

Alexander Fietz

**Ableitung von Bewegungsstrategien
zur automatisierten, vollständigen Vermessung
von Innenraumszenen auf autonom navigierender Plattform**

München 2012

**Verlag der Bayerischen Akademie der Wissenschaften
in Kommission beim Verlag C. H. Beck**



DGK Deutsche Geodätische Kommission
bei der Bayerischen Akademie der Wissenschaften

Reihe C

Dissertationen

Heft Nr. 685

**Ableitung von Bewegungsstrategien
zur automatisierten, vollständigen Vermessung
von Innenraumszenen auf autonom navigierender Plattform**

Von der Fakultät Luft- und Raumfahrttechnik und Geodäsie
der Universität Stuttgart
zur Erlangung der Würde eines
Doktors der Ingenieurwissenschaften (Dr.-Ing.)
genehmigte Abhandlung

Vorgelegt von
Alexander Fietz
aus Waiblingen

München 2012

Verlag der Bayerischen Akademie der Wissenschaften
in Kommission beim Verlag C. H. Beck

Adresse der Deutschen Geodätischen Kommission:



Deutsche Geodätische Kommission

Alfons-Goppel-Straße 11 • D – 80 539 München

Telefon +49 – 89 – 23 031 1113 • Telefax +49 – 89 – 23 031 -1283 / - 1100

e-mail hornik@dgfi.badw.de • <http://www.dgk.badw.de>

Hauptberichter: Prof. Dr.-Ing. habil. Dieter Fritsch

Mitberichter: Prof. Dr.rer.nat. habil. Paul Levi

Tag der mündlichen Prüfung: 08.03.2012

© 2012 Deutsche Geodätische Kommission, München

Alle Rechte vorbehalten. Ohne Genehmigung der Herausgeber ist es auch nicht gestattet,
die Veröffentlichung oder Teile daraus auf photomechanischem Wege (Photokopie, Mikrokopie) zu vervielfältigen.

Zusammenfassung

Die Selbstlokalisierung eines autonomen mobilen Roboters in der Umgebung bzw. in der ihm zur Verfügung stehenden Karte ist eine seiner grundlegenden Aufgaben. Eine präzise Lokalisierung ist für viele Applikationen notwendig. Eine Voraussetzung dafür ist das Vorliegen einer genauen und vollständigen Karte. Während die durch den Roboter erzeugte Karte bei typischen Robotikanwendungen ein notwendiges Nebenprodukt darstellt, rückt diese bei einer Betrachtung von vermessungstechnischer Seite in den Fokus. Es stellt sich die Frage, inwiefern sich die gesammelten Raumdaten bezüglich der Genauigkeit, der Vollständigkeit und des Detaillierungsgrades für eine Umgebungskartierung eignen, die den Anforderungen eines menschlichen Nutzers genügt. Im Alltag benötigt dieser exakte Modelle von Innenräumen, deren Beschaffung häufig mit großem Aufwand verbunden ist. Eine vollautomatische Generierung dieser Innenraummodelle wäre für ihn daher wünschenswert.

Die folgende Arbeit soll hierzu einen Beitrag leisten und versucht die Verfahren und Mittel zusammenzustellen, die notwendig sind, um das Modell einer Innenraumszene quasi „per Knopfdruck“ zu erhalten. Konzipiert wurde ein mobiles Messsystem, durch das sich Innenraumumgebungen vollständig und mit möglichst hoher Genauigkeit in 2D als auch in 3D einmessen lassen. Der Aufbau des Messsystems erfolgte in zwei Stufen. In einer Basisstufe wurde eine mobile Plattform mit einem Low-Cost Laserscanner ausgestattet, um eine 2D-Exploration von Innenraumszenen zu ermöglichen. In einer Ausbaustufe erlaubt die Anbringung einer Digitalkamera eine zusätzliche 3D-Rekonstruktion, basierend auf der Anwendung photogrammetrischer Methoden.

Die Qualität bzw. die Genauigkeit der durch einen Roboter erstellten Karte hängt wesentlich von der verwendeten Sensorik ab. Hinzu kommen softwareseitige Prozesse, die die im Laufe der Zeit gesammelten Daten in einem gemeinsamen Modell registrieren. Im Bereich der scannenden Systeme sind dies z.B. das Scan-Matching oder probabilistische Filterverfahren. Im 3D-Fall kann eine photogrammetrische Rekonstruktion durch die Schätzung der aus einem Bildverband extrahierten Merkmalspunkte über einen Bündelausgleich erfolgen. Die Resultate dieser Prozesse lassen sich optimieren, wenn deren Anforderungen und Restriktionen im Verlauf der Datenakquisition, also der Exploration der Umgebung durch den Roboter, berücksichtigt werden. Entscheidend ist hier die räumliche Platzierung des Sensors zu einem bestimmten Zeitpunkt des Akquiseprozesses. Zur Steuerung der Sensorplatzierungen bei einer Exploration werden in der Robotik Positionierungsstrategien eingesetzt, die in der Regel allen weiteren Prozessen übergeordnet sind. Ein Großteil der bekannten Strategien hat das primäre Ziel einer effizienten Erfassung bzw. Exploration, so dass jede Messung einen möglichst hohen Anteil neuer Umgebungsinformationen mit sich bringt, während die Anforderungen der Registrierungsverfahren vernachlässigt werden. In dieser Arbeit werden Positionierungsstrategien für die scannende 2D-Vermessung als auch die photogrammetrische 3D-Vermessung vorgestellt, deren primäres Ziel dagegen eine Genauigkeitsmaximierung der resultierenden Raumdaten ist.

Im ersten Teil der Arbeit wird ein scannendes 2D-Messsystem vorgestellt, das in der Lage ist, unbekannte Innenraumszenen zu erkunden und exakte Grundrisspläne von diesen zu erstellen. Dabei fährt das System iterativ Messposen an, die durch eine Positionierungsstrategie bestimmt werden. Die an den einzelnen Messpositionen aufgezeichneten 2D-Punktwolken werden über ein Scan-Matching Verfahren

in einem gemeinsamen Koordinatensystem registriert. Das Verfahren macht sich die charakteristische Erscheinungsform von Büroumgebungen zu nutze und extrahiert ebene Segmente aus den gemessenen Punktwolken (Manhattan-Geometrie). Über eine Minimierung der Summe der Lotabstände zu diesen Segmenten werden die Punkte einer weiteren Aufnahme mit hoher Genauigkeit im bestehenden Koordinatensystem registriert. Eine iterative Parameterverfeinerung macht das Verfahren sowohl präzise als auch robust.

Das Messsystem verwendet eine Positionierungsstrategie, die auf einer globalen Betrachtung der Umwelt als Verkettung von Liniensegmenten beruht. Da die Enden dieser Segmente auf Datenlücken hinweisen, wird über diese die Exploration einer Szene bis zu deren vollständiger Erfassung vorangetrieben. Die Strategie beurteilt alle, durch ein Belegtheitsgitter gegebenen, zugänglichen Messpositionen über eine Kostenfunktion hinsichtlich ihres Nutzens für die Exploration. Eine Szene wird als exploriert betrachtet, sobald jeder Bereich mit einer geforderten Auflösung observiert wurde.

