler nach Kalibrierung in Abhängigkeit der Genauigkeit der Näherungswerte. Die Fehler nach Kalibrierung sind dabei jeweils unterteilt in den Fehler der relativen Translation Δd auf der linken Ordinate und den Fehler der relativen Rotation Δr auf der rechten Ordinate.

Abbildung 5.7a zeigt den Fehler nach Kalibrierung in Abhängigkeit der Genauigkeit der Näherungswerte der relativen Translation Δd_0 . Für $\Delta d_0 \leq 2,2$ m liegt der Fehler nach Kalibrierung unter 1 mm und $0,01^\circ$. Für $\Delta d_0 > 2,2$ m steigen die Fehler nach Kalibrierung auf mehrere Meter und Grad.

Abbildung 5.7b zeigt den Fehler nach Kalibrierung in Abhängigkeit der Genauigkeit der Näherungswerte der relativen Rotation Δr_0 . Für $\Delta r_0 \leq 30^\circ$ liegt der Fehler nach Kalibrierung wieder unter 1 mm und $0,01^\circ$. Für $\Delta r_0 > 30^\circ$ vergrößert sich insbesondere der Fehler der relativen Rotation deutlich.

Eine Diskussion der Ergebnisse zur Untersuchung des Konvergenzradius erfolgt in Kapitel 6.3.

5.1.4 Vergleich zwischen Einzelskala- und Multiskalenverfahren

Die Untersuchungen in diesem Kapitel dienen dazu, die Aussagen aus Kapitel 3.3 hinsichtlich des Multiskalenverfahrens zu belegen. Sie ermöglichen den Vergleich zwischen der Merkmalsbasierten Selbstkalibrierung mit einer einzelnen Skala - im Folgenden als Einzelskalaverfahren bezeichnet - und dem Multiskalenverfahren hinsichtlich des Konvergenzradius und der Genauigkeit. Die Merkmalsbasierte Selbstkalibrierung verwendet auch hier das geometrische 3D-Merkmal Omnivarianz. Auch diesen Untersuchungen liegt der verrauschte synthetische Indoor-Datensatz zugrunde.

Abbildung 5.8 zeigt den Fehler der relativen Translation (Abbildung 5.8a) bzw. Rotation (Abbildung 5.8b) in Abhängigkeit von der Genauigkeit der Näherungswerte, die in die Merkmalsbasierte Selbstkalibrierung eingehen. Jeder Datenpunkt entspricht dem Median aus zehn Durchläufen mit unterschiedlichen räumlichen Erfassungen der gleichen Umgebung. Das feine Einzelskalaverfahren verwendet eine Skala, die fein genug ist, damit die Punktwolke eine gleichmäßigen Punktdichte aufweist, die allerdings noch möglichst nahe an der ursprünglichen Punktdichte der Rohdaten liegt. Die Skala des groben Einzelskalaverfahrens dagegen führt zu einer deutlichen geringeren Punktdichte gegenüber den Rohdaten. Das Multiskalenverfahren

⁷ Performante Hardware und kurze zurückgelegte Distanzen vorausgesetzt.

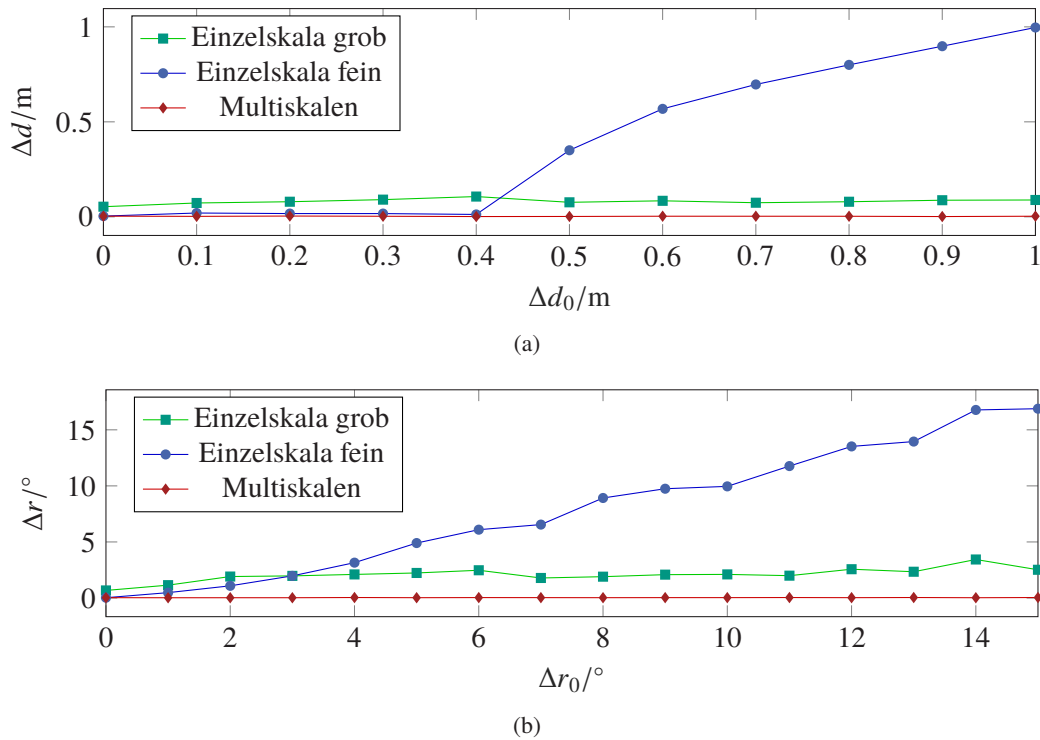


Abbildung 5.8: Vergleich der Einzelskalaverfahren mit dem Multiskalenverfahren. Die Abbildung zeigt den Fehler der relativen Orientierung nach der Kalibrierung in Abhängigkeit vom Fehler der Näherungswerte für die relative Orientierung. Die relative Orientierung ist aufgeteilt in die Komponenten relative Translation (5.8a) und relative Rotation (5.8b). Das Einzelskalaverfahren mit feiner Skala führt für kleine Fehler der Näherungswerte zu genaueren Ergebnissen als das Einzelskalaverfahren mit grober Skala. Allerdings weist das Einzelskalaverfahren mit grober Skala einen größeren Konvergenzbereich auf. Das Multiskalenverfahren kombiniert die Vorteile der beiden Einzelskalaverfahren und erzielt dadurch genaue Ergebnisse sowie einen großen Konvergenzbereich.

beginnt mit der Skala des groben Einzelskalaverfahrens und verfeinert sie in zwei Iterationen zu der Skala des feinen Einzelskalaverfahrens.

Abbildung 5.8 zeigt, dass das Einzelskalaverfahren mit feiner Skala für kleine Fehler in den Näherungswerten zu genaueren Ergebnissen führt als das Einzelskalaverfahren mit grober Skala. Allerdings ist der Konvergenzradius des Einzelskalaverfahrens mit grober Skala größer als der des Einzelskalaverfahrens mit feiner Skala. Dies zeigt sich daran, dass das Einzelskalaverfahren mit grober Skala für ungenaue Näherungswerte bessere Ergebnisse erzielt als das Einzelskalaverfahren mit feiner Skala. Das Multiskalenverfahren erzielt für alle getesteten Durchläufe die besten Ergebnisse, was die Aussagen aus Kapitel 3.3 hinsichtlich des Multiskalenverfahrens belegt.

5.2 Ergebnisse mit realen Daten

Im Folgenden werden die Ergebnisse gezeigt, die die Merkmalsbasierte Selbstkalibrierung mit realen Daten erzielt, beginnend mit dem kleinen Indoor-Datensatz (Kapitel 5.2.1) über den mittleren Outdoor-Datensatz (Kapitel 5.2.2) bis hin zum großen Outdoor-Datensatz (Kapitel 5.2.3). Die Diskussion dieser Ergebnisse erfolgt in Kapitel 6.5.

5.2.1 Kleiner Indoor-Datensatz

Abbildung 5.9 zeigt die Parameter der relativen Orientierung nach Kalibrierung mit der objektbasierten Kalibrierung, der Entropiebasierten Selbstkalibrierung und der Merkmalsbasierten Selbstkalibrierung basierend auf der Omnivarianz für den kleinen Indoor-Datensatz. Die Abbildung zeigt die sechs einzelnen Parameter der relativen Orientierung, sodass die Genauigkeit der Bestimmung jedes einzelnen Parameters sichtbar ist. Für die objektbasierte Vergleichskalibrierung ist nur ein einzelner Parametersatz verfügbar, sodass keine Aussagen über die Präzision des Verfahrens möglich sind. Die Präzision der Merkmalsbasierten Selbstkalibrierung basierend auf der Omnivarianz ist grundsätzlich höher als die der Entropiebasierten Selbstkalibrierung. Zudem unterscheiden sich die Ergebnisse der verschiedenen Kalibrierungen im Bereich von wenigen Zentimetern bzw. Grad. Insbesondere für den Parameter Θ (Abbildung 5.9d) liefern die Kalibrierungen Werte, die sich signifikant voneinander unterscheiden.

Die qualitativen Ergebnisse für den kleinen Indoor-Datensatz sind in Abbildung 5.5 und 5.6 dargestellt. Die linke Spalte in Abbildung 5.5 und 5.6 zeigt das Ergebnis der objektbasierten Kalibrierung, die auf UCalMiCeL basiert, wobei die Punktwolken mit dem jeweiligen geometrischen 3D-Merkmal eingefärbt sind. Die Ergebnisse der objektbasierten Kalibrierung und der Entropiebasierten Selbstkalibrierung sind visuell kaum voneinander zu unterscheiden. Das Ergebnis der Merkmalsbasierten Selbstkalibrierung mit dem Merkmal Omnivarianz ist dagegen besser, was sich in einer sichtbar schärferen Punktwolke ausdrückt.

5.2.2 Mittlerer Outdoor-Datensatz

Abbildung 5.10 zeigt die Parameter der relativen Orientierung nach Kalibrierung mit der Vergleichskalibrierung, der Entropiebasierten Selbstkalibrierung und der Merkmalsbasierten Selbstkalibrierung basierend auf der Omnivarianz für den mittleren Outdoor-Datensatz. Die Ergebnisse der drei Kalibrierverfahren liegen bis auf einen Zentimeter und weniger als ein Zehntelgrad sehr dicht beieinander. Einzig die Bestimmung der Höhenkoordinate durch die Entropiebasierte Selbstkalibrierung unterscheidet sich mit knapp fünf Zentimetern deutlicher von den anderen beiden Ergebnissen. Für alle Parameter bis auf Φ liegt das Ergebnis der Merkmalsbasierten Selbstkalibrierung näher an dem der Vergleichskalibrierung. Die Präzision

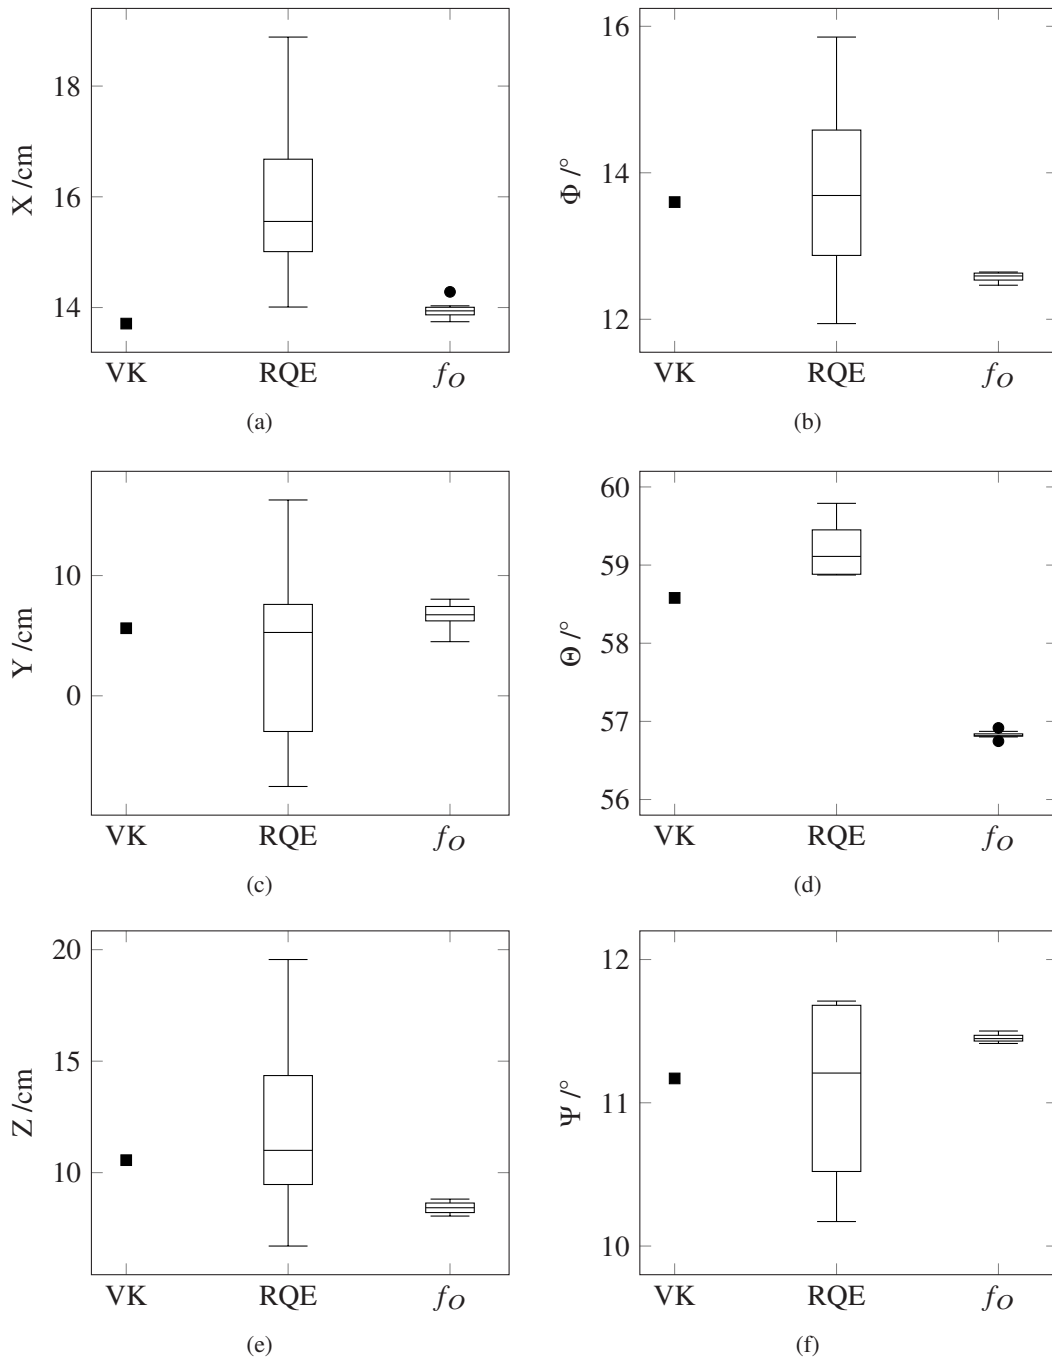


Abbildung 5.9: Parameter der relativen Orientierung nach Kalibrierung mit der objektbasierten Vergleichskalibrierung (VK) [79, 90], der Entropiebasierten Selbstkalibrierung (RQE) [124, 170] und der Merkmalsbasierten Selbstkalibrierung basierend auf der Omnivarianz f_o für den kleinen Indoor-Datensatz. Abbildungen (a),(c),(e) zeigen die Translationsparameter und Abbildungen (b),(d),(f) die Rotationsparameter. Die Ergebnisse der Verfahren unterscheiden sich zum Teil signifikant. Die Selbstkalibrierung basierend auf der Omnivarianz bestimmt alle Parameter mit höherer Präzision als die Entropiebasierte Selbstkalibrierung.