Der zweite Teil der Arbeit stellt eine Positionierungsstrategie vor, durch die sich ein Aufnahmeverband aufnehmen lässt, mit dem eine photogrammetrische Rekonstruktion möglich ist. Bereits vor der eigentlichen Aufnahme werden mögliche Posenkonfigurationen über eine Genauigkeitsabschätzung eruiert. Die Annahme, sich in ebenen Umgebungen zu bewegen, ermöglicht eine Einschränkung der Wahl möglicher Kameraposen auf ein vereinfachtes Suchproblem im \mathbb{R}^2 . Ausgangsinformation der Posebestimmung ist die 2D-Umgebungskarte, die sich durch das im ersten Teil der Arbeit vorgestellte System erstellen lässt. Aus dieser werden iterativ pseudozufällige Posenkonstellationen für definierte Umgebungsbereiche abgeleitet und anhand einer Kostenfunktion miteinander verglichen. Die Kostenfunktion versucht die im Bündelausgleich entstehenden Varianzen der Objektpunkte abzuschätzen. Dies ist möglich, indem auch das funktionale Modell des Bündelausgleichs auf den \mathbb{R}^2 abgebildet wird, wobei ein 2D-Richtungsnetz entsteht. Form und Größe der resultierenden Fehlerellipsen lassen Rückschlüsse auf die Güte möglicher Kameraposen zu und erlauben eine vergleichende Evaluierung. Ein wesentlicher Teil der Arbeit beschäftigt sich mit der empirischen Evaluierung der Systeme, um deren Leistungsvermögen und die Güte der resultierenden Raumdaten zu erörtern. Anhand von Versuchen in realen Umgebungen wird die praktische Anwendbarkeit der entwickelten Messverfahren belegt. In verschiedenen Versuchsreihen werden Anfangsbedingungen und Eingangsgrößen variiert, um deren Einfluss auf den Messprozess bzw. das Messergebnis herauszufinden. Um verlässliche Genauigkeitsaussagen treffen zu können, wurden anhand tachymetrischer Einmessungen Raummodelle der Versuchsumgebungen für referenzierende Vergleiche erzeugt.

Im Falle der scannenden Vermessung belegen die Experimente, dass das entwickelte Messsystem auch komplexe Innenraumszenarien einzumessen und zu explorieren vermag. Eine Betrachtung der erstellten Punktwolke zeigt, dass deren Genauigkeit vielen vermessungstechnischen Ansprüchen genügt und das Verfahren diesbezüglich herkömmlichen Messmitteln überlegen ist. Bei einer anschließenden Modellierung werden jedoch feinere Umgebungsstrukturen fälschlich abgebildet oder gehen ganz verloren. Auch die 3D-Messstrategie ist existierenden Strategien nachweislich überlegen. Das rein passive Verfahren führt jedoch zu Punktwolken, die nicht dicht genug sind, um mit entsprechender Software detaillierte Umgebungsmodelle erzeugen zu können.

Abstract

A fundamental task of an autonomous mobile robot is the ability of self-localization in its environment respectively in a map of it, available to the robot. Many applications require a localization that is as precise as possible. Thereby, a decisive factor is the accuracy but also the completeness of the map. The generated map can usually be seen as a necessary side-product. When considered from a surveying point of view, it is brought more into focus. The question is to what extent the spatial robot data can fulfill certain mapping requirements in terms of accuracy and completeness in a detailed enough manner to be useful to human users. Precise models of indoor environments are very useful in both public and private sectors. But since their procurement involves a great deal of effort, an automatical generation of indoor models is desirable.

The following thesis should make a contribution to this and tries to compose the techniques that are necessary to deliver interior models at the push of a button. Therefore, a mobile measuring system was designed, that is able to carry out complete and precise measurements of indoor environments. The system was build up in two stages. A mobile platform is equipped with a low-cost laser scanner in the basic stage. This build-up allows a precise exploration of indoor scenes in 2D. In an expansion stage the installation of a digital camera leads to an additional 3D reconstruction based on photogrammetric techniques.

The accuracy and quality of robotic mapping is primarily dependent on the sensors that are used. The software process to register the collected data in a common coordinate frame and to create a holistic map of the environment has an additional influence. In the field of scanning systems scan matching techniques or probabilistic filter approaches are used. In the case of 3D surveying, a photogrammetric reconstruction can be done by an estimation of feature points, which are extracted from a photo block, within a bundle adjustment process. Results can be optimized, if requirements and restrictions of these techniques are regarded in the data acquisition process, when the robot proceeds the exploration. A crucial aspect is the spatial sensor placement at a certain point of time in this process. In the field of robotics, sensor placement is controlled by positioning strategies, which normally are of overriding importance to all other processes. The majority of known positioning strategies have the primary aim to optimize the efficiency of the exploration, so that every measurement provides as much new spatial information as possible. Requirements of the data registration technique are neglected in contrast. This thesis presents positioning strategies for scanning 2D measurements as well as photogrammetric 3D measurements, that try to maximize the accuracy of the collected spatial data.

A scanning 2D measuring system, that is able to explore previously unknown indoor environments and generate precise floor plans is presented in the first part of this thesis. The system iteratively visits measurement poses defined by a positioning strategy. 2D point clouds, collected at various positions, are transformed into a common coordinate system by the use of a scan matching technique. The latter takes advantage of the characteristic manifestation of office environments and extracts planar segments from the measured point clouds. Minimizing the sum of perpendicular distances to these segments, points of a new scan are transformed into the existing coordinate system with high accuracy. Precision and robustness are improved through iterative parameter refinement. The measuring system uses a

positioning strategy, which is based on the global assumption that the environment can be described as a collection of line segments. Since segment ends indicate data gaps, exploration is pushed until their observation is complete. All accessible measuring positions, represented in an occupancy grid, are evaluated in terms of their explorative benefit by the strategy using a cost function. Exploration is stopped as soon as every section is observed with a desired resolution.

The second part of this work presents a positioning strategy to enable the recording of photo blocks, that are suitable for a photogrammetric reconstruction. In the run-up of data acquisition possible pose configurations are determined using an accuracy estimation. The assumption of plain environments allows a limitation to a 2D search problem regarding the choice of possible camera poses, whereby the combinatorial variety is reduced. Initial information of pose estimation provides a 2D map, generated by the system structure that was presented in the first part of this work. For predefined sections of the environment, pseudo-random pose constellations are derived iteratively from the map and compared with each other using a cost function. The cost function helps to predict the variances resulting from a bundle adjustment. Therefore the functional model of the bundle adjustment has to be projected on the \mathbb{R}^2 in a way that a geodetic network consisting of direction measurements remains. The size and the shape of the resulting error ellipses allow conclusions and a comparative consideration regarding the quality of camera pose candidates.

An essential part of the work is the empirical analysis of the systems, to evaluate their performance and the quality of the resulting spatial data. Various experiments in real indoor environments show that developed measurement methods can be applied in practice. In different sets of experiments initial conditions are varied to find out their influence on the measurement process or the result. In order to achieve reliable results, reference models of the experimental environments were created by the use of a total station.

In the case of scanner measurements, experiments show that the developed system is able to explore and measure also complex interiors. An examination of the point clouds show that the achieved accuracy comes up with surveying demands. On this issue, the presented technique outplays conventional measuring equipment. However, additional modeling shows that mainly fine structures of the environment are displayed wrongly or are even lost completely. Also the 3D measuring strategy is demonstrably superior to existing techniques. The purely passive technique leads to sparse point clouds, not dense enough to derive detailed environment models with the corresponding software.