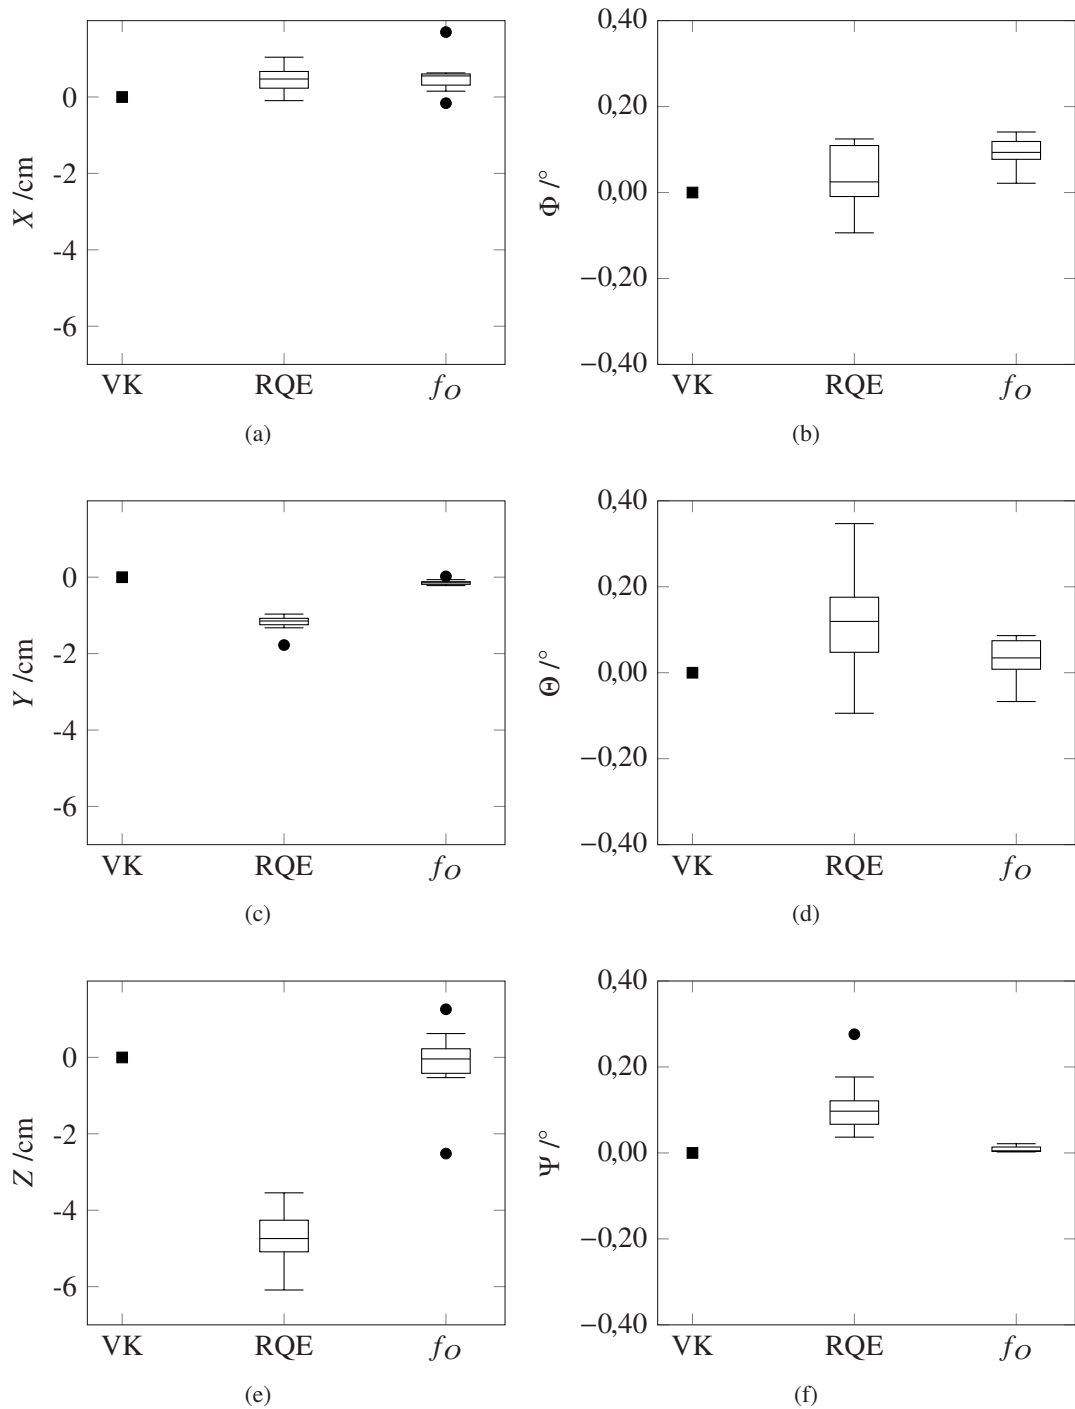


Abbildung 5.10: Parameter der relativen Orientierung nach Kalibrierung mit der Vergleichskalibrierung (VK) [55], der Entropiebasierten Selbstkalibrierung (RQE) [124, 170] und der Merkmalsbasierten Selbstkalibrierung basierend auf der Omnivarianz f_o für den mittleren Outdoor-Datensatz. Abbildungen (a), (c), (e) zeigen die Translationsparameter und Abbildungen (b), (d), (f) die Rotationsparameter. Die Ergebnisse der Verfahren unterscheiden sich kaum. Für alle Parameter bis auf Φ liegt das Ergebnis der Merkmalsbasierten Selbstkalibrierung näher an dem der Vergleichskalibrierung. Zudem ist die Präzision der Merkmalsbasierten Selbstkalibrierung insbesondere für die Bestimmung der Rotationsparameter höher, als die der Entropiebasierten Selbstkalibrierung.

der Merkmalsbasierten Selbstkalibrierung ist insbesondere für die Rotationsparameter höher, als die der Entropiebasierten Selbstkalibrierung. Visuell lassen sich die Ergebnisse der drei Kalibrierverfahren nicht voneinander unterscheiden, weswegen hier auf die Abbildung der qualitativen Ergebnisse verzichtet wird.

5.2.3 Großer Outdoor-Datensatz

Abbildung 5.11 visualisiert vier Punktwolken, die der qualitativen Evaluierung der Kalibrierergebnisse mit dem großen Outdoor-Datensatz dienen. Die Farbe jedes Punktes repräsentiert dabei seine vertikale Koordinate. Abbildung 5.11a zeigt einen Überblick der gesamten Punktwolke. Abbildung 5.11b–d zeigen die Punktwolken nach Kalibrierung mit den drei getesteten Verfahren. VK bezeichnet die objektbasierte Vergleichskalibrierung von [56] inklusive der manuellen Verfeinerung der Kalibrierung [59], RQE die Entropiebasierten Selbstkalibrierung [124, 170] und f_O die Merkmalsbasierte Selbstkalibrierung mit dem geometrischen 3D-Merkmal Omnivarianz.

Die Merkmalsbasierte Selbstkalibrierung basierend auf dem geometrischen 3D-Merkmal Omnivarianz führt zu visuell ähnlichen Ergebnissen wie die objektbasierte Vergleichskalibrierung. Die Entropiebasierte Selbstkalibrierung hingegen führt zu einer verrauschten Punktwolke, was insbesondere an der Wand links zu erkennen ist, sowie zu Artefakten, die neben den zwei Fahrzeugen am rechten Fahrbahnrand zu sehen sind. Prinzipiell sind die Qualitätsunterschiede anhand der visuellen Überprüfung allerdings schwer festzustellen. Aus diesem Grund werden im Folgenden erneut die weiteren quantitative Evaluierungsmetriken herangezogen.

Tabelle 5.4 stellt die mittleren Punkt-zu-Ebene-Distanzen für unterschiedliche Regionen der Punktwolke dar. Ebenen 1–3 sind Ausschnitte aus der Straßenebene und Ebenen 4–6 sind Ausschnitte von Wänden verschiedener Gebäude.

Die Unterschiede zwischen den mittleren Punkt-zu-Ebene-Distanzen der verschiedenen Ergebnisse sind im Bereich von wenigen Zentimetern für die meisten Ebenen. Für drei der sechs Ebenen liefert die objektbasierte Vergleichskalibrierung die besten Ergebnisse, für die anderen drei Ebenen die Merkmalsbasierte Selbstkalibrierung. Die Entropiebasierte Selbstkalibrierung führt für alle getesteten Ebenen mit Ausnahme von Ebene 4 zu den schlechtesten Ergebnissen. Diese Ergebnisse unterstützen den visuellen Eindruck aus Abbildung 5.11, dass die Ergebnisse der objektbasierten Vergleichskalibrierung und der Merkmalsbasierten Selbstkalibrierung ähnliche Qualitäten haben, die Qualität der Entropiebasierten Selbstkalibrierung jedoch geringer ausfällt.

Abschließend zeigt Abbildung 5.12 die Parameter der relativen Orientierung nach Kalibrierung mit den drei Verfahren für den großen Outdoor-Datensatz. Abbildungen 5.12a, 5.12c und 5.12e zeigen die Parameter der relativen Translation und Abbildungen 5.12b, 5.12d und 5.12f die Parameter der relativen Rotation. Für die Interpretation der Qualität der Ergebnisse ist die




Abbildung 5.11: Qualitative Ergebnisse für den großen Outdoor-Datensatz. Die Farbe jedes Punktes visualisiert dessen vertikale Koordinate dar und dient nur zu Visualisierungszwecken. Die Merkmalsbasierte Selbstkalibrierung basierend auf dem Merkmal Omnivarianz f_O führt zu visuell ähnlichen Ergebnissen, wie die Vergleichskalibrierung (VK) [56, 59]. Die Entropiebasierte Selbstkalibrierung (RQE) [124, 170] hingegen führt zu einer verrauschten Punktwolke, was insbesondere an der Wand links zu erkennen ist, sowie zu Artefakten, die neben den zwei Fahrzeugen am rechten Fahrbahnrand zu sehen sind.

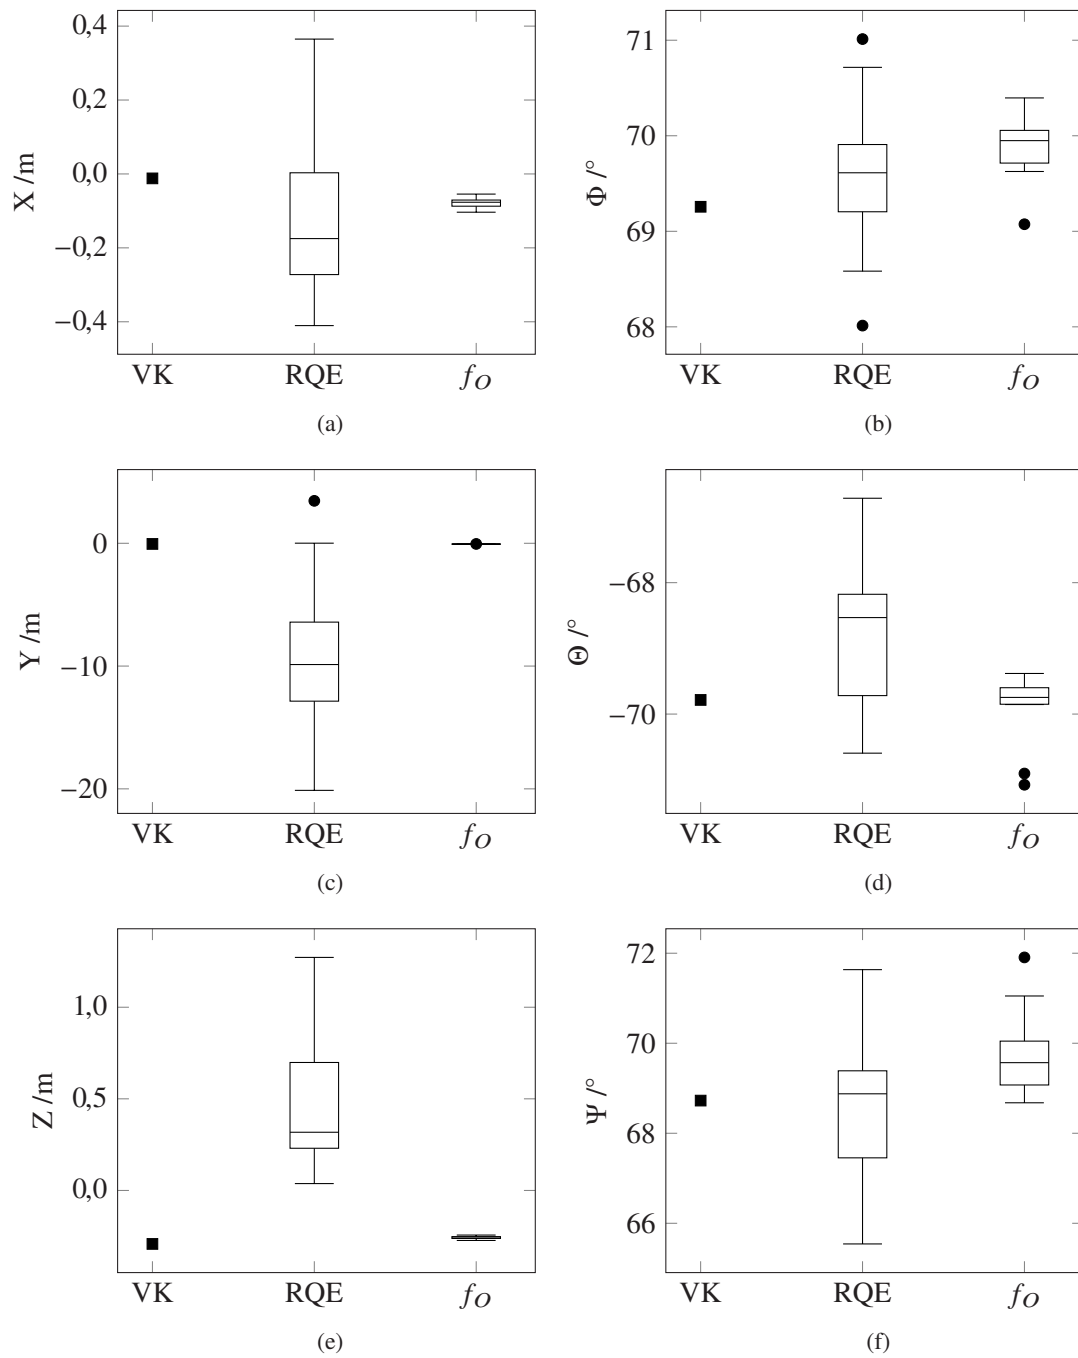


Abbildung 5.12: Parameter der relativen Orientierung nach Kalibrierung mit der objektbasierten Vergleichskalibrierung (VK) [56, 59], der Entropiebasierten Selbstkalibrierung (RQE) [124, 170] und der Merkmalsbasierten Selbstkalibrierung basierend auf dem geometrischen 3D-Merkmal Omnivarianz f_o für den großen Outdoor-Datensatz. Die Bestimmung der vertikalen Komponente (hier Y) der relativen Translation schlägt für die Entropiebasierte Selbstkalibrierung fehl. Die Ergebnisse der Merkmalsbasierten Selbstkalibrierung sind näher an denen der objektbasierten Vergleichskalibrierung und weisen eine höhere Präzision auf, als die Ergebnisse der Entropiebasierten Selbstkalibrierung.

Tabelle 5.4: Mittlere Punkt-zu-Ebene-Distanzen für verschiedene Regionen der Punktwolke des großen Outdoor-Datensatzes (in cm). Die besten Werte jeder Spalte sind fett dargestellt. VK bezeichnet die objektbasierte Vergleichskalibrierung für den großen Outdoor-Datensatz [56, 59], RQE die Entropiebasierte Selbstkalibrierung [124, 170] und f_O die Merkmalsbasierte Selbstkalibrierung mit dem geometrischen 3D-Merkmal Omnivarianz. Ebenen 1–3 sind Ausschnitte aus der Straßenebene und Ebenen 4–6 sind Ausschnitte von Wänden verschiedener Gebäude.

Verfahren	Ebene 1	Ebene 2	Ebene 3	Ebene 4	Ebene 5	Ebene 6
VK	5,4	3,0	5,4	8,3	8,2	16,4
RQE	11,4	10,3	7,9	8,6	10,0	23,1
f_O	5,0	4,5	4,1	8,7	9,4	13,3

Ausrichtung der Koordinatensysteme relevant. In diesem Datensatz zeigt die X-Achse des Koordinatensystems der Navigationseinheit nach rechts, die Y-Achse nach unten und die Z-Achse nach vorne. Beim Koordinatensystem des Laserscanners zeigt die X-Achse nach links, die Y-Achse nach oben und die Z-Achse nach vorne.

Die Bestimmung der vertikalen Komponente (hier Y) der relativen Translation schlägt für die Entropiebasierte Selbstkalibrierung fehl, der Fehler gegenüber der objektbasierten Vergleichskalibrierung beträgt ca. 10 m. Trotzdem sind Objekte wie Autos in der Punktwolke in Abbildung 5.11c erkennbar. Der Grund dafür ist, dass ein Fehler in der vertikalen Komponente der relativen Translation die gesamte Punktwolke um die Größe des Fehlers in vertikaler Richtung verschiebt. Dadurch ändert sich jedoch nicht die relative Lage der Punkte zueinander und damit auch nicht der Wert der Entropie für die Punktwolke (vgl. Kapitel 5.1.1). Dieser Sachverhalt wird in Kapitel 6.5.1 weiterführend diskutiert. Die Ergebnisse der Merkmalsbasierten Selbstkalibrierung sind näher an denen der Vergleichskalibrierung und weisen eine höhere Präzision auf als die Ergebnisse der Entropiebasierten Selbstkalibrierung.

Die Mediane zweier Parameter der relativen Rotation, Φ und Ψ , liegen für die Entropiebasierte Selbstkalibrierung mit weniger als 1° näher an der Lösung der objektbasierten Vergleichskalibrierung als für die Merkmalsbasierte Selbstkalibrierung. Da das Ergebnis der Entropiebasierten Selbstkalibrierung allerdings eine deutlich niedrigere Präzision aufweist als das der Merkmalsbasierten Selbstkalibrierung, hat eine einzelne Kalibrierung mit hoher Wahrscheinlichkeit eine niedrigere Genauigkeit.

5.3 Über die sechs Parameter der relativen Orientierung hinaus

Bei den bisherigen Experimenten wurden stets die sechs Parameter der relativen Orientierung bestimmt. Die Methodik der Merkmalsbasierten Selbstkalibrierung ist jedoch prinzipiell dafür geeignet, systematische Fehler zu bestimmen, die sich auf die Punktwolke auswirken (vgl.

Tabelle 1.1). Um diese prinzipielle Eignung zu testen, beschäftigt sich dieses Kapitel daher stellvertretend mit der Bestimmung eines konstanten Skalierungsfaktors für die Posen. Ein solcher Skalierungsfaktor sollte dann bestimmt werden, wenn die Posen des Posenbestimmungssensors nur bis auf eine unbekannte Skalierung bestimmt wurden. Dies ist beispielsweise dann der Fall, wenn zur Posenbestimmung eine einzelne Kamera und ein Odometrie- oder SLAM-Verfahren eingesetzt wird (vgl. Kapitel 2.4.3). In diesem Fall dienen die metrischen Messungen eines Laserscanners nicht nur der räumlichen Erfassung der Umgebung, sondern zusätzlich dazu, die Posen des Posenbestimmungssensors metrisch zu skalieren.

Für diese Experimente wurde die Merkmalsbasierte Selbstkalibrierung so modifiziert, dass statt der sechs Parameter der relativen Orientierung ein konstanter Skalierungsfaktor für die Posen bestimmt wird. Die Änderungen an der Methodik werden dafür an der vereinfachten Kostenfunktion aus Gleichung 3.9 erläutert:

Sei \mathbf{M}'_i die i -te unskalierte Pose eines Posenbestimmungssensors, wobei $i = 1, \dots, N$ und N der Anzahl der Posen entspricht. Diese unskalierte Pose lässt sich auch durch eine Rotationsmatrix \mathbf{R}_i und einen unskalierten Translationsvektor \mathbf{t}'_i ausdrücken, sodass

$$\mathbf{M}'_i = \begin{bmatrix} \mathbf{R}_i & \mathbf{t}'_i \\ \mathbf{0}^T & 1 \end{bmatrix} \quad (5.1)$$

gilt. Die skalierte Pose \mathbf{M}_i lässt sich durch

$$\mathbf{M}_i = \begin{bmatrix} \mathbf{R}_i & S \mathbf{t}'_i \\ \mathbf{0}^T & 1 \end{bmatrix} \quad (5.2)$$

darstellen, wobei die gesamte Pose skaliert wird, indem der Translationsvektor mit dem Skalierungsfaktor S multipliziert wird. Dann lässt sich die angepasste Kostenfunktion durch

$$K(S | \mathbf{R}, \mathbf{t}', \mathbf{C}, h(\mathbf{z})) = s(\mathcal{F}) \sum_{i=1}^N (f_{\mathcal{F},i}(g(\begin{bmatrix} \mathbf{R}_i & S \mathbf{t}'_i \\ \mathbf{0}^T & 1 \end{bmatrix}, \mathbf{C}, h(\mathbf{z}_i)), \mathcal{N}_i))^2 \quad (5.3)$$

ausdrücken.

Die zugehörigen Experimente wurden auf Untermengen des kleinen Indoor-Datensatzes durchgeführt, wobei für die Kostenfunktion wieder das Merkmal Omnivarianz gewählt wurde. Abbildung 5.13 zeigt exemplarisch ein qualitatives Ergebnis dieser Experimente. Abbildung 5.13a zeigt die Punktwolke bei einem fehlerhaften Skalierungsfaktor von $S = 2$. Dieser systematische Fehler der Posen sorgt für eine verzerrte Punktwolke. Abbildung 5.13b zeigt die entsprechende Punktwolke nach Korrektur des Skalierungsfaktors durch die beschriebene Methodik, die auf der Merkmalsbasierten Selbstkalibrierung basiert. Die korrigierte Punktwolke ist deutlich schärfer und die Geometrie des Raumes ist gut zu erkennen.

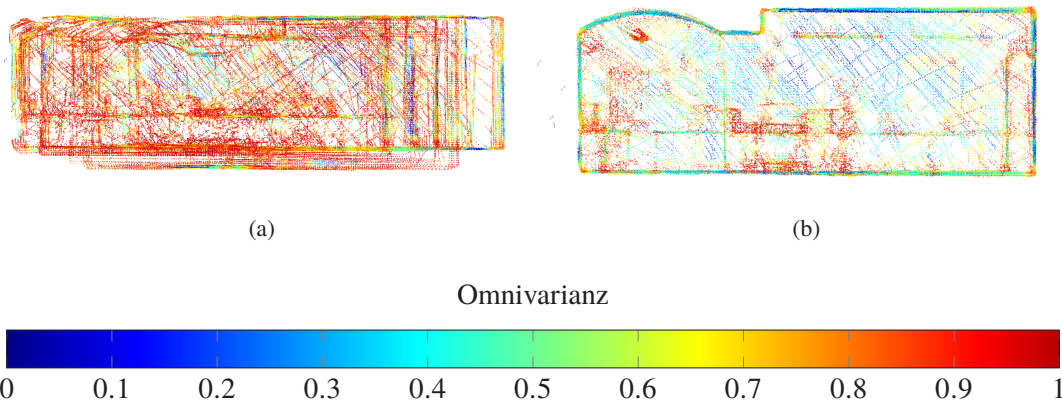


Abbildung 5.13: Qualitative Ergebnisse der Bestimmung des Skalierungsfaktors. (a) Punktwolke bei einem fehlerhaften Skalierungsfaktor von $S = 2$, (b) Entsprechende Punktwolke nach Korrektur des Skalierungsfaktors. Die korrigierte Punktwolke ist deutlich sichtbar schärfer.

Abbildung 5.14 zeigt die bestimmten Skalierungsfaktoren in Prozent aus jeweils 10 Durchläufen mit verschiedenen Untermengen des kleinen Indoor-Datensatzes. Die Posen wurden dabei um konstante Faktoren von $\tilde{S} = 1/30$, $\tilde{S} = 1/20$, $\tilde{S} = 1/10$, $\tilde{S} = 1$, $\tilde{S} = 2$, $\tilde{S} = 3$ skaliert. Diese Werte entsprechen in Abbildung 5.14 jeweils 100 % und sind durch die gestrichelte Linie dargestellt. Der Näherungswert für den Skalierungsfaktor S_0 liegt stets bei $S_0 = 1$.

Der Median der bestimmten Skalierungsfaktoren hat für alle getesteten fehlerhaften Skalierungsfaktoren eine Genauigkeit von über 99.5 %. Er ist jedoch tendenziell immer kleiner als der wahre Skalierungsfaktor. Dies gilt auch für den Fall $\tilde{S} = 1$, bei dem der Näherungswert bereits dem optimalen Skalierungsfaktor entspricht. Um auszuschließen, dass der zugrunde liegende kleine Indoor-Datensatz und nicht die Methodik diese Systematik verursacht, wurde das Experiment ein weiteres Mal mit dem synthetischen Indoor-Datensatz durchgeführt. Diese Ergebnisse enthalten keine systematische Unterschätzung des Skalierungsfaktors.

Für sehr große vorgegebene Skalierungsfaktoren schlägt die Bestimmung des Skalierungsfaktors jedoch fehl. Abbildung 5.15 visualisiert die Punktwolke bei einem fehlerhaften Skalierungsfaktor von $S = 20$.

Die einzelnen Scanzeilen sind in diesem Fall voneinander separiert. Die nächsten Nachbarn, die zur Bestimmung der Omnivarianz herangezogen werden, stammen dadurch überwiegend aus der selben Scanzeile. Eine Veränderung des Skalierungsfaktors wirkt sich jedoch nicht auf eine Veränderung innerhalb einer Scanzeile aus. Für die Kleinste-Quadrate-Ausgleichung bedeutet dies, dass die Ableitung der Kostenfunktion nach dem Skalierungsfaktor konstant ist. Das wiederum bedeutet, dass die Näherungslösung einem lokalen Minimum entspricht und somit keine Änderungen des Skalierungsfaktors durchgeführt werden. Das Fehlschlagen bei sehr großen fehlerhaften Skalierungsfaktoren ist somit plausibel.




Abbildung 5.14: Bestimmte Skalierungsfaktoren in Prozent. 100 % entsprechen jeweils dem wahren Skalierungsfaktor \tilde{S} . Der initiale Skalierungsfaktor S_0 beträgt für alle Experimente 1. Das Ergebnis wird für alle getesteten Skalierungsfaktoren mit einer Genauigkeit von über 99.5 % bestimmt. Das Ergebnis ist jedoch tendenziell immer kleiner, als der wahre Skalierungsfaktor.

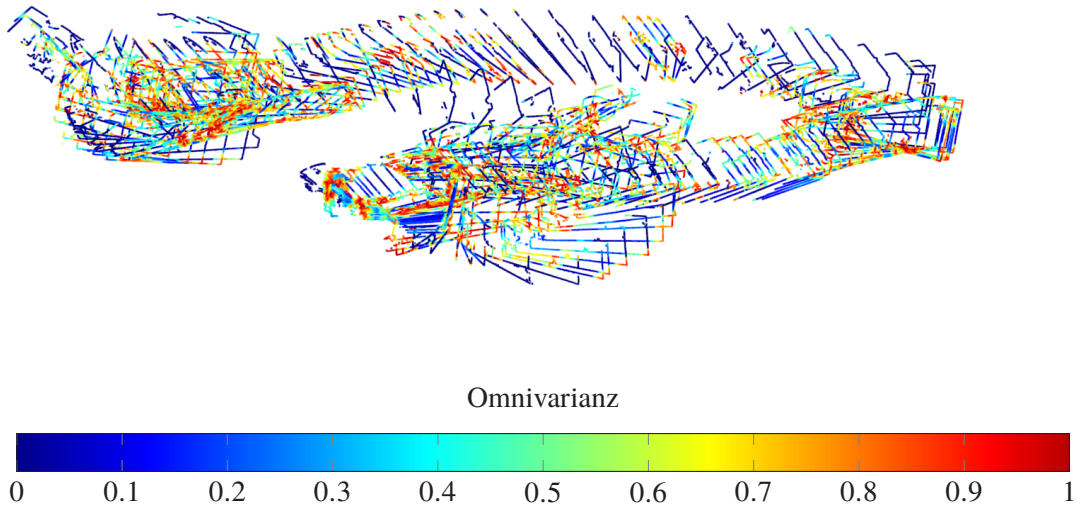


Abbildung 5.15: Punktwolke bei einem Skalierungsfaktor von $S = 20$.

6 Diskussion

In diesem Kapitel werden die Ergebnisse der Experimente in der selben Reihenfolge wie in Kapitel 5 beschrieben. Das Kapitel beginnt demzufolge mit der Diskussion der Untersuchungen der Selbstkalibrierung (Kapitel 6.1–6.4). Anschließend werden die Ergebnisse diskutiert, die die Merkmalsbasierte Selbstkalibrierung mit realen Daten erzielt.

6.1 Einfluss der Posen

Die Experimente mit verschiedenen Trajektorien zeigen, dass die Posen einen signifikanten Einfluss auf das Ergebnis der Kalibrierung haben. Die Ergebnisse variieren bis zu einigen Dezimetern und mehreren Grad. Da die Kalibrierungen mit der unidirektionalen und der orthodirektionalen Trajektorie die Näherungswerte zum Teil verschlechtern, sind diese Trajektorien für die Bestimmung aller sechs Parameter der relativen Orientierung ungeeignet. Demzufolge ist es für die Kalibrierung nicht ausreichend, die Umgebung aus einer einzelnen Bewegungsrichtung zu erfassen, auch wenn die Trajektorie Kurven enthält. Mit der bi- und der multidirektionalen Trajektorie werden deutlich bessere Kalibrierergebnisse erzielt, wobei die multidirektionale Trajektorie insbesondere bei den Rotationsparametern noch geringere Abweichungen zur Vergleichskalibrierung aufweist.

Die bidirektionale Trajektorie erfüllt einen großen Teil der Forderungen für eine optimale Bewegungskonfiguration, die in den theoretischen Betrachtungen in Kapitel 5.1.1 angegeben sind. Die Anzahl der Posen ist für diese Trajektorie geringer, als für die anderen Trajektorien. Demzufolge ist nicht die Anzahl der Posen entscheidend, sondern deren Konfiguration. Die Hinzunahme von weiteren Posen für die Kalibrierung bewirkt nicht unbedingt eine Verbesserung, es sei denn diese Posen liefern weitere geometrische Bedingungen für die Kalibrierung. Daneben ist die Berechnungsdauer der Kalibrierung mit der bidirektionalen Trajektorie am kürzesten, da am wenigsten Daten verarbeitet werden. Daraus lässt sich schließen, dass wenige Posen mit günstiger Konfiguration ein besseres Ergebnis liefern als eine hohe Anzahl zufälliger Posen.

Die multidirektionale Trajektorie liefert nochmals bessere Ergebnisse im Vergleich zur bidirektionalen Trajektorie. Dies gilt insbesondere für die Parameter der relativen Rotation. Der wesentliche Unterschied zwischen der bi- und der multidirektionalen Trajektorie ist, dass die multidirektionale Trajektorie deutlich mehr Variationen des Gierwinkels durch Kurvenfahr-

ten enthält. Eine hohe Variation des Gierwinkels ist somit für eine genaue Bestimmung der Parameter der relativen Rotation vorteilhaft.

Auffällig sind die hohen Wiederholgenauigkeiten aber die gleichzeitig großen Fehler gegenüber der Vergleichskalibrierung bei der Bestimmung der Rotationsparameter mit der uni- und der orthodirektionalen Trajektorie. Die Kalibrierung liefert wiederholt Ergebnisse für den Roll- und den Nickwinkel, die nahe bei den Näherungswerten von 3° liegen, und Werte nahe bei 2° für den Gierwinkel. Diese Ergebnisse lassen darauf schließen, dass die Kostenfunktion der Kleinste-Quadrate-Ausgleichung der Entropiebasierten Selbstkalibrierung bei diesen Trajektorien ein lokales Minimum in diesem Bereich aufweist. Die zugrundeliegenden Posen liefern nicht genügend geometrische Bedingungen, sodass Änderungen der Rotationsparameter nicht zu einer Verkleinerung des Wertes der Kostenfunktion führen. Diese Ergebnisse zeigen deutlich, dass es bei der Evaluierung nicht ausreicht, die Wiederholgenauigkeit des Verfahrens zu betrachten. Stattdessen müssen die Ergebnisse mit weiteren Metriken bzw. mit einem Vergleich zum Ergebnis anderer Kalibrierverfahren evaluiert werden. In der Praxis liegen häufig keine Ergebnisse von Vergleichsverfahren mit übergeordneter Genauigkeit vor. In diesen Fällen kann die Genauigkeit an Kontrollpunkten, die mit übergeordneter Genauigkeit eingemessen wurden [33], oder mittlere Punkt-zu-Ebene-Distanzen in der Punktwolke betrachtet werden [174].

An den Ergebnissen fällt auch auf, dass alle drei Parameter der relativen Translation mit der bi- und der multidirektionalen Trajektorie bestimmbar sind, obwohl kein zusätzliches Wissen über vertikale Abstände der Objekte vom Posenbestimmungssensor eingeführt wurde (vgl. Kapitel 5.1.1). Der potentielle Grund dafür, dass die Bestimmung der vertikalen Komponente entgegen der theoretischen Betrachtungen in Kapitel 5.1.1 funktioniert, liegt in der Sensorkonfiguration des Mobile Mapping Systems beim mittleren Outdoor-Datensatz. Wie in Kapitel 4 beschrieben, ist der Laserscanner unter einem Nickwinkel von 45° nach vorne auf dem Dach eines Kleinbusses montiert. Dadurch erfolgt die Bewegung des Fahrzeugs nicht in Richtung einer der Koordinatenachsen des Laserscanners, sondern unter einem Winkel von 45° gegenüber der Koordinatenachse. Ungenauigkeiten bei der Bestimmung der vertikalen Komponente verteilen sich aus diesem Grund anteilig auf alle Parameter der relativen Translation. Die Genauigkeit des Parameters mit dem größten vertikalen Anteil (hier Z) ist infolgedessen geringer als die Genauigkeit der anderen beiden Parameter der relativen Translation.

6.2 Eignung der verschiedenen Kostenfunktionen

Die Experimente in Kapitel 5.1.2 zeigen grundsätzlich, dass die Ergebnisse der Merkmalsbasierten Selbstkalibrierung von der Wahl der Kostenfunktion abhängen. Die Merkmalsbasierte Selbstkalibrierung ist mit vier der sechs getesteten geometrischen 3D-Merkmalen in der Lage, Näherungswerte der relativen Orientierung zu verbessern. Das Merkmal Linearität vergrößert den Fehler der relativen Orientierung. Gleiches zeigt sich für das Merkmal Planarität im Fall von

realen Daten. Diese beiden Merkmale sind somit ungeeignet für die Merkmalsbasierte Selbstkalibrierung. Die Merkmale Sphärizität, Omnivarianz, Eigenentropie und Krümmungsänderung eignen sich dagegen für die Merkmalsbasierte Selbstkalibrierung, da diese Kalibrierungen die Näherungswerte signifikant verbessern. Die Merkmalsbasierte Selbstkalibrierung mit diesen vier Merkmalen liefert zudem bessere Resultate als die Entropiebasierte Selbstkalibrierung, was sich sowohl bei synthetischen als auch bei realen Daten zeigt. Das Merkmal Omnivarianz führt zu den besten Ergebnissen, was mittels dreier quantitativer Evaluierungsmetriken und einer qualitativen Evaluierung nachgewiesen werden konnte. Die Omnivarianz wird daher im Folgenden nochmals detailliert diskutiert.

Die Omnivarianz ist klein, wenn mindestens einer der Eigenwerte klein ist. Das bedeutet, dass die Omnivarianz für lineare und planare Strukturen sowie für isolierte Punkte klein ist. Im Gegensatz dazu führen drei große Eigenwerte zu einer großen Omnivarianz. Das bedeutet, dass die Omnivarianz für volumetrische Strukturen, die eine große Ausdehnung in alle Richtungen aufweisen, groß ist. Die Omnivarianz repräsentiert das Volumen eines Ellipsoids, das die Struktur approximiert und ist damit ein Maß für die lokale Kompaktheit der Punkte. Die Minimierung der Omnivarianz bedeutet eine Minimierung des Volumens dieses Ellipsoids, was gleichbedeutend mit der Maximierung der lokalen Kompaktheit ist. Das Volumen eines Ellipsoids lässt sich am schnellsten minimieren, indem die kleinste Halbachse des Ellipsoids verkleinert wird. Eine Minimierung der Omnivarianz führt also bei einer linearen Struktur dazu, dass diese noch linearer wird, bei einer planaren Struktur, dass diese noch planarer wird und bei einer volumetrischen Struktur, dass die Punkte zunächst entlang der kleinsten Halbachse zusammenrücken, sodass das Volumen am schnellsten sinkt. Zusammengefasst tritt durch die Minimierung der Omnivarianz die zugrundeliegende Struktur noch deutlicher hervor, unabhängig davon, welche geometrische Form diese Struktur hat.