Inhaltsverzeichnis

Zusammenfassung	3
Abstract	5
Abkürzungsverzeichnis	7
1 Einleitung	11
1.1 Motivation	11
1.2 Zielsetzung	13
1.3 Gliederung	13
2 Grundlagen	15
2.1 Repräsentation der Umgebung für mobile Roboter	15
2.1.1 Konfigurationsraum	15
2.1.2 Karten	16
2.2 Lokalisierung	19
2.2.1 Koppelnavigation	20
2.2.2 Scan-Matching	21
2.2.3 Probabilistische Lokalisierungsverfahren	22
2.3 Robotische Exploration von 2D-Umgebungen	24
2.3.1 Bewegungsplanung	24
2.3.2 Explorationsstrategien	26
2.4 3D-Gebäuderekonstruktion	29
2.4.1 Photogrammetrische Rekonstruktion von Innenräumen	32
2.4.2 Robotische Ansätze zur 3D-Umgebungserfassung	35
2.5 Fazit	37
3 Exploration und Vermessung von Innenraumszenen im \mathbb{R}^2	39
3.1 Hardware 2D-RDM mobile	40
3.2 Belegtheitsgitter	43
3.3 Lokale Bewegungsplanung	44
3.4 Explorationsstrategie	45
3.4.1 Repräsentation der Umgebung	45
3.4.2 Globale Bewegungsplanung	45
3.4.3 Verwaltung von Messdaten	52
3.5 Scan-Matching	54
3.5.1 Matching 1. Näherung (<i>ENM</i>)	55
3.5.2 Iteratives kleinste Quadrate Matching (<i>IKQM</i>)	58

4	Evaluierung des 2D-Messsystems	63
4.1	Gewichtungsoptimierung der Kostenfunktion	63
4.2	Lokalisierungsgenauigkeit des Scan-Matchings	64
4.3	Lokalisierungsgenauigkeit der Odometrie	66
4.4	Variation der Datendichte	67
4.5	Variation der Startposition	69
4.6	Vergleich mit herkömmlichen Messmitteln	69
4.7	Exploration komplexer Innenraumszenen	71
4.8	Vergleich der Raummodelle	73
4.9	Diskussion	75
5	Photogrammetrische Vermessung von Innenraumszenen	78
5.1	Systemkomponenten	79
5.1.1	Hardware 3D-RDM mobile	79
5.1.2	Rekonstruktionsmodul	79
5.2	Photogrammetrische Positionierungsstrategie	83
5.2.1	Restriktionen	83
5.2.2	Präparation gegebener Daten	85
5.2.3	A priori Genauigkeitsbetrachtung	86
5.2.4	Strategie zur Wahl von Kameraposen	89
5.3	Gesamtablauf der photogrammetrischen Rekonstruktion	93
5.3.1	A priori Behandlung von Subkonfigurationen	95
5.3.2	Abfolge angefahrener Posen	96
5.3.3	Aufnahme und Rekonstruktion	96
5.3.4	A posteriori Behandlung von Subkonfigurationen	98
5.3.5	Skalierung und Registrierung	98
6	Evaluierung des 3D-Messsystems	102
6.1	Evaluierung mittels synthetischer Daten	102
6.1.1	Vergleich der Strategien	104
6.1.2	Gewichtungsoptimierung der Kostenfunktion	105
6.1.3	Variation der Redundanz	106
6.1.4	Variation der Diskretisierungsdichte	107
6.1.5	Variation der Merkmalsverteilung	108
6.1.6	Variation der Iterationen	110
6.1.7	Auswirkung von Fehlmessungen auf die Parameterschätzung	111
6.2	Empirische Evaluierung	112
6.2.1	Parametervariationen	114
6.2.2	Untersuchung der Wiederholungsgenauigkeit	117
6.2.3	Variation der Redundanz	117
6.2.4	Variation der Merkmalsdichte	118
6.2.5	Vergleich mit Photosynth Strategie	119
6.2.6	Analyse von Einzelpunktabständen	120
6.2.7	Vergleich der ermittelten Varianzen mit der Schätzung	121

6.2.8	Vergleich des Tachymetermodells mit einem automatisch generierten Modell . . .	124
6.3	Diskussion	125
	Fazit	129
A	Anhang	131
A.1	Odometrie	131
A.2	Linien- und Geradensegmente	131
A.3	Algorithmen zur graphenbasierten Pfadsuche	131
A.4	Ausgleichsrechnung	133
A.4.1	Allgemein	133
A.4.2	Bündelausgleich	136
A.4.3	Gesamtspurminimierung	138
A.5	SIFT - Scale Invariant Feature Transform	140
A.6	Messgenauigkeit 2D-RDM	141
A.7	Ungarische Methode	141
A.8	Projektionsfilter	143
A.9	Messinstrumente	144
A.10	Korrelationskoeffizient	144
A.11	Untersuchung der Odometriegenauigkeit	145
A.12	Abbildungen zu Kapitel 4.4	146
A.13	Abbildungen zu Kapitel 4.5	147
A.14	Konfigurationsdatei des Rekonstruktionsmoduls	148
A.15	Definition der Genauigkeit	149
A.15.1	Messunsicherheit nach GUM	149
A.15.2	Genauigkeitsmaße von Messreihen	149
A.15.3	Genauigkeitskriterien geodätischer Netze	150
A.16	Min-Cut-Max-Flow-Theorem	152
A.17	Registrierung mittels Singulärwertzerlegung	153
	Literaturverzeichnis	153
	Danksagung	161
	Lebenslauf	162

Abkürzungsverzeichnis

APD	A valanche P hoto D iode
BBF	B est B in F irst
BMV	B undle final full M in V iews
CAD	C omputer A ided D esign
DEM	D igital E levation M ap
DLE	D igitaler L aserentfernungsmesser
DoG	D ifference of G aussian
EKF	E xtended K alman F ilter
EMV	E inmessversuch
ENM	E rste N äherung M atching
EZM	E ntfernung Z um M esspunkt
GPS	G lobal P ositioning S ystem
GUM	G uide to the expression of U ncertainty in M easurement
ICP	I terative C losest P oint
IDC	I terative D ual C orrespondences
IKQM	I teatives K leinste Q uadrant M atching
LoG	L aplacian of G aussian
LPA	L ifelong P lanning A *
MbICP	M etric based I CP
ORE	O utlier R eprojection E rror
PMVS	P atch-based M ulti- V iew S tereo
PTAM	P arallel T racking A nd M apping
RANSAC	R ANdOm S Ample C onsensus
RBPF	R ao B lackwellised P article F ilter
RDM	R oom D ata M easurer
RDT	R apidly exploring D ense T ree
RRT	R apidly exploring R andom T ree
SIFT	S cale I nvariant F eature T ransform
SLAM	S imultaneous L ocalization A nd M apping
SVD	S ingular V alue D ecomposition
TOF	T ime O f F light
TSP	T ravelling S alesman P roblem

1 Einleitung

1.1 Motivation

Es ist ein Jahrhunderte alter Wunsch des Menschen zeit- und kraftintensive Arbeitsgänge von Maschinen erledigen zu lassen. Ansätze zur Entwicklung solcher sogenannten *Automaten* lassen sich bis in die Antike zurückführen. Das im Jahre 1921 erschienene Drama „Rossum’s Universal Robots“ von Karel Čapek¹ bildet die Geburtsstunde des Namens, mit dem ein wesentlicher Teil heutiger Automaten bezeichnet wird.

Die völlig unterschiedlichen Einsatzgebiete gegenwärtiger Roboter bringen diverse Ausprägungsformen mit sich. Das Spektrum reicht von stationären Industrierobotern zur Durchführung von Schweißarbeiten bis hin zu „sozialen“ Robotern, die zur Unterstützung der Pflege alter Menschen, aber auch für deren soziale Bedürfnisse, als Ersatz des Menschen genutzt werden.