Die Omnivarianz ist somit für beliebige geometrische Formen und damit für beliebige Umgebungen geeignet. Mit anderen Worten führt die Verwendung der Omnivarianz im Kontext einer Selbstkalibrierung zu einem rein datenbasierten Ansatz, der keinerlei Modellannahmen bzgl. der Geometrie der Umgebung trifft.

Dennoch kann die Umgebung einen Einfluss auf das Ergebnis der Merkmalsbasierten Selbstkalibrierung haben. Bei der Merkmalsbasierten Selbstkalibrierung handelt es sich um ein gradientenbasiertes Verfahren. Dabei werden die Parameter der relativen Orientierung iterativ so verändert, dass der Wert der Kostenfunktion sinkt. Im Falle, dass die Umgebung überwiegend aus volumetrischen Strukturen besteht, wie beispielsweise in einer Umgebung mit dichter Vegetation, ist anzunehmen, dass die Kostenfunktion viele lokale Minima aufweist. Eine solche Umgebung könnte demzufolge eine besondere Herausforderung für die Merkmalsbasierte Selbstkalibrierung darstellen. Allerdings zeigen die Experimente mit insgesamt drei verschiedenen Datensätzen mit unterschiedlichen Charakteristiken die vielseitige Einsetzbarkeit der Merkmalsbasierten Selbstkalibrierung mit dem Merkmal Omnivarianz.

Ein weiterer potentieller Grund dafür, dass die Omnivarianz die Ergebnisse der anderen geometrischen 3D-Merkmale übertrifft, ist die höhere Robustheit dieses Merkmals gegenüber verrauschten Punktwolken [38].

Die Entropiebasierte Selbstkalibrierung [124, 170] ist verglichen mit der Merkmalsbasierten Selbstkalibrierung mit dem Merkmal Omnivarianz ungenauer und unpräziser. Zur Interpretation sei die Kostenfunktion der Entropiebasierten Selbstkalibrierung hier wiederholt:

$$f_{RQE}(\mathbf{C} | \mathbf{M}, \mathbf{z}) = - \frac{1}{(2\pi\sigma^2)^{3/2}} \sum_{i=1}^N \sum_{j=1}^N \exp \left\{ - \frac{\|g(\mathbf{M}_i, \mathbf{C}, h(\mathbf{z}_i)) - g(\mathbf{M}_j, \mathbf{C}, h(\mathbf{z}_j))\|^2}{2\sigma^2} \right\}. \quad (6.1)$$

Hierbei sind $g(\mathbf{M}_i, \mathbf{C}, h(\mathbf{z}_i)), g(\mathbf{M}_j, \mathbf{C}, h(\mathbf{z}_j)) \in \mathbb{R}^3$ Punkte der Punktwolke, N ist die Anzahl der Punkte und σ ist die zu erwartende Standardabweichung eines 3D-Punktes, die als a-priori Wissen in das Verfahren eingeführt wird. Da die Entropiebasierte Selbstkalibrierung für σ in der Praxis einen konstanten Wert verwendet, ist der Term $1/(2\pi\sigma^2)^{3/2}$ konstant und dadurch für die Optimierung vernachlässigbar. Die Basis für die Kostenfunktion bilden demnach paarweise Koordinatendifferenzen $g(\mathbf{M}_i, \mathbf{C}, h(\mathbf{z}_i)) - g(\mathbf{M}_j, \mathbf{C}, h(\mathbf{z}_j))$. Die quadrierte L2-Norm dieser Koordinatendifferenzen entspricht der quadrierten euklidischen Distanz zwischen diesen Punkten. Die Exponentialfunktion kann als Gewichtung dieser Distanzen interpretiert werden. Das Argument der Exponentialfunktion ist immer negativ, da sowohl die quadrierten euklidischen Distanzen, als auch der Nenner $2\sigma^2$ immer größer null sind. Dadurch ergibt sich für eine euklidische Distanz zwischen zwei Punkten von Null der maximale Wert von Eins für die Exponentialfunktion. Je größer die euklidische Distanz zwischen zwei Punkten ist, desto stärker wird der Einfluss der Punkte heruntergewichtet und desto kleiner ist der Beitrag zur gesamten Kostenfunktion. Die Gewichtung kann demzufolge auch als kontinuierliche Form der Nachbarschaft interpretiert werden. Die Kostenfunktion wird durch die negative Summe über alle gewichteten paarweisen Punktdistanzen gebildet.

Eine Minimierung der Kostenfunktion der Entropiebasierten Selbstkalibrierung bewirkt, dass alle Punkte näher zusammenrücken. Dies gilt unabhängig von der zugrundeliegenden Geometrie der Punktwolke. Für den Fall, dass die zugrundeliegende Geometrie beispielsweise eine Ebene ist, versucht die Entropiebasierte Selbstkalibrierung, die Punkte näher zusammen zu bringen. Dies ist allerdings nicht zwangsläufig zielführend, da die Abstände innerhalb dieser Ebene durch die Abtastung mit dem Laserscanner bedingt sein können und nicht durch eine fehlerhafte relative Orientierung. In diesem Fall würde die Entropiebasierte Selbstkalibrierung die Parameter der relativen Orientierung verändern, obwohl die Punktwolke die reale Umgebung bereits optimal approximiert. Dies ist ein wesentlicher Unterschied zur Merkmalsbasierten Selbstkalibrierung mit dem Merkmal Omnivarianz und ein möglicher Grund dafür, dass die Entropiebasierte Selbstkalibrierung ungenauere Ergebnisse liefert als die Merkmalsbasierte Selbstkalibrierung.

6.3 Konvergenzradius

Die Größe des Konvergenzradius ist von praktischer Relevanz, da diese darüber entscheidet, ob ein zusätzliches Verfahren zur Bestimmung der Näherungswerte eingesetzt werden muss, oder ob es ausreichend ist, die Näherungswerte grob abzuschätzen. Abbildung 5.7 zeigt, dass der Konvergenzradius der Merkmalsbasierten Selbstkalibrierung für den simulierten Datensatz mehr als 2 m und 30° beträgt. Das bedeutet, dass die Merkmalsbasierten Selbstkalibrierung auch bei einer Abweichung von zwei Metern von der wahren Distanz und von 30° vom wahren Raumwinkel zwischen den beiden Sensoren noch optimale Parameter der relativen Orientierung bestimmt.

Zur Veranschaulichung eines entsprechenden Fehlers der Näherungswerte, zeigt Abbildung 6.1 die zugehörigen Punktwolken in der Schrägsicht (a, b, c) bzw. in der Seitenansicht (d, e, f). Obwohl die tatsächliche Geometrie der Punktwolke in Abbildung 6.1b, c, e und f aufgrund der großen Fehler der Näherungswerte nur schwer zu errahnen ist, bestimmt die Merkmalsbasierte Selbstkalibrierung die Parameter der relativen Orientierung mit hoher Genauigkeit (vgl. Abbildung 5.7).

Die Merkmalsbasierte Selbstkalibrierung ist somit robust gegenüber großen Fehlern der Näherungswerte. Für die meisten operativen Sensorsysteme ist es demzufolge ausreichend, die Näherungswerte grob abzuschätzen oder mit einfachen Mitteln wie beispielsweise einem Zoll-

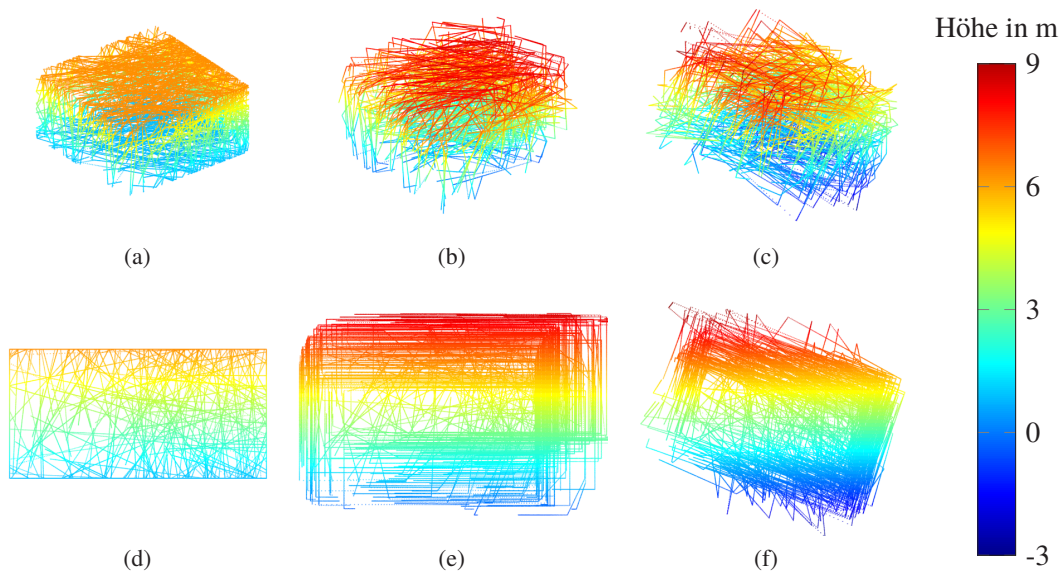


Abbildung 6.1: Schräg- und Seitenansicht dreier Punktwolken aus den Untersuchungen zum Konvergenzradius. (a) Schrägsicht fehlerfrei, (b) Schrägsicht mit $\Delta d_0 = 2,2$ m, (c) Schrägsicht mit $\Delta r_0 = 30^\circ$, (d) Seitenansicht fehlerfrei, (e) Seitenansicht mit $\Delta d_0 = 2,2$ m, (f) Seitenansicht mit $\Delta r_0 = 30^\circ$.

stock auszumessen. Des Weiteren besteht die Möglichkeit basierend auf der Visualisierung der Punktwolke ausreichend genaue Näherungswerte manuell zu ermitteln.

6.4 Vergleich zwischen Einzelskala- und Multiskalenverfahren

Die Experimente in Kapitel 5.1.4 evaluieren das Multiskalenverfahren gegenüber einem Einzelskalaverfahren mit grober und einem mit feiner Skala hinsichtlich der Genauigkeit und des Konvergenzradius. Die Resultate dieser Experimente lassen sich folgendermaßen zusammenfassen:

1. Das feine Einzelskalaverfahren liefert für kleine Fehler der Näherungswerte genaue Ergebnisse. Bei größeren Fehlern schlägt die Bestimmung der relativen Orientierung ab einem gewissen Schwellwert jedoch fehl. Für den synthetischen Indoor-Datensatz, der diesen Experimenten zugrunde liegt, beträgt dieser Schwellwert zwischen kleinen und großen Fehlern 40 cm bzw. ca. 3° .
2. Das grobe Einzelskalaverfahren ist robust gegenüber ungenauen Näherungswerten und verbessert alle in den Experimenten getesteten Näherungswerte. Allerdings erzielt das grobe Einzelskalaverfahren ungenauere Ergebnisse als das feine Einzelskalaverfahren.
3. Das Multiskalenverfahren dagegen erzielt für alle getesteten Näherungswerte die genauesten Ergebnisse.

Für die Anwendung bedeutet dies, dass das feine Einzelskalaverfahren ausreichend ist, solange die Näherungswerte weniger als 40 cm und 3° von der wahren relativen Orientierung abweichen, vorausgesetzt die Genauigkeit der verwendeten Sensoren ist vergleichbar mit denen des synthetischen Datensatzes. Für geringere Sensorgenauigkeiten ist zu erwarten, dass die Näherungswerte genauer sein müssen, damit das feine Einzelskalaverfahren gute Ergebnisse erzielt.

Zusammengefasst, ist das feine Einzelskalaverfahren genauer für kleine Fehler der Näherungswerte. Das grobe Einzelskalaverfahren ist dagegen robuster gegenüber großen Fehlern der Näherungswerte. Das Multiskalenverfahren kombiniert die Vorteile beider Einzelskalaverfahren, was bedeutet, dass es sowohl robust ist, als auch hohe Genauigkeiten liefert. Der einzige Nachteil des Multiskalenverfahrens ist dessen längere Berechnungsdauer. Demzufolge ist das Multiskalenverfahren stets zu bevorzugen, wenn die Berechnungsdauer unkritisch ist.

6.5 Ergebnisse mit realen Daten

Die Experimente mit realen Daten zeigen die vielseitige Einsetzbarkeit der Merkmalsbasierten Selbstkalibrierung. Während die meisten herkömmlichen Verfahren auf eine bestimmte Sen-

sorkombination spezialisiert sind, ist die Merkmalsbasierte Selbstkalibrierung für verschiedene Sensoren einsetzbar. So konnte die Eignung für eine Kombination aus einem Motion Capture System und einem 2D-Laserscanner, einem GNSS/IMU System und einem 3D-Laserscanner sowie einer Stereokamera und einem 3D-Laserscanner gezeigt werden, obwohl alle diese Sensoren unterschiedliche Eigenschaften und Genauigkeiten aufweisen. Die verwendeten Datensätze variieren in der Größe der Punktwolke, der Beschaffenheit der Umgebung und der verwendeten Trägerplattform, was die universelle Anwendbarkeit der Merkmalsbasierten Selbstkalibrierung in Bezug auf diese Kriterien belegt. Ein Teil des kleinen Indoor-Datensatzes wurde zusammen mit dem Code der Merkmalsbasierten Selbstkalibrierung veröffentlicht. Zusammen mit dem mittleren und großen Outdoor-Datensatz, die ebenfalls öffentliche Datensätzen darstellen, sind die Ergebnisse somit transparent und reproduzierbar.

6.5.1 Kleiner Indoor-Datensatz

Die Sensorkombination, die beim kleinen Indoor-Datensatz eingesetzt wurde, bildet eine besondere Herausforderung für Kalibrierverfahren. Im Gegensatz zu zwei Scans eines 3D-Laserscanners, die mit Hilfe von gebräuchlichen Verfahren wie dem ICP-Algorithmus registriert werden können, ist die Registrierung der Zeilen eines 2D-Laserscanners in 3D nicht möglich. Mit anderen Worten kann die vollständige 6-DOF-Pose nicht mit einem 2D-Laserscanner alleine bestimmt werden. Dadurch ist eine Vielzahl an Kalibrierverfahren aus der Literatur nicht anwendbar.

Für diese Sensoren geeignet ist eine objektbasierte Kalibrierung, die auf [79] und [90] basiert und in Kapitel 4.3 zusammengefasst wird. Diese objektbasierte Kalibrierung ist ein Verfahren auf dem aktuellen Stand der Forschung, dennoch können die Ergebnisse dieses Verfahrens nicht als Ground Truth angesehen werden. Die Experimente zeigen, dass die Merkmalsbasierte Selbstkalibrierung die objektbasierte Kalibrierung übertrifft, was sowohl die qualitativen als auch die quantitativen Ergebnisse zeigen. Darüber hinaus ist die Merkmalsbasierte Selbstkalibrierung universeller anwendbar, erfordert kein spezielles Kalibrierobjekt und ist bei geeigneter Wahl der Kostenfunktion vollständig datenbasiert und trifft keine Modellannahmen.

Im Vergleich zur Entropiebasierten Selbstkalibrierung liefert die Merkmalsbasierte Selbstkalibrierung mit dem geometrischen 3D-Merkmal Omnivarianz ebenfalls genauere Ergebnisse auf dem kleinen Indoor-Datensatz, was sich in allen Evaluierungsmetriken zeigt.

6.5.2 Mittlerer Outdoor-Datensatz

Beim mittleren Outdoor-Datensatz wurde ein Fahrzeug als Trägerplattform verwendet. Deutliche Variationen aller sechs Freiheitsgrade der Posen sind bei Fahrzeugen nicht umsetzbar. Die Experimente in Kapitel 5.1.1 zeigen jedoch, dass durch eine geeignete Wahl der Posen auch für

eine fahrzeuggestützte Trägerplattform mit der Merkmalsbasierten Selbstkalibrierung alle sechs Parameter der relativen Orientierung bestimmt werden können.

Im Gegensatz zum kleinen Indoor-Datensatz, wurde die Erfassung beim Mittleren Outdoor-Datensatz im Außenbereich durchgeführt. Dadurch ist die Umgebung nicht ausschließlich anthropogen, sondern enthält natürliche Objekte wie Vegetation. Die Ergebnisse des mittleren Outdoor-Datensatzes zeigen somit auch die Eignung des Verfahrens für solche Umgebungen.

Auch die Entropiebasierte Selbstkalibrierung erzielt auf dem mittleren Outdoor-Datensatz genaue Ergebnisse. Allerdings sind sowohl die Genauigkeit als auch die Präzision des Ergebnisses für alle Parameter bis auf Φ geringer als die der Merkmalsbasierten Selbstkalibrierung.

Die Sensoren, die beim mittleren Outdoor-Datensatz eingesetzt werden sind typisch für Mobile Mapping Systeme: Ein GNSS/IMU System zur Bestimmung der Pose und ein 3D-Laserscanner zur räumlichen Erfassung der Umgebung. Die Spezifikationen des GNSS/IMU Systems weisen insbesondere im Vergleich zum Großen Outdoor-Datensatz und in Anbetracht der Größe der Punktwolke hohe Genauigkeiten für die Position von ca. 5 cm und für die Orientierung von ca. 0.02° auf. Der 3D-Laserscanner weist eine Genauigkeit der Distanzmessung von 5 cm auf. Vor dem Hintergrund dieser Sensorgenauigkeiten sind die Ergebnisse der Merkmalsbasierten Selbstkalibrierung mit ca. 1 cm und unter 0.2° bemerkenswert genau. Durch die Verwendung von redundanten Beobachtungen ist insbesondere die Genauigkeit der bestimmten Translationsparameter höher als die der Positionsbestimmung mit dem GNSS/INS System und die der Distanzmessung des Laserscanners. Die hohe Redundanz kommt insbesondere durch die Posenzustände, die das Fahrzeug bei der Erfassung angenommen hat. Restfehler nach der Bestimmung der relativen Translation durch die Merkmalsbasierte Selbstkalibrierung wirken sich somit nicht signifikant auf die Qualität der Punktwolke aus.

6.5.3 Großer Outdoor-Datensatz

Die Ergebnisse für den großen Outdoor-Datensatz zeigen, dass die Merkmalsbasierte Selbstkalibrierung auch in der Lage ist, die relative Orientierung zwischen einer Stereokamera und einem 3D-Laserscanner zu bestimmen. Allerdings werden niedrigere Genauigkeiten erreicht als beim kleinen Indoor- und beim mittleren Outdoor-Datensatz. Anhand der Visualisierung der Ergebnisse in Abbildung 5.11 zeigt sich jedoch, dass diese Genauigkeit beispielsweise für eine Applikation wie die Fahrzeugerkennung ausreicht.

Durch die Experimente können zwei Gründe für die niedrigere Genauigkeit im Vergleich zu den anderen beiden realen Datensätzen identifiziert werden:

1. **Niedrige Genauigkeit der Posenbestimmung:** Das Stereo-SLAM Verfahren ORB-SLAM2 [136], das zur Posenbestimmung eingesetzt wurde, erzielt niedrigere Genauigkeiten, als die Posenbestimmungssensoren der anderen beiden Datensätze, wodurch

niedrigere Genauigkeiten bei der Bestimmung der relativen Orientierung zu erwarten sind. Der Stereo-SLAM bestimmt die relativen Posen von einem Aufnahmeort zum nächsten. Dadurch akkumulieren sich kleinere Fehler im Laufe der Zeit (vgl. Kapitel 2.4.3). Die Posen können demzufolge nur als lokal konsistent bezeichnet werden.

2. **Schlechte Bewegungskonfiguration:** Die Trajektorie des großen Outdoor-Datensatzes enthält so gut wie keine bidirektionalen Abschnitte, bei denen die gleiche Umgebung aus stark unterschiedlichen Blickrichtungen erfasst wurde.

Die schlechteren Genauigkeiten im Vergleich zu den anderen beiden Datensätzen sind somit plausibel.

Verglichen mit der ersten, automatischen Stufe der objektbasierten Kalibrierung [56] erzielt die Merkmalsbasierte Selbstkalibrierung um einen Faktor von ca. 10 höhere Genauigkeiten für die Bestimmung der Rotationsparameter. Die Genauigkeiten der Translationsparameter sind vergleichbar. Die objektbasierte Kalibrierung [56] verwendet die Beobachtungen einer einzelnen Kamera. Die Merkmalsbasierte Selbstkalibrierung hingegen ist in der Lage, die Beobachtungen der Stereokamera auszunutzen, was ein Grund für die höhere Genauigkeit bei der Bestimmung der Rotationsparameter sein könnte. Ein weiterer Grund könnte sein, dass die Merkmalsbasierte Selbstkalibrierung aufgrund ihrer Natur als Selbstkalibrierung deutlich mehr Beobachtungen ausnutzt, als eine Objektbasierte Kalibrierung. Verglichen mit dem zweiten Schritt der objektbasierten Kalibrierung nach manueller Verfeinerung der Kalibrierung [59] haben die Ergebnisse in etwa die gleiche Genauigkeit, was sich auch anhand der quantitativen Evaluierung in Kapitel 5.2.3 zeigt.

7 Zusammenfassung und Ausblick

In dieser Arbeit wird ein neues Verfahren zur Selbstkalibrierung von mobilen Multisensorsystemen vorgestellt, das als *Merkmalsbasierte Selbstkalibrierung* bezeichnet wird.

Die Merkmalsbasierte Selbstkalibrierung eignet sich zur Bestimmung der relativen Orientierung zwischen einem beliebigen Posenbestimmungssensor und einem beliebigen Tiefensensor. Da es sich um eine Selbstkalibrierung handelt, hat die Merkmalsbasierte Selbstkalibrierung eine Reihe von Vorteilen gegenüber herkömmlichen Verfahren, die die relative Orientierung mit Hilfe eines Kalibrierobjektes bestimmen: (i) Die Merkmalsbasierte Selbstkalibrierung bestimmt die gesuchten Parameter mit der höchstmöglichen Aktualität, da sie simultan zum operationellen Betrieb des mobilen Multisensorsystems durchgeführt werden kann. Dadurch können sogar Veränderungen der gesuchten Parameter, die während der Datenerfassung beispielsweise durch mechanische oder thermale Einflüsse auftreten, korrigiert werden, ohne die Datenerfassung zu unterbrechen. (ii) Die Merkmalsbasierte Selbstkalibrierung ist zeitsparender und praktikabler für den Anwender als herkömmliche Verfahren, da sie vollautomatisch ist und keine zusätzlichen Daten eigens zum Zwecke der Kalibrierung erfasst werden müssen. Sie wird mit den Daten durchgeführt, die im operationellen Betrieb ohnehin anfallen. (iii) Die Merkmalsbasierte Selbstkalibrierung ist flexibler einsetzbar als herkömmliche Verfahren, da sie in verschiedensten Umgebungen durchgeführt werden kann, ohne dass diese Umgebungen im Vorfeld präpariert werden müssen. Dies wird dadurch erreicht, dass die Merkmalsbasierte Selbstkalibrierung ein rein datenbasiertes Verfahren ist, das keine Modellannahmen wie beispielsweise die Planarität von Ebenen in der Umgebung trifft.

Die fundamentale Annahme, die die Merkmalsbasierte Selbstkalibrierung trifft, ist, dass die Parameter der relativen Orientierung am besten bestimmt sind, wenn die erfasste Punktwolke die höchstmögliche Qualität hat. Die Kostenfunktion, die zur Bewertung der Qualität verwendet wird, basiert auf geometrischen 3D-Merkmalen, die wiederum auf der lokalen Nachbarschaft jedes Punktes basieren. Es werden verschiedene geometrische 3D-Merkmale auf ihre Eignung in der Kostenfunktion getestet. Die Ergebnisse zeigen, dass das geometrische 3D-Merkmal Omnivarianz, das ein Maß für die lokale Kompaktheit der Punktwolke darstellt, von den untersuchten Merkmalen am besten geeignet ist. In dieser Arbeit kann gezeigt werden, dass die Omnivarianz eine neue Möglichkeit bietet die Qualität einer Punktwolke zu evaluieren. Durch die Minimierung einer Kostenfunktion, die auf der Omnivarianz basiert, wird die lokale Kompaktheit einer Punktwolke maximiert. Dadurch lassen sich prinzipiell nicht nur die Parameter der relativen Orientierung mit hoher Genauigkeit bestimmen, sondern auch andere systematische Fehler, die

sich in der Geometrie der Punktwolke abbilden. Dies wird beispielhaft durch die Bestimmung eines konstanten Skalierungsfaktors für die Posen eines mobilen Multisensorsystems gezeigt. In diesem Beispiel können mit einer angepassten Methodik der Merkmalsbasierten Selbstkalibrierung unskalierte Posen durch die metrischen Messungen eines Laserscanners skaliert werden.

Des Weiteren werden in dieser Arbeit unterschiedliche Aspekte analysiert, die einen Einfluss auf das Ergebnis haben. Aus den Experimenten wird deutlich, dass insbesondere die Posen des Systems einen gravierenden Einfluss auf die Ergebnisse haben. Die Posen sollten nach Möglichkeit in allen sechs Freiheitsgraden variieren. Darüber hinaus ist die Erfassung der gleichen Objekte aus zwei unterschiedlichen Bewegungsrichtungen insbesondere für die Bestimmung der relativen Translation zwischen den beiden Sensoren zuträglich. Die optimale Bewegungskonfiguration für fahrzeuggesteuerte Multisensorsysteme besteht aus einer kurvigen Fahrt in einem begrenzten Bereich, sodass die selbe Umgebung von vielen verschiedenen Aufnahmestandorten und unter verschiedenen Blickwinkeln erfasst wird. Durch eine solche Bewegung entstehen effizient geometrische Bedingungen, die eine genaue Bestimmung aller sechs Parameter der relativen Orientierung ermöglichen. Die Experimente mit realen Datensätzen zeigen, dass nach der Bewegungskonfiguration auch die Genauigkeit der bestimmten Posen einen Einfluss auf das Ergebnis der Merkmalsbasierten Selbstkalibrierung haben. Je genauer die Posen bestimmt sind, desto genauer ist auch die Bestimmung der relativen Orientierung.

Durch die Implementierung eines Multiskalenverfahrens, erzielt die Merkmalsbasierte Selbstkalibrierung auch dann genaue Ergebnisse, wenn die Näherungswerte für die relative Orientierung ungenau sind. Dies ist wichtig für die Praktikabilität eines Kalibrierverfahrens, da die benötigte Genauigkeit der Näherungswerte darüber entscheidet, ob ein zusätzliches Verfahren zur Bestimmung der Näherungswerte eingesetzt werden muss. Sofern die Posen des Systems eine hohe Genauigkeit und eine geeignete Konfiguration aufweisen, reicht es aus, wenn die Parameter der relativen Orientierung im Bereich von wenigen Metern und besser als 30° bekannt sind. Für die meisten operativen Sensorsysteme ist es demzufolge ausreichend, die Näherungswerte grob abzuschätzen oder mit einfachen Mitteln wie beispielsweise einem Zollstock auszumessen. Dies reicht ebenfalls aus, um operative mobile Multisensorsysteme mit der Merkmalsbasierten Selbstkalibrierung automatisch online kalibrieren zu können, ohne dass Experten das System warten müssen.

Die Experimente mit realen Daten zeigen die vielseitige Einsetzbarkeit der Merkmalsbasierten Selbstkalibrierung. Während die meisten herkömmlichen Verfahren auf eine bestimmte Sensorkombination beschränkt sind, ist die Merkmalsbasierte Selbstkalibrierung für verschiedene Sensoren einsetzbar. So kann die Eignung für eine Kombination aus einem Motion Capture System und einem 2D-Laserscanner, einem GNSS/IMU System und einem 3D-Laserscanner sowie einer Stereokamera und einem 3D-Laserscanner gezeigt werden, obwohl alle diese Sensoren unterschiedliche Eigenschaften und Genauigkeiten aufweisen. Die Datensätze variieren auch in

der Größe der Punktwolke, der Beschaffenheit der Umgebung und der verwendeten Trägerplattform, sodass die vielseitige Einsetzbarkeit der Merkmalsbasierten Selbstkalibrierung gegenüber diesen Kriterien nachgewiesen werden kann. Ein Teil des kleinen Indoor-Datensatzes wurde zusammen mit dem Code der Merkmalsbasierten Selbstkalibrierung veröffentlicht. Zusammen mit dem mittleren und großen Outdoor-Datensatz, die ebenfalls öffentliche Datensätze darstellen, sind die Ergebnisse somit transparent und reproduzierbar.

Die Genauigkeit und Präzision der Ergebnisse der Merkmalsbasierten Selbstkalibrierung entsprechen dem aktuellen Stand der Forschung. Die Ergebnisse werden für jeden Datensatz jeweils mit der Entropiebasierten Selbstkalibrierung [124, 170] sowie mit einer geeigneten Vergleichskalibrierung [55, 60, 79] validiert. Für alle Datensätze erzielt die Merkmalsbasierte Selbstkalibrierung bessere oder zumindest vergleichbare Genauigkeiten und eine höhere Präzision. Für den kleinen Indoor-Datensatz, der die höchsten Sensorgenauigkeiten aufweist, werden die Parameter der relativen Orientierung mit einer Genauigkeit von ca. 1 cm und unter 1° bestimmt, obwohl die Distanzmessgenauigkeit des verwendeten Laserscanners nur 3 cm beträgt.

Um die Merkmalsbasierte Selbstkalibrierung künftig als Online-Kalibrierung in operationellen Systemen einsetzen zu können, ist die Entwicklung eines Algorithmus zur automatischen Selektion geeigneter Posen empfehlenswert, da die Bewegungskonfiguration den größten Einfluss auf die Genauigkeit und Robustheit des Ergebnisses hat. Alternativ kann die Methodik der Merkmalsbasierten Selbstkalibrierung so erweitert werden, dass nicht alle Beobachtungen in die Kleinste-Quadrate-Ausgleichung eingehen, sondern nur solche, bei denen die Punkte in der lokalen Nachbarschaft aus stark variierenden Richtungen aufgezeichnet wurden. Dadurch könnte vermutlich die Robustheit der Merkmalsbasierten Selbstkalibrierung weiter erhöht und zusätzlich die Berechnungsdauer reduziert werden.

In dieser Arbeit wird mit der Omnivarianz eine neue Metrik zur Bewertung der Qualität einer Punktwolke verwendet. Eine Kostenfunktion, die auf dieser Metrik basiert, wird eingesetzt, um die relative Orientierung sowie einen konstanten Skalierungsfaktor der Posen zu bestimmen, die sich jeweils als systematischer Fehler in der Punktwolke auswirken. Dies wirft die Fragestellung auf, welche weiteren systematischen Fehler mit Hilfe der Omnivarianz automatisch korrigiert werden können:

- Es ist denkbar, dass beispielsweise die Parameter der inneren Orientierung des Tiefensensors, wie etwa ein konstanter Offset bei der Entfernungsmessung oder ein Skalierungsfaktor der Richtungsmessung (vgl. Tabelle 1.1), durch Minimierung der gleichen Kostenfunktion bestimmbar sind.
- Auf die gleiche Art und Weise könnten weitere systematische Fehler bei der Posenbestimmung, wie beispielsweise eine Skalierungsdrift korrigiert werden, indem die Messungen des Tiefensensors berücksichtigt werden. Eine solche Skalierungsdrift ist typisch für bildbasierte SLAM-Verfahren mit einer einzelnen Kamera.

- Auch die Registrierung von Punktwolken kann theoretisch durch Minimierung dieser Metrik durchgeführt werden. Im Gegensatz zum ICP-Verfahren, bei dem iterativ die Distanzen der Punkte zu ihren jeweiligen nächsten Nachbarn in der anderen Punktwolke minimiert werden, verwendet die Omnivarianz jeweils eine größere Menge von Nachbarn und dadurch mehr Beobachtungen, was letztlich zu einer genaueren Registrierung führen könnte. Die Punkt-zu-Punkt Metrik des ICP-Verfahrens beruht auf der Annahme, dass jeder Punkt in der ersten Punktwolke einem physikalisch identischen Punkt in der zweiten Punktwolke entspricht. Aufgrund der diskreten Abtastung der Umgebung durch den Tiefensensor ist dies in der Realität jedoch nicht der Fall, sodass diese Annahme in der Praxis verletzt wird. Aus diesem Grund wird häufig die Punkt-zu-Flächen Metrik eingesetzt, die den Abstand eines Punktes in der ersten Punktwolke zu der nächsten Fläche aus der vermaschten zweiten Punktwolke minimiert. Diese Metrik geht jedoch von der Annahme aus, dass benachbarte Punkte in der zweiten Punktwolke Teil einer gemeinsamen Fläche sind. Auch diese Annahme wird in der Realität schnell verletzt. Die Omnivarianz ist dagegen eine Metrik für die lokale Kompaktheit, die keine solche Modellannahme trifft. Sie ist unabhängig von der Geometrie der Punktwolke. Unter Umständen führt die Verwendung der Omnivarianz zu einer genaueren Registrierung der Punktwolken als mit der Punkt-zu-Punkt- bzw. Punkt-zu-Flächen-Metrik des ICP-Verfahrens.