Eine Klasse von Robotern bilden die *autonomen mobilen Roboter*. Diesem Robotertyp ist es möglich, sich mehr oder weniger frei und mit einem gewissen Grad an Selbständigkeit in seiner Umgebung zu bewegen. Für eine präzise Lokalisierung sowie eine sichere Navigation benötigen die Roboter Karten ihrer Umgebung. Wenn ihnen diese nicht bereits „a priori“ vorliegen, müssen die Roboter in der Lage sein, eine Kartierung anhand der von ihnen gesammelten Sensordaten selbstständig durchzuführen. Die Genauigkeit und die Detaillierung der Umgebungskarten hängt dabei maßgeblich von der Wahl der Sensoren ab. Applikationsbedingt steht modernen Robotern zur Interaktion mit ihrer Umwelt eine Vielzahl von möglichen Aktoren und Sensoren zur Verfügung. Im Bereich der Aktorik finden vorwiegend taktile Systeme Verwendung, wenn deren Einsatz erforderlich ist. Auf sensorischer Seite sind dies überwiegend Kameras für eine projektive Umfeldabbildung und scannende Systeme, durch die eine Umwelterfassung in 2D oder 3D möglich ist.

Im wissenschaftlichen Umfeld existieren bereits robotische Systeme, die die Genauigkeitsanforderungen einer Vermessungsaufgabe erreichen können [6, 101]. Als Sensoren dieser Systeme werden in der Regel Laserscanner verwendet, deren Einsatz bisher mit hohen Kosten verbunden ist.

Architekten und Handwerker, aber auch andere Berufsgruppen beschäftigen sich häufig mit der baulichen Veränderung von Innenräumen. Eine modellhafte Darstellung von Innenraumszenen dient diesen Gruppen als Grundlage von weiteren Planungs- bzw. Arbeitsschritten. Abhängig von der Aufgabe variieren deren Anforderungen an das Modell hinsichtlich des Detaillierungsgrades sowie der notwendigen Genauigkeit. In allen Fällen geht der Modellbildung eine Vermessung des Objektes voraus. Zur Erfassung der Bausubstanz können dabei unterschiedlichste Messsysteme zum Einsatz kommen. Das Spektrum reicht hier vom einfachen Zollstock bis zu modernsten Messgeräten wie Laserentfernungsmessern und terrestrischen Laserscannern.

Trotz einer zunehmenden Automatisierung des Messprozesses stellt die Vermessung einen Arbeitsschritt dar, der mit erheblichem Kosten- und Zeitaufwand verbunden ist. Abgesehen von den steigenden Kosten der immer komplexer werdenden Messsysteme, nehmen auch die Anforderungen an deren Nutzer zu. Fehlende vermessungstechnische Fachkenntnisse können zu einer Überforderung im

¹Karel Čapek: * 9. Januar 1890 in Malé Svatoňovice, Tschechien; † 25. Dezember 1938 in Prag, Tschechien. Tschechischer Schriftsteller

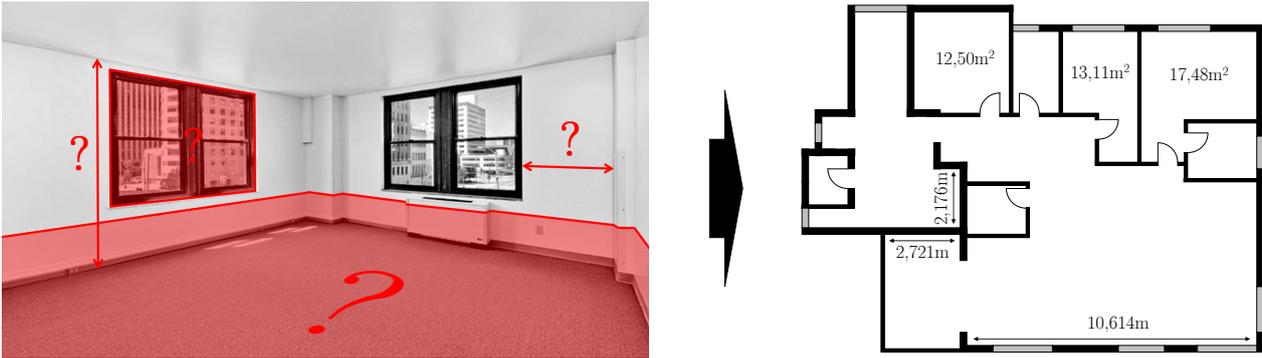


Abb. 1.1: Beispiel einer Modellbildung in Form eines Grundrissplans mit Längen- und Flächenmaßen [7]

Umgang mit der Gerätschaft und damit zu einer fehlerhaften Datenerfassung führen.

Bei der Modellbildung werden die gesammelten Messdaten in ein Format konvertiert, das dem Nutzer eine Interpretation und Weiterverarbeitung der Daten erleichtern soll. Eine generelle Definition dieses Formats ist nicht möglich, sondern abhängig von der individuellen Applikation. Auch in diesem Zusammenhang bilden fundierte Fachkenntnisse des Nutzers eine wichtige Voraussetzung. Für eine optimale Wertschöpfung muss dieser in der Lage sein, das vorliegende Modell zu verstehen und die für ihn relevanten Informationen daraus zu entnehmen.

Die Problematik, ein komplexes und hochtechnologisches System einem fachfremden Nutzer zugänglich und für diesen handhabbar zu machen, tritt heutzutage vermehrt auf². Ein hoher Grad an Automatisierung und nutzerfreundliche Bedienerschnittstellen (HMI's³) sollen den Umgang mit diesen Systemen selbsterklärend machen. So wird auch im Bereich der Vermessung die Entwicklung von Geräten angestrebt, die per Plug & Play genutzt werden können. Auch seitens der Modellierung wird, speziell im Bereich scannender Systeme, die Entwicklung von Software vorangetrieben, mit der es möglich ist, halb- oder sogar vollautomatisch Modelle aus den erfassten Daten zu generieren.

So steht diese Automatisierung in engem Kontext mit dem Technologiefeld der Robotik. Dies bildet die Motivationsgrundlage für die vorliegende Arbeit im Feld der automatisierten Innenraumvermessung. Die Thematik wird dabei von ingenieurstechnischer Seite betrachtet. Es wurde versucht ein System zu konzipieren, dessen Gesamtkosten auf einem Niveau für die angesprochenen Nutzergruppen liegen. Durch eine ausführliche Evaluierung wird das Leistungsvermögen des Systems in realen Anwendungen geprüft und damit dessen Produktfähigkeit nachgewiesen.

Ein Szenario, welches der heutigen Praxis näher steht als eine robotische Vermessung, ist eine manuelle Bewegung der Messsensoren durch den menschlichen Nutzer selbst. Die notwendigen Verfahren zur Datenverarbeitung bzw. -registrierung bleiben gleich. So wird hierfür im 2D-Fall ein Scan-Matching Verfahren verwendet. Im 3D-Fall erfolgt eine gemeinsame Registrierung aller Daten anhand eines Bündelausgleichs. Um eine erfolgreiche Anwendung der Verfahren gewährleisten zu können, müssen verfahrensspezifische Restriktionen bei der Wahl der Standorte eingehalten werden. Die in dieser Arbeit angewandten Bewegungsstrategien berücksichtigen diese Restriktionen. So ist auch eine Verwendung der entwickelten Strategien im manuellen Betrieb sinnvoll. Dem menschlichen Nutzer könnte während einer Messaufgabe mitgeteilt werden, welche Umgebungsbereiche noch nicht vollständig beobachtet sind. Zusätzlich könnten Vorschläge unterbreitet werden, welcher nächste Standort bzw. Standortbereich für eine erfolgreiche und effiziente Fortführung der Messaufgabe zu besuchen ist.