Literaturverzeichnis

- [1] AGARWAL, S. ; FURUKAWA, Y. ; SNAVELY, N. ; SIMON, I. ; CURLESS, B. ; SEITZ, S. M. ; SZELISKI, R. : Building Rome in a Day. In: *Communications of the ACM* 54-10 (2011), S. 105–112
- [2] AGARWAL, S. ; MIERLE, K. u. a.: *Ceres Solver*. <http://ceres-solver.org/>. Version: 2019. – [Online; abgerufen am 24.10.2019]
- [3] ALCANTARILLA, P. F. ; BARTOLI, A. ; DAVISON, A. J.: KAZE Features. In: *European Conference on Computer Vision* (2012), S. 214–227
- [4] ARMENAKIS, C. : (Editor). In: *Proceedings of International Conference on Unmanned Aerial Vehicles in Geomatics (UAV-g). ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences XL-1-W4* (2015), S. 1–419
- [5] BAILEY, T. ; DURRANT-WHYTE, H. : Simultaneous Localization and Mapping (SLAM): Part II. In: *IEEE robotics & automation magazine* 13-3 (2006), S. 108–117
- [6] BAKER, P. ; ALOIMONOS, Y. : Complete Calibration of a Multi-Camera Network. In: *Proceedings of IEEE Workshop on Omnidirectional Vision* IEEE, 2000, S. 134–141
- [7] BARRETO, J. ; DANIILIDIS, K. : Wide Area Multiple Camera Calibration and Estimation of Radial Distortion. In: *Proceedings of the Workshop on Omnidirectional Vision, Camera Networks and Non-Classical Cameras, Prague, Czech Republic* Bd. 63, 2004, S. 64
- [8] BAY, H. ; TUYTELAARS, T. ; VAN GOOL, L. : SURF: Speeded up Robust Features. In: *European conference on computer vision* (2006), S. 404–417
- [9] BESL, P. ; MCKAY, N. D.: A Method for Registration of 3-D Shapes. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence* 14-2 (1992), S. 239–256
- [10] BISHOP, G. ; WELCH, G. ; ALLEN, B. D.: Tracking: Beyond 15 minutes of thought. In: *SIGGRAPH Course Pack* 11 (2001)
- [11] BLANCO, J.-L. ; MORENO, F.-A. ; GONZALEZ, J. : A Collection of Outdoor Robotic Datasets with Centimeter-Accuracy Ground Truth. In: *Autonomous Robots* 27-4 (2009), S. 327–351
- [12] BLANCO-CLARACO, J.-L. ; MORENO-DUEÑAS, F.-Á. ; GONZÁLEZ-JIMÉNEZ, J. : The Málaga Urban Dataset: High-rate Stereo and LiDAR in a Realistic Urban Scenario. In: *The International Journal of Robotics Research (IJRR)* 33-2 (2014), S. 207–214

- [13] BLASER, S. ; CAVEGN, S. ; NEBIKER, S. : Development of a Portable High Performance Mobile Mapping System Using the Robot Operating System. In: *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences* 4–1 (2018)
- [14] BLASER, S. ; NEBIKER, S. ; CAVEGN, S. : System Design, Calibration and Performance Analysis of a Novel 360 Stereo Panoramic Mobile Mapping System. In: *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 4 (2017), S. 207
- [15] BLOMLEY, R. ; WEINMANN, M. ; LEITLOFF, J. ; JUTZI, B. : Shape Distribution Features for Point Cloud Analysis – A Geometric Histogram Approach on Multiple Scales. In: *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences* II-3 (2014), S. 9–16
- [16] BOK, Y. ; CHOI, D.-G. ; KWEON, I. S.: Extrinsic Calibration of a Camera and a 2D Laser without Overlap. In: *Robotics and Autonomous Systems* 78 (2016), Apr., S. 17–28
- [17] BORGMANN, B. ; SCHATZ, V. ; KIERITZ, H. ; SCHERER-KLÖCKLING, C. ; HEBEL, M. ; ARENS, M. : Data Processing and Recording Using a Versatile Multi-sensor Vehicle. In: *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences* 4–1 (2018)
- [18] BOSSE, M. ; ZLOT, R. ; FLICK, P. : Zebedee: Design of a spring-mounted 3-d range sensor with application to mobile mapping. In: *IEEE Transactions on Robotics* 28–5 (2012), S. 1104–1119
- [19] BRIALES, J. ; GONZALEZ-JIMENEZ, J. : A Minimal Solution for the Calibration of a 2D Laser-Rangefinder and a Camera Based on Scene Corners. In: *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, IEEE, 2015, S. 1891–1896
- [20] BRODU, N. ; LAGUE, D. : 3D Terrestrial LiDAR Data Classification of Complex Natural Scenes Using a Multi-scale Dimensionality Criterion: Applications in Geomorphology. In: *ISPRS Journal of Photogrammetry and Remote Sensing* 68 (2012), S. 121–134
- [21] BRÜCKNER, M. ; BAJRAMOVIC, F. ; DENZLER, J. : Intrinsic and Extrinsic Active Self-Calibration of Multi-Camera Systems. In: *Machine vision and applications* 25-2 (2014), S. 389–403
- [22] BUENO, M. ; GONZÁLEZ-JORGE, H. ; MARTÍNEZ-SÁNCHEZ, J. ; LORENZO, H. : Automatic Point Cloud Coarse Registration Using Geometric Keypoint Descriptors for Indoor Scenes. In: *Automation in Construction* 81 (2017), S. 134–148
- [23] BUENO, M. ; MARTÍNEZ-SÁNCHEZ, J. ; GONZÁLEZ-JORGE, H. ; LORENZO, H. : Detection of Geometric Keypoints and its Application to Point Cloud Coarse Registration. In: *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* XLI-B3 (2016), S. 187–194

- [24] BUENO, M. ; BOSCHÉ, F. ; GONZÁLEZ-JORGE, H. ; MARTÍNEZ-SÁNCHEZ, J. ; ARIAS, P. : 4-Plane Congruent Sets for Automatic Registration of as-is 3D Point Clouds with 3D BIM Models. In: *Automation in Construction* 89 (2018), S. 120–134
- [25] BURRI, M. ; NIKOLIC, J. ; GOHL, P. ; SCHNEIDER, T. ; REHDER, J. ; OMARI, S. ; ACHELIK, M. W. ; SIEGWART, R. : The EuRoC Micro Aerial Vehicle Datasets. In: *The International Journal of Robotics Research (IJRR)* (2016)
- [26] CADENA, C. ; CARLONE, L. ; CARRILLO, H. ; LATIF, Y. ; SCARAMUZZA, D. ; NEIRA, J. ; REID, I. ; LEONARD, J. J.: Past, Present, and Future of Simultaneous Localization and Mapping: Toward the Robust-perception Age. In: *IEEE Transactions on robotics* 32-6 (2016), S. 1309–1332
- [27] CALONDER, M. ; LEPETIT, V. ; STRECHA, C. ; FUA, P. : BRIEF: Binary Robust Independent Elementary Features. In: *European conference on computer vision* (2010), S. 778–792
- [28] CARRERA, G. ; ANGELI, A. ; DAVISON, A. J.: SLAM-based Automatic Extrinsic Calibration of a Multi-Camera Rig. In: *Proceedings of the International Conference on Robotics and Automation (ICRA)* IEEE, 2011, S. 2652–2659
- [29] CERIANI, S. ; FONTANA, G. ; GIUSTI, A. ; MARZORATI, D. ; MATTEUCCI, M. ; MIGLIORE, D. ; RIZZI, D. ; SORRENTI, D. G. ; TADDEI, P. : Rawseeds Ground Truth Collection Systems for Indoor Self-Localization and Mapping. In: *Autonomous Robots* 27-4 (2009), S. 353–371
- [30] CHAN, T. O. ; LICHTI, D. D. ; GLENNIE, C. L.: Multi-feature Based Boresight Self-Calibration of a Terrestrial Mobile Mapping System. In: *ISPRS Journal of Photogrammetry and Remote Sensing* 82 (2013), S. 112–124
- [31] CHEN, Y. ; MEDIONI, G. : Object Modelling by Registration of Multiple Range Images. In: *Image and Vision Computing* 10-3 (1992), S. 145–155
- [32] CHOSET, H. M. ; HUTCHINSON, S. ; LYNCH, K. M. ; KANTOR, G. ; BURGARD, W. ; KAVRAKI, L. E. ; THRUN, S. : *Principles of Robot Motion: Theory, Algorithms, and Implementation*. MIT press, 2005
- [33] CSANYI, N. ; TOTH, C. K.: Improvement of LiDAR Data Accuracy Using LiDAR-specific Ground Targets. In: *Photogrammetric Engineering & Remote Sensing* 73-4 (2007), S. 385–396
- [34] DAVISON, A. J. ; REID, I. D. ; MOLTON, N. D. ; STASSE, O. : MonoSLAM: Real-time Single Camera SLAM. In: *IEEE Transactions on Pattern Analysis & Machine Intelligence* 29-6 (2007), S. 1052–1067
- [35] DELLAERT, F. : Factor Graphs and GTSAM: A Hands-on Introduction / Georgia Institute of Technology. 2012. – Forschungsbericht
- [36] DELMERICO, J. ; SCARAMUZZA, D. : A Benchmark Comparison of Monocular Visual-Inertial Odometry Algorithms for Flying Robots. In: *Proceedings of the International Conference on Robotics and Automation (ICRA)* 10 (2018), S. 20–28

- [37] DEMANTKÉ, J. ; MALLET, C. ; DAVID, N. ; VALLET, B. : Dimensionality Based Scale Selection in 3D LiDAR Point Clouds. In: *International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences* 38-5 (2011), S. W12
- [38] DITTRICH, A. ; WEINMANN, M. ; HINZ, S. : Analytical and Numerical Investigations on the Accuracy and Robustness of Geometric Features Extracted from 3D Point Cloud Data. In: *ISPRS Journal of Photogrammetry and Remote Sensing* 126 (2017), S. 195–208
- [39] DOMHOF, J. ; KOUIJ, J. F. P. ; GAVRILA, D. M.: An Extrinsic Calibration Tool for Radar, Camera and LiDAR. In: *International Conference on Robotics and Automation (ICRA)* IEEE, 2019, S. 8107–8113
- [40] DONG, W. ; ISLER, V. : A Novel Method for the Extrinsic Calibration of a 2-D Laser-range-finder & a Camera. In: *Proceedings of the International Conference on Robotics and Automation (ICRA)* IEEE, 2017, S. 5104–5109
- [41] DOUCET, A. : On Sequential Simulation-based Methods for Bayesian Filtering. In: *Technical report CUED/F-INFENG/TR.310* (1998)
- [42] DOUCET, A. ; DE FREITAS, N. ; MURPHY, K. ; RUSSELL, S. : Rao-Blackwellised Particle Filtering for Dynamic Bayesian Networks. In: *Proceedings of the Sixteenth conference on Uncertainty in artificial intelligence* (2000), S. 176–183
- [43] EBNER, H. : Self Calibrating Block Adjustment. In: *Bildmessung und Luftbildwesen* 44 (1976), S. 128–139
- [44] ENGEL, J. ; USENKO, V. ; CREMERS, D. : A Photometrically Calibrated Benchmark For Monocular Visual Odometry. In: *arXiv:1607.02555*, 2016
- [45] ENGEL, J. ; KOLTUN, V. ; CREMERS, D. : Direct Sparse Odometry. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence* 40-3 (2017), S. 611–625
- [46] ENGEL, J. ; STÜCKLER, J. ; CREMERS, D. : Large-scale Direct SLAM with Stereo Cameras. In: *2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)* (2015), S. 1935–1942
- [47] ESQUIVEL, S. ; WOELK, F. ; KOCH, R. : Calibration of a Multi-Camera Rig from Non-overlapping Views. In: *Joint Pattern Recognition Symposium* Springer, 2007, S. 82–91
- [48] FAN, B. ; WANG, Z. ; WU, F. : *Local Image Descriptor: Modern Approaches*. Bd. 108. Springer, 2015
- [49] FILIN, S. ; PFEIFER, N. : Neighborhood Systems for Airborne Laser Data. In: *Photogrammetric Engineering & Remote Sensing* 71-6 (2005), S. 743–755
- [50] FIRMAN, M. : RGBD Datasets: Past, Present and Future. In: *Proceedings of the IEEE conference on computer vision and pattern recognition workshops*, 2016, S. 19–31
- [51] FISCHLER, M. A. ; BOLLES, R. C.: Random Sample Consensus: A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography. In: *Communications of the ACM* 24-6 (1981), S. 381–395

- [52] FORSTER, C. ; ZHANG, Z. ; GASSNER, M. ; WERLBERGER, M. ; SCARAMUZZA, D. : SVO: Semidirect Visual Odometry for Monocular and Multicamera Systems. In: *IEEE Transactions on Robotics* 33-2 (2016), S. 249–265
- [53] FROME, A. ; HUBER, D. ; KOLLURI, R. ; BÜLOW, T. ; MALIK, J. : Recognizing Objects in Range Data using Regional Point Descriptors. In: *Proceedings of the European Conference on Computer Vision, Springer, 11-14 May, 2004*, S. III:224–III:237
- [54] GAUSS, C. F.: *Theoria motus corporum coelestium in sectionibus conicis solem ambientium*. Bd. 7. Perthes et Besser, 1809
- [55] GEHRUNG, J. ; HEBEL, M. ; ARENS, M. ; STILLA, U. : An Approach to Extract Moving Objects from MLS Data Using a Volumetric Background Representation. In: *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences IV-1* (2017), S. 107–114
- [56] GEIGER, A. ; MOOSMANN, F. ; CAR, O. ; SCHUSTER, B. : Automatic Camera and Range Sensor Calibration Using a Single Shot. In: *Proceedings of the International Conference on Robotics and Automation (ICRA)*, 2012, S. 3936–3943
- [57] GEIGER, A. ; LENZ, P. ; STILLER, C. ; URTASUN, R. : Vision meets robotics: The KITTI Dataset. In: *The International Journal of Robotics Research* 32-11 (2013), S. 1231–1237
- [58] GEIGER, A. ; LENZ, P. ; STILLER, C. ; URTASUN, R. : *Visual Odometry / SLAM Evaluation 2012*. http://www.cvlibs.net/datasets/kitti/eval_odometry.php, 2019. – [Online; abgerufen am 23.07.2019]
- [59] GEIGER, A. ; LENZ, P. ; URTASUN, R. : Are we ready for autonomous driving? The KITTI Vision Benchmark Suite. In: *2012 IEEE Conference on Proceedings of the Computer Vision and Pattern Recognition (CVPR) IEEE*, 2012, S. 3354–3361
- [60] GEIGER, A. ; MOOSMANN, F. ; CAR, Ö. ; SCHUSTER, B. : Automatic Camera and Range Sensor Calibration Using a Single Shot. In: *Proceedings of the International Conference on Robotics and Automation (ICRA) IEEE*, 2012, S. 3936–3943
- [61] GLENNIE, C. : Rigorous 3D Error Analysis of Kinematic Scanning LiDAR Systems. In: *Journal of Applied Geodesy* 1-3 (2007), S. 147–157
- [62] GLENNIE, C. : Calibration and Kinematic Analysis of the Velodyne HDL-64E S2 LiDAR Sensor. In: *Photogrammetric Engineering & Remote Sensing* 78-4 (2012), S. 339–347
- [63] GLIRA, P. ; PFEIFER, N. ; MANDLBURGER, G. : Rigorous Strip Adjustment of UAV-based Laserscanning Data Including Time-dependent Correction of Trajectory Errors. In: *Photogrammetric Engineering & Remote Sensing* 82–12 (2016), S. 945–954
- [64] GOMEZ-OJEDA, R. ; BRIALES, J. ; FERNANDEZ-MORAL, E. ; GONZALEZ-JIMENEZ, J. : Extrinsic Calibration of a 2D Laser-Rangefinder and a Camera Based on Scene Corners. In: *Proceedings of the International Conference on Robotics and Automation (ICRA)*, IEEE, 2015, S. 3611–3616

- [65] GRÄFE, G. : High Precision Kinematic Surveying with Laser Scanners. In: *Journal of Applied Geodesy* 1-4 (2007), S. 185–199
- [66] GUO, B. ; HUANG, X. ; ZHANG, F. ; SOHN, G. : Classification of Airborne Laser Scanning Data Using JointBoost. In: *ISPRS Journal of Photogrammetry and Remote Sensing* 100 (2015), S. 71–83
- [67] HABIB, A. F. ; KERSTING, A. P. ; BANG, K. I. ; LEE, D. : Alternative Methodologies for the Internal Quality Control of Parallel LiDAR Strips. In: *IEEE Transactions on Geoscience and Remote Sensing* 48–1 (2009), S. 221–236
- [68] HABIB, A. F. ; KERSTING, A. P. ; SHAKER, A. ; YAN, W.-Y. : Geometric Calibration and Radiometric Correction of LiDAR Data and their Impact on the Quality of Derived Products. In: *Sensors* 11-9 (2011), S. 9069–9097
- [69] HACKEL, T. ; WEGNER, J. D. ; SCHINDLER, K. : Fast Semantic Segmentation of 3D Point Clouds with Strongly Varying Density. In: *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences* III-3 (2016), S. 177–184
- [70] HARAKÉ, L. ; SCHILLING, H. ; BLOHM, C. ; HILLEMANN, M. ; LENZ, A. ; BECKER, M. ; KESKIN, G. ; MIDDELMANN, W. : Concept for an Airborne Real-Time ISR System with Multi-sensor 3D Data Acquisition. In: *Electro-Optical and Infrared Systems: Technology and Applications XIII* Bd. 9987 International Society for Optics and Photonics, 2016, S. 998709
- [71] HARRIS, C. G. ; STEPHENS, M. u. a.: A Combined Corner and Edge Detector. In: *Alvey vision conference* 15-50 (1988), S. 10–5244
- [72] HARTLEY, R. ; ZISSERMAN, A. : *Multiple View Geometry in Computer Vision*. 2. ed., [Nachdr.]. Cambridge : Cambridge Univ. Press, 2010
- [73] HEBEL, M. ; STILLA, U. : Simultaneous Calibration of ALS Systems and Alignment of Multiview LiDAR Scans of Urban Areas. In: *IEEE Transactions on Geoscience and Remote Sensing* 50–6 (2011), S. 2364–2379
- [74] HEINLY, J. ; DUNN, E. ; FRAHM, J.-M. : Comparative Evaluation of Binary Features. In: *European Conference on Computer Vision* (2012), S. 759–773
- [75] HEINZ, E. ; ELING, C. ; WIELAND, M. ; KLINGBEIL, L. ; KUHLMANN, H. : Development, Calibration and Evaluation of a Portable and Direct Georeferenced Laser Scanning System for Kinematic 3D Mapping. In: *Journal of Applied Geodesy* 9-4 (2015), S. 227–243
- [76] HEINZ, E. ; ELING, C. ; WIELAND, M. ; KLINGBEIL, L. ; KUHLMANN, H. : Analysis of Different Reference Plane Setups for the Calibration of a Mobile Laser Scanning System. In: *Lienhart, W. (Hrsg.): Ingenieurvermessung 17, Beiträge zum 18. Internationalen Ingenieurvermessungskurs, Graz, Austria, 2017*, S. 131–146

- [77] HENG, L. ; LI, B. ; POLLEFEYS, M. : CamOdoCal: Automatic Intrinsic and Extrinsic Calibration of a Rig with Multiple Generic Cameras and Odometry. In: *Intelligent Robots and Systems (IROS)*, 2013, S. 1793–1800
- [78] HESS, W. ; KOHLER, D. ; RAPP, H. ; ANDOR, D. : Real-time Loop Closure in 2D LiDAR SLAM. In: *IEEE International Conference on Robotics and Automation (ICRA)* (2016), S. 1271–1278
- [79] HILLEMANN, M. ; JUTZI, B. : UCalMiCeL – Unified Intrinsic and Extrinsic Calibration of a Multi-Camera-System and a Laserscanner. In: *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences IV-2* (2017), S. 17–24
- [80] HILLEMANN, M. ; MEIDOW, J. ; JUTZI, B. : Impact of Different Trajectories on Extrinsic Self-Calibration for Vehicle-based Mobile Laser Scanning Systems. In: *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* (2019)
- [81] HILLEMANN, M. ; WEINMANN, M. ; MUELLER, M. S. ; JUTZI, B. : Automatic Extrinsic Self-Calibration of Mobile Mapping Systems Based on Geometric 3D Features. In: *Remote Sensing 11-16* (2019), S. 1955
- [82] HINTERSTOISSER, S. ; LEPETIT, V. ; ILIC, S. ; HOLZER, S. ; BRADSKI, G. ; KONOLIGE, K. ; NAVAB, N. : Model Based Training, Detection and Pose Estimation of Texture-less 3D Objects in Heavily Cluttered Scenes. In: *Proceedings on the Asian Conference on Computer Vision (ACCV)* Springer, 2012, S. 548–562
- [83] HOLLAND, P. W. ; WELSCH, R. E.: Robust Regression Using Iteratively Reweighted Least-squares. In: *Communications in Statistics-theory and Methods 6-9* (1977), S. 813–827
- [84] HORN, B. K.: Closed-form Solution of Absolute Orientation Using Unit Quaternions. In: *Josa a 4-4* (1987), S. 629–642
- [85] HOWARD, A. ; ROY, N. : *The Robotics Data Set Repository (Radish)*. 2003
- [86] HU, Z. ; LI, Y. ; NA ; ZHAO, B. : Extrinsic Calibration of 2-D Laser Rangefinder and Camera From Single Shot Based on Minimal Solution. In: *IEEE Transactions on Instrumentation and Measurement 65-4* (2016), 04, S. 915–929
- [87] HUANG, B. ; ZHAO, J. ; LIU, J. : A Survey of Simultaneous Localization and Mapping. In: *arXiv e-prints* (2019). – arXiv:1909.05214
- [88] HUBER, P. J.: Robust Estimation of a Location Parameter. In: *Breakthroughs in statistics*. Springer, 1992, S. 492–518
- [89] HUBER, P. J.: Robust Statistics. In: *International Encyclopedia of Statistical Science*. Springer, 2011, S. 1248–1251

- [90] HÜBNER, P. ; WEINMANN, M. ; HILLEMANN, M. ; JUTZI, B. ; WURSTHORN, S. : Combining Independent Visualization and Tracking Systems for Augmented Reality. In: *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 42-2 (2018)
- [91] IEEE COMPUTER SOCIETY (Hrsg.): *Sixth International Conference on Computer Vision, January 4-7, 1998, Bombay, India*. New Delhi : [New York] : Narosa Pub. House ; Institute for Electrical and Electronics Engineering, 1998
- [92] ILA, V. ; POLOK, L. ; SOLONY, M. ; SVOBODA, P. : SLAM++ – A Highly Efficient and Temporally Scalable Incremental SLAM Framework. In: *The International Journal of Robotics Research* 36-2 (2017), S. 210–230
- [93] JOHNSON, A. E. ; HEBERT, M. : Using Spin Images for Efficient Object Recognition in Cluttered 3D Scenes. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence* 21 (5) (1999), S. 433–449
- [94] JUNG, J. ; KIM, J. ; YOON, S. ; KIM, S. ; CHO, H. ; KIM, C. ; HEO, J. : Bore-sight Calibration of Multiple Laser Range Finders for Kinematic 3D Laser Scanning Systems. In: *Sensors* 15-5 (2015), S. 10292–10314
- [95] JUTZI, B. ; GROSS, H. : Nearest Neighbour Classification on Laser Point Clouds to Gain Object Structures from Buildings. In: *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences XXXVIII-1-4-7/W5* (2009), S. 1–6
- [96] JUTZI, B. : *Methoden zur automatischen Szenencharakterisierung basierend auf aktiven optischen Sensoren für die Photogrammetrie und Fernerkundung*, Habilitation, Karlsruhe, Karlsruher Institut für Technologie (KIT), Diss., 2015
- [97] JUTZI, B. ; WEINMANN, M. ; MEIDOW, J. : Improved UAV-borne 3D Mapping by Fusing Optical and Laserscanner Data. In: *UAV-g2013. The international archives of the photogrammetry, remote sensing and spatial information sciences, Rostock, XL-1 W 2* (2013), S. 223–228
- [98] JUTZI, B. ; WEINMANN, M. ; MEIDOW, J. : Weighted Data Fusion for UAV-borne 3D Mapping with Camera and Line Laser Scanner. In: *International Journal of Image and Data Fusion* 5-3 (2014), S. 226–243
- [99] KAESS, M. ; RANGANATHAN, A. ; DELLAERT, F. : iSAM: Incremental Smoothing And Mapping. In: *IEEE Transactions on Robotics* 24-6 (2008), S. 1365–1378
- [100] KALMAN, R. E.: *A New Approach to Linear Filtering and Prediction Problems*. <http://www.cs.unc.edu/~welch/kalman/media/pdf/Kalman1960.pdf>. Version: 1960. – [Online; abgerufen am 25.10.2019]
- [101] KASSIR, A. ; PEYNOT, T. : Reliable Automatic Camera-Laser Calibration. In: *Proceedings of the Australasian Conference on Robotics and Automation*, ARAA, 2010

- [102] KLEIN, G. ; MURRAY, D. : Parallel Tracking and Mapping for Small AR Workspaces. In: *Proceedings of the 2007 6th IEEE and ACM International Symposium on Mixed and Augmented Reality* IEEE Computer Society, 2007, S. 1–10
- [103] KNEIP, L. ; FURGALE, P. : OpenGV: A Unified and Generalized Approach to Real-time Calibrated Geometric Vision. In: *Proceedings of the International Conference on Robotics and Automation (ICRA)*, 2014, S. 1–8
- [104] KNEIP, L. ; LI, H. ; SEO, Y. : UPnP: An Optimal $O(n)$ Solution to the Absolute Pose Problem with Universal Applicability. In: *European Conference on Computer Vision (ECCV)*. Springer, 2014, S. 127–142
- [105] KNYAZ, V. A.: The Development of New Coded Targets for Automated Point Identification and Non-contact 3D Surface Measurements. In: *International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences* 5 (1998), S. 80–85
- [106] KONG, J. ; YAN, L. ; LIU, J. ; HUANG, Q. ; DING, X. : Improved Accurate Extrinsic Calibration Algorithm of Camera and Two-dimensional Laser Scanner. In: *Journal of Multimedia* 8-6 (2013), S. 777–783
- [107] KSCHISCHANG, F. R. ; FREY, B. J. ; LOELIGER, H.-A. u. a.: Factor Graphs and the Sum-product Algorithm. In: *IEEE Transactions on information theory* 47-2 (2001), S. 498–519
- [108] KÜMMERLE, R. ; GRISETTI, G. ; STRASDAT, H. ; KONOLIGE, K. ; BURGARD, W. : g2o: A General Framework for Graph Optimization. In: *2011 IEEE International Conference on Robotics and Automation* IEEE, 2011, S. 3607–3613
- [109] KURILLO, G. ; LI, Z. ; BAJCSY, R. : Wide-area External Multi-Camera Calibration Using Vision Graphs and Virtual Calibration Object. In: *ACM/IEEE International Conference on Distributed Smart Cameras (ICDSC)* IEEE, 2008, S. 1–9
- [110] LAMB, P. : ARToolkit. In: *Human Interface Technology Laboratory (HIT Lab), University of Washington*, <http://www.hitl.washington.edu/artoolkit> (2007)
- [111] LAMBERT, J. ; CLEMENT, L. ; GIAMOU, M. ; KELLY, J. : Entropy-based Sim (3) Calibration of 2D LiDARs to Egomotion Sensors. In: *2016 IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems (MFI)* IEEE, 2016, S. 455–461
- [112] LAWSON, C. L. ; HANSON, R. J.: *Solving Least Squares Problems*. Bd. 15. SIAM, 1995
- [113] LEE, I. ; SCHENK, T. : Perceptual Organization of 3D Surface Points. In: *International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences* 34-3A (2002), S. 193–198
- [114] LEGENDRE, A. M.: *Analyse des triangles tracés sur la surface d'un sphéroïde*. 1806

- [115] LEICA GEOSYSTEMS: *Leica Pegasus Backpack – Wearable Mobile Mapping Solution*. <https://leica-geosystems.com/products/mobile-sensor-platforms/capture-platforms/leica-pegasus-backpack>. Version: 2018. – [Online; abgerufen am 07.01.2020]
- [116] LEICA GEOSYSTEMS: *Leica CityMapper-2 – High-Performance Urban Mapping Sensor*. <https://leica-geosystems.com/de-de/products/airborne-systems/leica-citymapper-2>. Version: 2020. – [Online; abgerufen am 07.01.2020]
- [117] LEUTENEGGER, S. ; CHLI, M. ; SIEGWART, R. : BRISK: Binary Robust Invariant Scalable Keypoints. In: *IEEE international conference on computer vision (ICCV)* (2011), S. 2548–2555
- [118] LEVENBERG, K. : A Method for the Solution of Certain Problems in Least Squares. In: *Quarterly of Applied Mathematics* 2 (1944), S. 164–168
- [119] LI, N. ; HU, Z. ; ZHAO, B. : Flexible Extrinsic Calibration of a Camera and a Two-dimensional Laser Rangefinder with a Folding Pattern. In: *Applied Optics* 55-9 (2016), 03, S. 2270
- [120] LINSEN, L. ; PRAUTZSCH, H. : Local Versus Global Triangulations. In: *Proceedings of EUROGRAPHICS* Bd. 1, 2001, S. 257–263
- [121] LOWE, D. G.: Distinctive Image Features from Scale-invariant Keypoints. In: *International journal of computer vision* 60-2 (2004), S. 91–110
- [122] LUHMANN, T. : *Nahbereichsphotogrammetrie: Grundlagen, Methoden und Anwendungen*. 3. Auflage. Berlin : Wichmann, 2010
- [123] MAAS, H.-G. : Image Sequence Based Automatic Multi-Camera System Calibration Techniques. In: *ISPRS Journal of Photogrammetry and Remote Sensing* 54–5/6 (1999), S. 352–359
- [124] MADDERN, W. ; HARRISON, A. ; NEWMAN, P. : Lost in Translation (and Rotation): Rapid Extrinsic Calibration for 2D and 3D LIDARs. In: *Proceedings of the International Conference on Robotics and Automation (ICRA)* IEEE, 2012, S. 3096–3102
- [125] MADDERN, W. ; PASCOE, G. ; LINEGAR, C. ; NEWMAN, P. : 1 year, 1000 km: The Oxford RobotCar Dataset. In: *The International Journal of Robotics Research* 36-1 (2017), S. 3–15
- [126] MADER, D. ; BLASKOW, R. ; WESTFELD, P. ; MAAS, H. : UAV-based Acquisition of 3D Point Cloud – A Comparison of a Low-cost Laser Scanner and SFM-tools. In: *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences* XL-3/W3 (2015), S. 335–341
- [127] MAIR, E. ; HAGER, G. D. ; BURSCHKA, D. ; SUPPA, M. ; HIRZINGER, G. : Adaptive and Generic Corner Detection Based on the Accelerated Segment Test. In: *European Conference on Computer Vision* (2010), S. 183–196

- [128] MALLET, C. ; BRETAR, F. ; ROUX, M. ; SOERGEL, U. ; HEIPKE, C. : Relevance Assessment of Full-waveform LiDAR Data for Urban Area Classification. In: *ISPRS Journal of Photogrammetry and Remote Sensing* 66 (6) (2011), S. S71–S84
- [129] MARQUARDT, D. W.: An Algorithm for Least-Squares Estimation of Nonlinear Parameters. In: *Journal of the society for Industrial and Applied Mathematics* 11-2 (1963), S. 431–441
- [130] MAYBANK, S. J. ; FAUGERAS, O. D.: A Theory of Self-Calibration of a Moving Camera. In: *International journal of computer vision* 8-2 (1992), S. 123–151
- [131] MOGHADAM, P. ; BOSSE, M. ; ZLOT, R. : Line-based Extrinsic Calibration of Range and Image Sensors. In: *Proceedings of the International Conference on Robotics and Automation (ICRA) IEEE*, 2013, S. 3685–3691
- [132] MONTEMERLO, M. ; THRUN, S. ; KOLLER, D. ; WEGBREIT, B. u. a.: FastSLAM: A Factored Solution to the Simultaneous Localization and Mapping Problem. In: *American Association for Artificial Intelligence* 593598 (2002)
- [133] MUNOZ, D. ; BAGNELL, J. A. ; VANDAPEL, N. ; HEBERT, M. : Contextual Classification with Functional Max-margin Markov Networks. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, IEEE*, 2009, S. 975–982
- [134] MUNOZ-SALINAS, R. : ARUCO: A Minimal Library for Augmented Reality Applications based on OpenCV. In: *Universidad de Córdoba* (2012)
- [135] MUR-ARTAL, R. ; MONTIEL, J. M. M. ; TARDOS, J. D.: ORB-SLAM: A Versatile and Accurate Monocular SLAM System. In: *IEEE Transactions on Robotics* 31-5 (2015), S. 1147–1163
- [136] MUR-ARTAL, R. ; TARDÓS, J. D.: ORB-SLAM2: An Open-source SLAM System for Monocular, Stereo, and RGB-D Cameras. In: *IEEE Transactions on Robotics* 33-5 (2017), S. 1255–1262
- [137] NAIMARK, L. ; FOXLIN, E. : Circular Data Matrix Fiducial System and Robust Image Processing for a Wearable Vision-inertial Self-tracker. In: *Proceedings of the 1st International Symposium on Mixed and Augmented Reality IEEE Computer Society*, 2002, S. 27
- [138] NAPIER, A. ; CORKE, P. ; NEWMAN, P. : Cross-calibration of Push-broom 2D LiDARs and Cameras in Natural Scenes. In: *Proceedings of the International Conference on Robotics and Automation (ICRA), IEEE*, 2013, S. 3679–3684
- [139] NATURALPOINT, INC.: *OptiTrack*. <https://optitrack.com>. Version: 2019. – [Online; abgerufen am 26.04.2019]
- [140] NAVVIS GMBH: *Digitizing indoors – NavVis M6*. <https://www.navvis.com/m6>. Version: 2020. – [Online; abgerufen am 07.01.2020]

- [141] NEIRA, J. ; DAVISON, A. J. ; LEONARD, J. J.: Guest Editorial Special Issue on Visual SLAM. In: *IEEE Transactions on Robotics* 24-5 (2008), S. 929–931
- [142] NEWCOMBE, R. A. ; LOVEGROVE, S. J. ; DAVISON, A. J.: DTAM: Dense Tracking and Mapping in Real-time. In: *2011 International Conference on Computer Vision* (2011), S. 2320–2327
- [143] NIEMEIER, W. : *Ausgleichsrechnung: Statistische Auswertemethoden*. Walter de Gruyter, 2008
- [144] NIEMEYER, J. ; ROTTENSTEINER, F. ; SOERGEL, U. : Contextual Classification of LiDAR Data and Building Object Detection in Urban Areas. In: *ISPRS journal of photogrammetry and remote sensing* 87 (2014), S. 152–165
- [145] NISTÉR, D. ; NARODITSKY, O. ; BERGEN, J. : Visual Odometry. In: *Proceedings of the 2004 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2004. CVPR 2004*. Bd. 1 Ieee, 2004, S. I–I
- [146] NÜCHTER, A. ; BLEIER, M. ; SCHAUER, J. ; JANOTTA, P. : Continuous-Time SLAM – Improving Google’s Cartographer 3D Mapping. In: *Latest Developments in Reality-Based 3D Surveying and Modelling* (2018), S. 53–73
- [147] OSADA, R. ; FUNKHOUSER, T. ; CHAZELLE, B. ; DOBKIN, D. : Shape Distributions. In: *ACM Transactions on Graphics* 21 (4) (2002), S. 807–832
- [148] P. W. THEILER AND J. D. WEGNER AND K. SCHINDLER: Keypoint-based 4-Points Congruent Sets – Automated marker-less registration of laser scans. In: *ISPRS Journal of Photogrammetry and Remote Sensing* 96 (2014), S. 149–163
- [149] PAULY, M. ; KEISER, R. ; GROSS, M. : Multi-scale Feature Extraction on Point-sampled Surfaces. In: *Computer Graphics Forum* 22-3 (2003), S. 281–289
- [150] PHOTOMODELER TECHNOLOGIES: *PhotoModeler*. <https://www.photomodeler.com/>. Version: 2019. – [Online; abgerufen am 15.10.2019]
- [151] PIZZOLI, M. ; FORSTER, C. ; SCARAMUZZA, D. : REMODE: Probabilistic, Monocular Dense Reconstruction in Real time. In: *2014 IEEE International Conference on Robotics and Automation (ICRA)* IEEE, 2014, S. 2609–2616
- [152] POMERLEAU, F. ; COLAS, F. ; SIEGWART, R. u. a.: A Review of Point Cloud Registration Algorithms for Mobile Robotics. In: *Foundations and Trends in Robotics* 4–1 (2015), S. 1–104
- [153] PREMEBIDA, C. ; LUDWIG, O. ; NUNES, U. : LiDAR and Vision-based Pedestrian Detection System. In: *Journal of Field Robotics* 26-9 (2009), S. 696–711
- [154] PUENTE, I. ; GONZÁLEZ-JORGE, H. ; MARTÍNEZ-SÁNCHEZ, J. ; ARIAS, P. : Review of Mobile Mapping and Surveying Technologies. In: *Measurement* 46-7 (2013), S. 2127–2145
- [155] QUALISYS AB: *Qualisys*. <https://www.qualisys.com/>. Version: 2019. – [Online; abgerufen am 15.10.2019]