²wie z.B. im Automobil- oder Computerbereich

³Human Machine Interface

1.2 Zielsetzung

Grundsätzliches Ziel dieser Arbeit war es ein mobiles autonomes System zur Vermessung von Innenraumszenen unter dem Gesichtspunkt einer möglichen Kommerzialisierung als Produkt zu entwickeln (Einsatz vergleichsweise preisgünstiger Komponenten). Der Entwicklungsfokus lag dabei auf den Strategien zur Sensorpositionierung.

Im Falle der 2D-Vermessung bilden robotische Systeme, die eine unbekannte Umgebung zu explorieren vermögen, den Stand der Wissenschaft. Die durch die Systeme erstellten Karten bzw. Punktwolken versprechen aufgrund der Präzision der eingesetzten Sensoren, aber auch wegen der immer ausgereiften Kartierungsverfahren eine hohe Genauigkeit. An expliziten Untersuchungen und Nachweisen der Qualität dieser Raumdaten mangelt es jedoch bisher. Ein Bestreben dieser Arbeit ist es deshalb, die Güte einer durch einen autonomen Messroboter erstellten Karte zu eruieren. Dies beinhaltet unter anderem die Anwendung von Modellierungsalgorithmen auf die Raumdaten. Normalerweise stellt nur das Modell einer Szene ein Format dar, das dem menschlichen Nutzer für weiterführende Applikationen als Datenbasis dienen kann. So fokussiert sich die Entwicklung des Messsystems darauf, die bestehenden robotischen Verfahren mit dem Ziel auszulegen, die Qualität der hervorgehenden Modelldaten zu optimieren.

Photogrammetrische Mess- bzw. Rekonstruktionsverfahren werden bisher nur bedingt für Innenraumapplikationen eingesetzt, was sich auf die dafür nur bedingt geeignete Beschaffenheit des Messprinzips zurückführen lässt. Existierende Ansätze basieren vorwiegend auf handgehaltenen Geräten [33, 74]. Für eine adäquate Positionierung des Sensors werden hier lediglich grobe Empfehlungen ausgesprochen. Es mangelt an Strategien, die konkret anleiten, wie eine Kamera durch eine Innenraumszene zu bewegen ist. Daraus ergibt sich das primäre Ziel des zweiten Teils dieser Arbeit. Dessen wesentlicher wissenschaftliche Beitrag ist es eine Strategie abzuleiten, die vorgibt welche Posen mit einer Kamera besucht werden müssen, um einen Bildverband einer Innenraumszene aufzunehmen, der dessen vollständige Rekonstruktion ermöglicht. Eine Randbedingung dabei ist, dass sich aus dem Bildverband ausreichend Punktmerkmale extrahieren bzw. Punktkorrespondenzen zuordnen lassen, um die Aufnahmen anhand eines Bündelausgleichs auswerten zu können. Auch hier erfolgt eine Eruierung der Rekonstruktionsergebnisse, um deren Brauchbarkeit für Modellierungszwecke zu ermitteln.

1.3 Gliederung

In Kapitel 2 werden die robotischen Methoden erläutert, die zur Entwicklung eines autonomen mobilen Messsystems notwendig sind. Es werden die verschiedenen Kartentypen erörtert, durch die ein Roboter seine Umgebung repräsentieren kann, sowie mögliche Definitionen der Roboterkonfiguration innerhalb der Karte. In engem Zusammenhang zur Kartenbildung steht die Aufgabe der Selbstlokalisierung. Verschiedene Lokalisierungsprobleme werden aufgezeigt sowie bestehende Verfahren zu deren Lösung erörtert. Es folgt eine Zusammenstellung von Verfahren zur lokalen und globalen Bewegungsplanung. Die lokalen Methoden beschäftigen sich mit der Ableitung befahrbarer Pfade aus der Karte. Im Globalen werden dagegen übergeordnete Bewegungsstrategien zur Definition von Zielorten eingesetzt. Des Weiteren werden die für eine dreidimensionale Gebäudevermessung nutzbaren Verfahren erörtert. Insbesondere werden die notwendigen Methoden für eine photogrammetrische Rekonstruktion von Innenräumen erläutert und die verfahrensspezifischen Prämissen angeführt. Den Abschluss des Kapitels bildet eine Diskussion der existierenden Verfahren.

Kapitel 3 beschreibt den konzeptionellen Entwurf des mobilen, scannenden 2D-Messsystems zur Exploration von unbekanntem Innenraumszenen. Zunächst wird die verwendete Hardware vorgestellt, da sich diese restriktiv auf die softwareseitigen Implementierungen auswirkt. Kern des Kapitels ist die Entwicklung einer Bewegungsstrategie zur globalen Planung der Exploration. Diese lässt sich nur bei gleichzeitiger Betrachtung weiterer Verfahrenskomponenten sinnvoll darstellen. So zeigt das Kapitel, wie sich aus der Auslegung der Umgebungskarte, der lokalen Bewegungsplanung sowie der Verwaltung der Messdaten eine übergeordnete Bewegungsstrategie ableiten lässt. Ein zusätzlicher Fokus liegt auf der Auslegung des Scan-Matching Verfahrens, da dieses für die Genauigkeit der resultierenden Punktwolken bedeutend ist.

In Kapitel 4 wird das in Kapitel 3 vorgestellte 2D-Messsystem evaluiert. Es werden die durchgeführten praktischen Versuche erklärt sowie die dabei erzielten Ergebnisse analysiert. Anhand einer synthetischen Versuchsreihe wird die Parametrisierung der Kostenfunktion optimiert. Eine Evaluierung der odometrie-basierten Lokalisierungsgenauigkeit des Messsystems dient dazu, Reglementierungen der Explorationsstrategie festzulegen. In weiteren Versuchen werden reale Innenraumumgebungen durch das System exploriert. Dabei wird der Einfluss verschiedener Eingangsgrößen auf den Explorationsprozess aufgezeigt und analysiert. Die resultierenden Raumdaten werden mit den Daten anderer Messmittel verglichen und für ein automatisches Modellierungsverfahren weiterverwendet.

Die Entwicklung einer photogrammetrischen Positionierungsstrategie behandelt Kapitel 5. Die relevanten Einflussfaktoren und Restriktionen werden einleitend erörtert. Es wird dargestellt, wie die Kartendaten der 2D-Vermessung dazu genutzt werden, die Abfolge einer Posebestimmung im \mathbb{R}^2 zu regeln und den Suchraum für mögliche Kameraposen einzuschränken. Dabei werden zunächst zwei Vorgehensweisen in Betracht gezogen, wobei eine der beiden aufgrund der Ergebnisse aus Kapitel 6 wieder verworfen wird. Weiterhin wird gezeigt, wie sich ein 2D-Richtungsnetz dazu nutzen lässt, das Fehlerverhalten von Aufnahmekonfigurationen anhand einer Betrachtung der Fehlerellipsen zu prognostizieren. Beides führt zu einer Kostenfunktion, die den Kern der Positionierungsstrategie bildet. Abschließend wird der ganzheitliche konzeptionelle Entwurf des 3D-Messsystems erläutert.

Eine ausführliche Evaluierung der in Kapitel 5 entwickelten Positionierungsstrategie ist Inhalt von Kapitel 6. Anhand theoretischer Analysen wird geprüft, welchen Einfluss die Änderungen verschiedener Eingangsgrößen auf die Rekonstruktionsgenauigkeit haben, um diese im Vorfeld der praktischen Anwendung optimieren zu können. Zudem kommt das photogrammetrische 3D-Messsystem in einer realen Versuchsumgebung zum praktischen Einsatz. Auch hier wird das Leistungsvermögen des Systems durch verschiedene Versuchsreihen unter variierenden Bedingungen analysiert. Ein Referenzmodell erlaubt absolute Genauigkeitsaussagen und einen direkten Vergleich mit einer alternativen Positionierungsstrategie.

Das Fazit bildet den Abschluss der Arbeit und gibt eine kurze Zusammenfassung der Ergebnisse sowie einen Ausblick auf weitere Entwicklungen.

Weiterführende Informationsquellen wie Grafiken und Tabellen sowie eine Erläuterung bekannter Verfahren, die im Rahmen dieser Arbeit angewendet wurden, finden sich im Anhang.

2 Grundlagen

Das in dieser Arbeit entwickelte Messsystem hat die Aufgabe, autonom eine in sich abgeschlossene Innenraumszene möglichst vollständig zu erfassen und zu kartieren. Ein robotisches System, das diese Aufgabe bewältigen soll, muss im Messbetrieb die drei folgenden Kernfragen beantworten können:

1. *Wo bin ich?*
2. *Wohin will ich mich als nächstes begeben?*
3. *Wie gelange ich dort hin?*

Die Verfahren zur Beantwortung der ersten Frage lassen sich unter dem Begriff SLAM (*Simultaneous Localization And Mapping*) zusammenfassen. Die Erfassung der Umgebung mit einem Sensor von unterschiedlichen Posen¹ aus, verbunden mit einer anschließenden Registrierung der Daten in einem gemeinsamen Modell, erlaubt dabei eine Auto-Lokalisierung des Systems sowie den Aufbau eines Modells bzw. einer Karte der Umgebung im selben Schritt. Die bekanntesten Lokalisierungsverfahren werden in Abschnitt 2.2 vorgestellt. Um eine Lokalisierung zu ermöglichen, muss eine Form der Umgebungsrepräsentation definiert werden. Eine Lokalisierungsaussage erfolgt in Bezug zu dieser Repräsentationsform (siehe Abschnitt 2.1).

Die Lösung der zweiten Frage ist abhängig von der Systemapplikation. Aufgrund der Anforderungen an das hier verwendete System, setzt sich Abschnitt 2.3 in erster Linie mit Strategien zur Exploration unbekannter Umgebungen im \mathbb{R}^2 auseinander. Zielorte bzw. Messposen werden dabei so gewählt, dass eine Erweiterung der bekannten Umgebung möglich ist.

Durch die Beantwortung der dritten Frage wird geklärt, wie sich ein System innerhalb der ihm gegebenen Karte bzw. Umgebungsrepräsentation effizient und vor allem kollisionsfrei zum gewünschten Zielort begeben kann. Mögliche Methoden werden in Abschnitt 2.3.1 erörtert.

Während sich die vorigen Abschnitte auf eine zweidimensionale Betrachtung beschränken, widmet sich Abschnitt 2.4 der Umgebungsrekonstruktion zuzüglich der robotischen Methoden im \mathbb{R}^3 .

2.1 Repräsentation der Umgebung für mobile Roboter

2.1.1 Konfigurationsraum

Die Konfiguration k ist eine vollständige Beschreibung der Lage eines Roboters in seiner Umgebung, wobei der Konfigurationsraum K die Menge aller möglichen Konfigurationen angibt (vgl. z.B. [62, 65]). Die Form, die Größe sowie die für die Bewegung relevanten Teile schränken die Bewegungsmöglichkeiten eines Roboters ein und müssen daher in der Pfadplanung berücksichtigt werden. Abhängig von dessen Konstruktion lassen sich die möglichen Bewegungen anhand eines Satzes unabhängiger Parameter beschreiben. Die Anzahl der Parameter gibt die Anzahl der Freiheitsgrade des Roboters an.

Die Konfiguration eines sich in einer Ebene bewegenden Roboters, der in der Lage ist, sich transla-

¹Als Pose wird die Kombination von Position und Orientierung eines Objekts im Raum bezeichnet

torisch als auch rotatorisch beliebig fortzubewegen, läßt sich z.B. anhand von 3 Parametern (x, y, ϕ) beschreiben und hat folglich 3 Freiheitsgrade. Aus Gründen der Einfachheit wird die Repräsentation des Roboters häufig auf diese Darstellung reduziert. In den Abbildungen 2.1a und 2.1b wird das Umgebungsmodell, welches die Umwelt abbildet, dem Konfigurationsraum gegenübergestellt. Während der Roboter auf einen Punkt reduziert wird, werden die Objekte der Umgebung um dessen Abmaße erweitert. Mit der Erweiterung wird der Raum abgedeckt, der vom Roboter nicht befahren werden kann. Im Falle eines kreisförmigen Roboters ermöglicht eine gleichmäßige Ausdehnung aller Objekte um dessen Radius eine korrekte Modellierung von K . Ist K erstellt, vereinfacht sich die Pfadplanung, da diese nun ohne Berücksichtigung der Abmaße des Roboters erfolgen kann.

Im Gegensatz zum hier angeführten Beispiel ist die Bewegungsplanung von Robotern, die einer komplexeren Bauweise unterliegen, dagegen mit einem erheblichen Mehraufwand verbunden, wie es das Beispiel der zweiachsigen Plattform in Abbildung 2.1c zeigt.

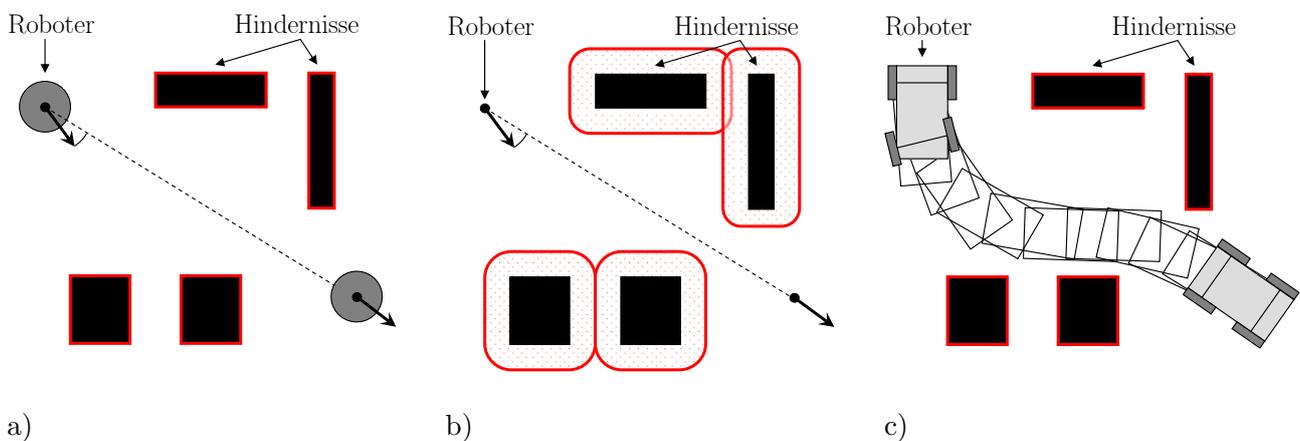


Abb. 2.1: Darstellungsmöglichkeiten des Konfigurationsraumes
 a) Kreisförmiger Roboter mit drei Freiheitsgraden (x, y, ϕ) im Umgebungsmodell
 b) Resultierender Konfigurationsraum K , Reduktion der Roboterform auf einen Punkt
 c) Beispiel für einen Roboter mit höherdimensionalem Konfigurationsraum

2.1.2 Karten

Die Repräsentation der Umgebung in einer Karte ist die Grundlage für die Navigation eines mobilen Roboters. In der Regel ist dieser mit Sensoren ausgestattet, die ihm Informationen über die Beschaffenheit der Umgebung liefern. Das System muss die gesammelten Daten so mit der bekannten Karte in Bezug setzen, dass eine Interpretation und korrekte Wahl der Folgehandlung möglich ist. Welche Art der Umgebungsrepräsentation durch die Karte sinnvoll ist, hängt sowohl vom Typ des Sensors als auch von der grundlegenden Aufgabe des Roboters ab. Es existiert eine Vielzahl unterschiedlicher Kartentypen die bereits in der Robotik Verwendung gefunden haben. Diese lassen sich im Wesentlichen in die zwei Hauptgruppen der metrischen und der topologischen Karten aufspalten.

Metrische Karten

Mit diesem Kartentyp wird eine metrisch korrekte Abbildung der Umgebung angestrebt. Metrische Karten sind „Datenstrukturen, welche die Position von Umgebungsmerkmalen (engl.: *features*) bezüglich eines gegebenen Koordinatensystems speichern“ [108]. Zur Gruppe der metrischen Karten zählen die geometrischen Karten und die Rasterkarten.

Geometrische Karten

In geometrischen oder auch Merkmals-Karten werden geometrische Primitive wie Punkte und Linien oder auch Polygone zur Darstellung der Umgebung verwendet. Als typisches Beispiel lassen sich Grundrisspläne von Gebäuden nennen, die die Gebäudegeometrie durch einen Verbund von Linienelementen vollständig wiedergeben können. Die Merkmale werden aus den Sensordaten extrahiert und deren Position gemeinsam mit der zugehörigen Unsicherheit abgespeichert [86]. Im Allgemeinen stellt die Sensorik die Merkmale nicht direkt bereit. Daher müssen weitere Techniken wie Linien- oder Ecken-detektionsalgorithmen angewandt werden, um diese aus den aufgezeichneten Daten herzuleiten.

Durch die Abstraktion der Umwelt sind geometrische Karten am ehesten für die Modellierung künstlich geschaffener Umgebungen geeignet. Komplexe oder auch natürliche Strukturen lassen sich mit ihnen dagegen nur schwer repräsentieren. Eine gewisse Unflexibilität der Methode rührt auch daher, dass die verwendeten Merkmale der zu erwartenden Umgebung vorab angepasst werden müssen.

Rasterkarten

Rasterkarten oder auch Belegtheitsgitter (engl.: *occupancy grids*) wurden bereits vor mehr als zwei Dekaden eingeführt (z.B. [77]). Bei diesen wird die Umgebung durch eine Unterteilung in Gitterzellen $C_{m,n}$ diskretisiert. Jeder Zelle wird eine Klassifizierungsvariable $s(c_{m,n})$ zugewiesen, die den Zustand der von der Zelle repräsentierten Region wiedergibt. Eine typische Belegung wären z.B. die Zustände *frei*, *belegt* oder *unbekannt*. Der Zustand einer Zelle läßt sich aus der Anzahl von Sensormessungen, die die Zelle im Verlauf der Messprozedur passieren bzw. der Objekte, die innerhalb der Zellregion registriert wurden, ermitteln. Da sowohl die Sensorposition in der Karte als auch die Messungen selbst mit Fehlern behaftet sind, eignet sich die Verwendung probabilistischer Verfahren. Gerade die in der Vergangenheit vermehrt eingesetzten Ultraschallsensoren weisen einen hohen Grad an Unsicherheit auf. Im Allgemeinen wird für $s(c_{m,n})$ ein wahrscheinlichkeitsbasierter Wert $P(s(c_{m,n}) = bel) \in [0; 1]$ hinterlegt, der die Wahrscheinlichkeit angibt, mit der eine Zelle $c_{m,n}$ als *belegt* angenommen wird.

Gemäß [24] läßt sich über den Satz von Bayes (vgl. Abschnitt 2.2.3) die Belegtheitswahrscheinlichkeit einer Zelle $P(s(c_{m,n}) = bel | M_{i+1})$ nach einer weiteren Messung M_{i+1} anhand der bisher getätigten Messungen $\{M\}_i = \{M_0, M_1, \dots, M_i\}$ rekursiv bestimmen über:

$$P(s(c_{m,n}) = bel | \{M\}_{i+1}) = \frac{P(M_{i+1} | s(c_{m,n}) = bel)P(s(c_{m,n}) = bel | \{M\}_i)}{\sum_{s(c_{m,n})} P(M_{i+1} | s(c_{m,n}))P(s(c_{m,n}) | \{M\}_i)} \quad (2.1)$$

Wobei sich die Wahrscheinlichkeitsverteilung $P(M_{i+1} | s(c_{m,n}))$ aus den Sensoreigenschaften der Distanzmessung ergibt (Abbildung 2.2a). Wird dieses Sensormodell verwendet, ergibt sich unter Berücksichtigung einer Vielzahl von Messungen ein Belegtheitsgitter, wie es in Abbildung 2.2b dargestellt ist.

Belegtheitsgitter können ein effizienter Ansatz sein, um Messunsicherheiten unter Berücksichtigung der Informationen bereits vergangener Messungen in einer Karte zu repräsentieren. Dies spielt insbesondere im Zusammenhang mit der SLAM-Problematik eine besondere Rolle. Durch die explizite Definition befahrbarer und unbefahrbarer Bereiche sowie einer detaillierten, metrischen Repräsentation der Umgebung eignen sie sich zur Planung von Pfaden und Vermeidung von Hindernissen. Abhängig von der Maschenweite des Gitters und den Ausmaßen der Umgebung ist deren Handhabung mit erheblichem Rechenaufwand und Speicherbedarf verbunden. Dies gilt insbesondere in dynamischen Umgebungen. Die Wahl einer festen Gittergröße macht das Verfahren hinsichtlich einer Anpassung an

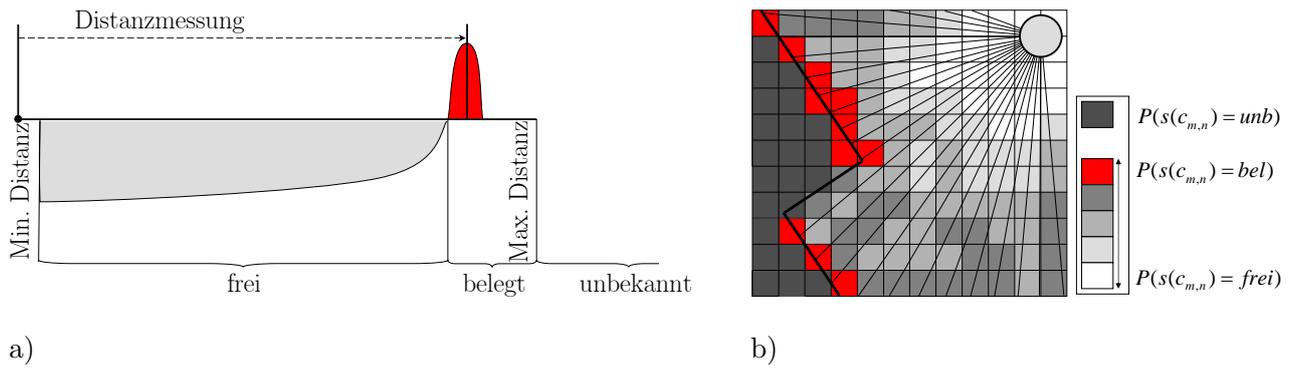


Abb. 2.2: Modellierung des Belegtheitsgitters

a) Typisches Modell eines Abstandssensors

b) Auswirkung auf die Belegheitswahrscheinlichkeit $P(s(c_{m,n}))$ der $c_{m,n}$ nach Durchführung mehrerer Distanzmessungen von einer Messposition

die Umgebungsbedingungen unflexibel. Eine Verbesserung bringt der Einsatz von Baumstrukturen, wie *quad-trees* [91] für 2D-Umgebungen oder *oct-trees* als Pendant im 3D. Diese erlauben eine individuelle Anpassung der Zellengröße an den Detaillierungsgrad der lokalen Umgebung und ermöglichen damit eine Verringerung der zur Umgebungsrepräsentation notwendigen Information. Die zugehörige Modellierung der Messunsicherheit konnte bereits erfolgreich auf diese Art von Gitterstruktur übertragen werden (z.B. [55]).

Topologische Karten

Rein topologische Karten versuchen die Umwelt ohne die Verwendung von metrischen Informationen darzustellen. Räumliche Informationen werden stattdessen durch die Angabe sich voneinander abgrenzender Orte ersetzt. Eingeführt wurde der Ansatz durch Kuipers [58]. Die Modellierung erfolgt im Allgemeinen durch den Aufbau eines Graphen. Dieser besteht aus Knoten, also den distinktiven Orten, und Kanten zur Speicherung von Weginformationen zwischen den Knoten².

Topologische Karten stellen die Umwelt in einer abstrakteren Form als metrische Karten dar und speichern nur die groben Zusammenhänge der Umgebung. Fragestellungen wie die Planung von Pfaden lassen sich einfach und direkt aus dem Graphen ableiten. Der benötigte Rechenaufwand wird minimal, da der Graph die Relationen der Knoten bereits enthält.

Um sich in einer topologischen Karte lokalisieren zu können, müssen spezielle Verfahren zur Wiedererkennung der distinktiven Orte (engl.: *place recognition techniques*) eingesetzt werden [41]. Der Anspruch an die Techniken zur Interpretation der Sensordaten ist entsprechend höher. Die Genauigkeit der Lokalisierung hängt von der Leistungsfähigkeit der Wiedererkennungsverfahren ab. Aufgrund fehlender metrischer Informationen kann keine entsprechende Genauigkeitsaussage getroffen werden. Ersetzt wird diese durch die Angabe der Unsicherheit an einem bestimmten Ort zu sein.

Rein topologische Modelle finden sich quasi in keiner realen Robotikanwendung. Dies liegt vor allem daran, dass ihre Nutzung zu viele Einschränkungen mit sich bringt. Die sehr reduzierte Umweltdarstellung beinhaltet nur Informationen für die Navigation zwischen verschiedenen Orten. Flächenbezogene Anwendungen, wie z.B. das Staubsaugen oder Rasenmähen lassen sich mit diesen nicht bewerkstelligen.

Kombination von Kartentypen

Topologische Karten bieten eine effiziente Möglichkeit zur Pfadplanung. Aufgrund ihrer Kompaktheit

²Beispiele sind Netzpläne für Straßenbahnen und Busse

eignen sie sich prinzipiell dazu, die Planungen in großflächigen Gebieten durchzuführen. Demgegenüber erlauben metrische Modelle einen Roboter mit hoher Genauigkeit zu lokalisieren und dessen Bewegungen zu definieren. Die anhand der Abstandssensoren gesammelten Daten sowie deren Unsicherheiten lassen sich gut in die Karte integrieren.

Da beide Verfahrenstypen Vorteile bieten, läßt sich folgern, dass eine Verbindung der Verfahren gewinnbringend wäre. So existieren verschiedene hybride Ansätze, die auf einer Kombination beider Modelle beruhen. Verbleibt ein starker Topologiebezug, spricht man von *Kognitiven Karten*. Z.B. ergänzt Kuipers [59] die topologische Karte um metrische Weginformationen zur Verbesserung des Navigationsverhaltens. Bei Thrun [103] werden dagegen gleich zwei isomorphe Karten angelegt: eine metrische Karte für eine genaue Lokalisierung und eine konsistente Umgebungserweiterung. Aus dieser wird eine topologische Karte abgeleitet, die für eine effiziente Pfadplanung verwendet werden kann. Ausgehend von einem Belegtheitsgitter wird die Umgebung unter Verwendung eines Voronoi-Diagramms in zusammenhängende Regionen unterteilt (Abbildung 2.3a). Die Konnektivität der Regionen (Abbildung 2.3b) erlaubt das Ableiten eines Graphen zur übergeordneten Planung der Roboterbewegungen (Abbildung 2.3c).

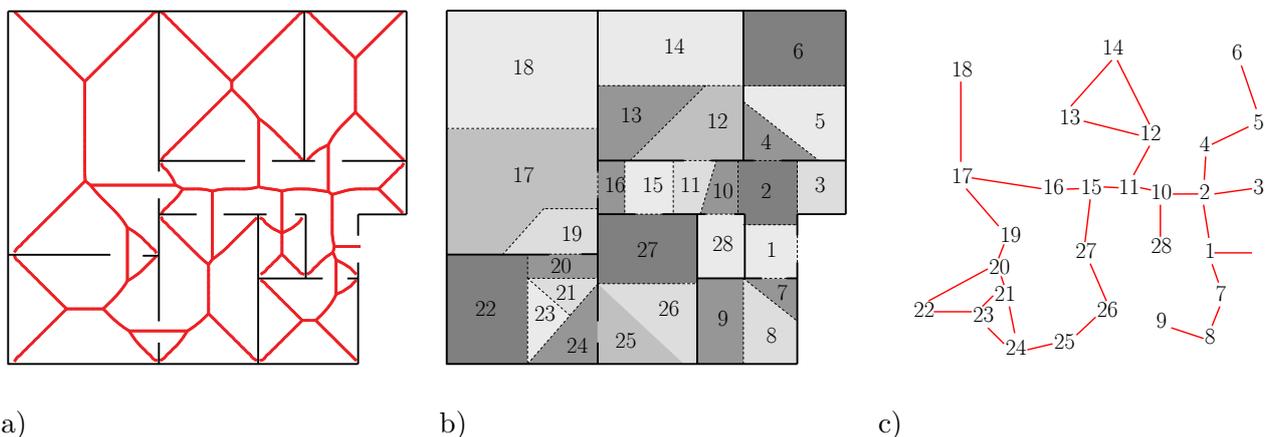


Abb. 2.3: Ableitung einer topologischen aus einer metrischen Karte nach Thrun [103]

- a) Erstellung eines Voronoi Diagramms aus Rasterkarte
- b) Aufteilung befahrbarer Bereiche in Regionen
- c) Ableitung einer topologischen Karte über Regionennachbarschaften

2.2 Lokalisierung

Der Begriff *Lokalisierung* beschreibt die Fähigkeit eines autonomen Roboters sich bezüglich eines festen Koordinatensystems zu orientieren. Die Ungewissheit über Position und Orientierung des Roboters stellt eines der zentralen Probleme der Robotik dar. Ohne die Kenntnis der momentanen Pose ist ein Roboter nicht in der Lage weiterführende