- [156] RANFTL, R. ; VINEET, V. ; CHEN, Q. ; KOLTUN, V. : Dense Monocular Depth Estimation in Complex Dynamic Scenes. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, S. 4058–4066
- [157] RAVI, R. ; SHAMSELDIN, T. ; ELBAHNASAWY, M. ; LIN, Y.-J. ; HABIB, A. : Bias Impact Analysis and Calibration of UAV-Based Mobile LiDAR System with Spinning Multi-Beam Laser Scanner. In: *Applied Sciences* 8-2 (2018), S. 297
- [158] REHDER, J. ; BEARDSLEY, P. ; SIEGWART, R. ; FURGALE, P. : Spatio-temporal Laser to Visual/inertial Calibration with Applications to Hand-held, Large Scale Scanning. In: *2014 IEEE/RSJ International Conference on Intelligent Robots and Systems*, IEEE, 2014, S. 459–465
- [159] RÉNYI, A. : On Measures of Entropy and Information. In: *Proceedings of the 4th Berkeley Symposium on Mathematics, Statistics and Probability* Bd. 1, University of California Press, 1961, S. 547–561
- [160] ROSTEN, E. ; PORTER, R. ; DRUMMOND, T. : Faster and Better: A Machine Learning Approach to Corner Detection. In: *IEEE transactions on pattern analysis and machine intelligence* 32-1 (2008), S. 105–119
- [161] RUBLEE, E. ; RABAUD, V. ; KONOLIGE, K. ; BRADSKI, G. R.: ORB: An Efficient Alternative to SIFT or SURF. In: *International Conference on Computer Vision (ICCV)* 11-1 (2011), S. 2
- [162] RUSU, R. B. ; BLODOW, N. ; BEETZ, M. : Fast Point Feature Histograms (FPFH) for 3D Registration. In: *Proceedings of the IEEE International Conference on Robotics and Automation*, IEEE, 2009, S. 3212–3217
- [163] RUSU, R. B.: Semantic 3D Object Maps for Everyday Manipulation in Human Living Environments. In: *KI-Künstliche Intelligenz* 24-4 (2010), S. 345–348
- [164] SALTI, S. ; TOMBARI, F. ; DI STEFANO, L. : SHOT: Unique Signatures of Histograms for Surface and Texture Description. In: *Computer Vision and Image Understanding* 125 (2014), S. 251–264
- [165] SCARAMUZZA, D. ; HARATI, A. ; SIEGWART, R. : Extrinsic Self Calibration of a Camera and a 3D Laser Range Finder from Natural Scenes. (2007), S. 4164–4169
- [166] SCARAMUZZA, D. ; MARTINELLI, A. ; SIEGWART, R. : A Flexible Technique for Accurate Omnidirectional Camera Calibration and Structure from Motion. In: *IEEE International Conference on Computer Vision Systems (ICVS)*, 2006, S. 45–45
- [167] SCARAMUZZA, D. ; ZHANG, Z. : Visual-Inertial Odometry of Aerial Robots. In: *arXiv preprint arXiv:1906.03289* (2019)
- [168] SCHMALSTIEG, D. ; HOLLERER, T. : *Augmented Reality: Principles and Practice*. Addison-Wesley Professional, 2016

- [169] SHAN, J. ; TOOTH, C. K.: *Topographic Laser Ranging and Scanning: Principles and Processing*. CRC press, 2018
- [170] SHEEHAN, M. ; HARRISON, A. ; NEWMAN, P. : Self-calibration for a 3D Laser. In: *The International Journal of Robotics Research* 31-5 (2012), S. 675–687
- [171] SHI, J. u. a.: Good Features to Track. In: *Proceedings of IEEE conference on computer vision and pattern recognition* (1994), S. 593–600
- [172] SIM, S. ; SOCK, J. ; KWAK, K. : Indirect Correspondence-Based Robust Extrinsic Calibration of LiDAR and Camera. In: *MDPI Sensors* 16-6 (2016), 06, S. 933–952
- [173] SIMI REALITY MOTION SYSTEMS GMBH: *Simi*. <http://www.simi.com/>. Version: 2019. – [Online; abgerufen am 15.10.2019]
- [174] SKALLOUD, J. ; LICHTI, D. : Rigorous Approach to Bore-sight Self-calibration in Airborne Laser Scanning. In: *ISPRS Journal of Photogrammetry and Remote Sensing* 61-1 (2006), oct, S. 47–59
- [175] STACHNISS, C. ; LEONARD, J. J. ; THRUN, S. : Simultaneous Localization and Mapping. In: *Springer Handbook of Robotics*. Springer, 2016, S. 1153–1176
- [176] STRASDAT, H. ; MONTIEL, J. ; DAVISON, A. J.: Scale Drift-Aware Large Scale Monocular SLAM. In: *Robotics: Science and Systems VI* 2-3 (2010), S. 7
- [177] STRÜBING, T. ; NEUMANN, I. : Positions- und Orientierungsschätzung von LiDAR-Sensoren auf Multisensorplattformen. In: *ZfV* 3 (2013), S. 210–221
- [178] STURM, J. ; ENGELHARD, N. ; ENDRES, F. ; BURGARD, W. ; CREMERS, D. : A Benchmark for the Evaluation of RGB-D SLAM Systems. In: *Proc. of the International Conference on Intelligent Robot Systems (IROS)*, 2012, S. 573–580
- [179] SVOBODA, T. ; HUG, H. ; VAN GOOL, L. : ViRoom - Low Cost Synchronized Multicamera System and its Self-Calibration. In: *Joint Pattern Recognition Symposium* Springer, 2002, S. 515–522
- [180] TAKETOMI, T. ; UCHIYAMA, H. ; IKEDA, S. : Visual SLAM Algorithms: A Survey from 2010 to 2016. In: *IPSJ Transactions on Computer Vision and Applications* 9-1 (2017), S. 16
- [181] TALAYA, J. ; ALAMUS, R. ; BOSCH, E. ; SERRA, A. ; KORNU, W. ; BARON, A. : Integration of a Terrestrial Laser Scanner with GPS/IMU Orientation Sensors. In: *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences* Bd. 35-B5, 2004, S. 1049–1055
- [182] THE CAPTURE GMBH: *The Capture*. <http://www.thecapture.com/>. Version: 2019. – [Online; abgerufen am 15.10.2019]
- [183] THOMSON, C. ; APOSTOLOPOULOS, G. ; BACKES, D. ; BOEHM, J. : Mobile laser scanning for indoor modelling. In: *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 5 (2013), S. W2

- [184] TOMBARI, F. ; SALTI, S. ; DI STEFANO, L. : Unique Signatures of Histograms for Local Surface Description. In: *Proceedings of the European Conference on Computer Vision, Springer*, 2010, S. III:356–III:369
- [185] TRIGGS, W. ; McLAUCHLAN, P. ; HARTLEY, R. ; FITZGIBBON, A. : Bundle Adjustment for Structure from Motion. In: *Vision Algorithms: Theory and Practice 1883* (2000), S. 298–372
- [186] URBAN, S. : *Real-Time Multi-Fisheye Camera Self-Localization and Egomotion Estimation in Complex Indoor Environments*, Dissertation, Karlsruhe, Karlsruher Institut für Technologie (KIT), Diss., 2016
- [187] URBAN, S. ; HINZ, S. : MultiCol-SLAM – A Modular Real-Time Multi-Camera SLAM System. In: *arXiv preprint arXiv:1610.07336* (2016)
- [188] URBAN, S. ; JUTZI, B. : LaFiDa – A Laserscanner Multi-Fisheye Camera Dataset. In: *Journal of Imaging* 3-1 (2017), S. 5
- [189] URBAN, S. ; LEITLOFF, J. ; HINZ, S. : Improved Wide-angle, Fisheye and Omnidirectional Camera Calibration. In: *ISPRS Journal of Photogrammetry and Remote Sensing* 108 (2015), S. 72–79
- [190] URBAN, S. ; WEINMANN, M. ; HINZ, S. : mdBRIEF – A fast Online-adaptable, Distorted Binary Descriptor for Real-time Applications Using Calibrated Wide-angle or Fisheye Cameras. In: *Computer Vision and Image Understanding* 162 (2017), S. 71–86
- [191] URBAN, S. ; WURSTHORN, S. ; LEITLOFF, J. ; HINZ, S. : MultiCol Bundle Adjustment: A Generic Method for Pose Estimation, Simultaneous Self-Calibration and Reconstruction for Arbitrary Multi-Camera Systems. In: *International Journal of Computer Vision (IJCV)* (2016), S. 1–19
- [192] VALGAERTS, L. ; BRUHN, A. ; MAINBERGER, M. ; WEICKERT, J. : Dense Versus Sparse Approaches for Estimating the Fundamental Matrix. In: *International Journal of Computer Vision* 96-2 (2012), S. 212–234
- [193] VASCONCELOS, F. ; BARRETO, J. P. ; NUNES, U. : A Minimal Solution for the Extrinsic Calibration of a Camera and a Laser-Rangefinder. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence (PAMI)* 34-11 (2012), S. 2097–2107
- [194] VIAMETRIS: *Viametris iMS2D*. <https://www.viametris.com/ims2d>. Version: 2020. – [Online; abgerufen am 07.01.2020]
- [195] VICON MOTION SYSTEMS LTD UK: *Vicon*. <https://www.vicon.com/>. Version: 2019. – [Online; abgerufen am 15.10.2019]
- [196] VRMAGIC: *VRmagic VRmC-12/BW OEM (USB-Platform)*, 2016. https://www.vrmagic.com/fileadmin/downloads/imaging/Camera_Datasheets/usb_cameras/VRmMFC_multisensor.pdf

- [197] WALDHAUSER, C. ; HOCHREITER, R. ; OTEPKA, J. ; PFEIFER, N. ; GHUFFAR, S. ; KORZENIOWSKA, K. ; WAGNER, G. : Automated Classification of Airborne Laser Scanning Point Clouds. In: *Koziel, S., Leifsson, L., Yang, X.-S. (Eds.), Solving Computationally Expensive Engineering Problems: Methods and Applications, Springer, 2014, S. 269–292*
- [198] WANG, F. ; SYEDA-MAHMOOD, T. ; VEMURI, B. C. ; BEYMER, D. ; RANGARAJAN, A. : Closed-form Jensen-Renyi Divergence for Mixture of Gaussians and Applications to Group-wise Shape Registration. In: *International Conference on Medical Image Computing and Computer-Assisted Intervention Springer, 2009, S. 648–655*
- [199] WANG, R. ; SCHWORER, M. ; CREMERS, D. : Stereo DSO: Large-scale Direct Sparse Visual Odometry with Stereo Cameras. In: *Proceedings of the IEEE International Conference on Computer Vision (2017), S. 3903–3911*
- [200] WEHR, A. ; LOHR, U. : Airborne Laser Scanning – An Introduction and Overview. In: *ISPRS Journal of photogrammetry and remote sensing 54-2-3 (1999), S. 68–82*
- [201] WEINMANN, M. ; HOEGNER, L. ; LEITLOFF, J. ; STILLA, U. ; HINZ, S. ; JUTZI, B. : Fusing Passive and Active Sensed Images to Gain Infrared-textured 3D Models. In: *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences XXXIX-B1 (2012), S. 71–76*
- [202] WEINMANN, M. ; JUTZI, B. : Fully Automatic Image-based Registration of Unorganized TLS Data. In: *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences XXXVIII-5/W12 (2011), S. 55–60*
- [203] WEINMANN, M. ; JUTZI, B. ; HINZ, S. ; MALLET, C. : Semantic Point Cloud Interpretation Based on Optimal Neighborhoods, Relevant Features and Efficient Classifiers. In: *ISPRS Journal of Photogrammetry and Remote Sensing 105 (2015), S. 286–304*
- [204] WEINMANN, M. ; JUTZI, B. ; MALLET, C. ; WEINMANN, M. : Geometric Features and their Relevance for 3D Point Cloud Classification. In: *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences IV-1/W1 (2017), S. 157–164*
- [205] WEINMANN, M. ; MUELLER, M. ; HILLEMANN, M. ; REYDEL, N. ; HINZ, S. ; JUTZI, B. : Point Cloud Analysis for UAV-borne Laser Scanning with Horizontally and Vertically Oriented Line Scanners–Concept and First Results. In: *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences 42 (2017), S. 399*
- [206] WEINMANN, M. ; WEINMANN, M. ; HINZ, S. ; JUTZI, B. : Fast and Automatic Image-based Registration of TLS Data. In: *ISPRS Journal of Photogrammetry and Remote Sensing 66-6 (2011), S. S62–S70*
- [207] WEINMANN, M. : *Visual Features – From Early Concepts to Modern Computer Vision.* Springer, 2013
- [208] WEINMANN, M. ; JUTZI, B. ; MALLET, C. : Semantic 3D Scene Interpretation: A Framework Combining Optimal Neighborhood Size Selection with Relevant Features. In:

- ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 2-3 (2014), S. 181
- [209] WELCH, G. ; BISHOP, G. ; VICCI, L. ; BRUMBACK, S. ; KELLER, K. ; COLUCCI, D. : High-performance Wide-area Optical Tracking: The Hiball Tracking System. In: *Presence: Teleoperators & Virtual Environments* 10-1 (2001), S. 1–21
- [210] WENDEL, J. : *Integrierte Navigationssysteme: Sensordatenfusion, GPS und Inertiale Navigation*. Oldenbourg Verlag, 2009
- [211] WEST, K. F. ; WEBB, B. N. ; LERSCH, J. R. ; POTHIER, S. ; TRISCARI, J. M. ; IVERSON, A. E.: Context-driven Automated Target Detection in 3-D Data. In: *Proceedings of SPIE 5426, Automatic Target Recognition XIV, SPIE*, 2004, S. 133–143
- [212] YANG, N. ; WANG, R. ; STUCKLER, J. ; CREMERS, D. : Deep Virtual Stereo Odometry: Leveraging Deep Depth Prediction for Monocular Direct Sparse Odometry. In: *Proceedings of the European Conference on Computer Vision (ECCV)* (2018), S. 817–833
- [213] ZHANG, Q. ; PLESS, R. : Extrinsic Calibration of a Camera and Laser Range Finder (Improves Camera Calibration). In: *Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)* Bd. 3 IEEE, 2004, S. 2301–2306
- [214] ZHANG, Z. : A Flexible New Technique for Camera calibration. In: *IEEE Transactions on pattern analysis and machine intelligence* 22-11 (2000), S. 1330–1334
- [215] ZHENG, Y. ; KUANG, Y. ; SUGIMOTO, S. ; ASTROM, K. ; OKUTOMI, M. : Revisiting the PnP Problem: A Fast, General and Optimal Solution. In: *International Conference on Computer Vision (ICCV)*, 2013, S. 2344–2351
- [216] ZHOU, L. : A New Minimal Solution for the Extrinsic Calibration of a 2D LiDAR and a Camera Using Three Plane-Line Correspondences. In: *IEEE Sensors Journal* 14-2 (2014), 02, S. 442–454

Danksagung

Zunächst möchte ich mich herzlich bei meinem Doktorvater Boris Jutzi für die tolle Betreuung während meiner Promotion und die langjährige Zusammenarbeit bedanken. Mein Dank gilt ebenso Jochen Meidow, der mir in dieser Zeit stets mit Rat und Tat zur Seite gestanden hat. Da ich meine Promotion zu gleichen Teilen am Institut für Photogrammetrie und Fernerkundung des Karlsruher Instituts für Technologie und in der Abteilung Szenenanalyse des Fraunhofer Instituts für Optronik, Systemtechnik und Bildauswertung in Ettlingen durchgeführt habe, möchte ich mich bei Stefan Hinz und bei Karsten Schulz dafür bedanken, dass sie mir die Promotion ermöglicht haben. Des weiteren möchte ich mich bei allen Freunden und Kollegen von IPF und SZA für die Diskussionen, die Zusammenarbeit, die angenehme Atmosphäre und die privaten Unternehmungen bedanken. Insbesondere möchte ich mich noch bedanken bei:

Markus Müller, Jens Kern, Andreas Lenz und Eckehard Bernstein, dafür, dass ihr mich im Büro ausgehalten habt.

Steffen Urban und Clémence Dubois für eure Freundschaft und dafür, dass ihr einen Teil dazu beigetragen habt, dass ich diese Fachrichtung für mich entdeckt und diesen Weg eingeschlagen habe.

Meiner Familie für die unbegrenzte Unterstützung auf all meinen Wegen.

Zu guter Letzt möchte ich mich bei Maryse bedanken fürs Korrekturlesen und die Unterstützung auf diesem Lebensabschnitt, dafür, dass du so bist, wie du bist, für unsere bisherige gemeinsame Zeit und für die, die noch vor uns liegt.

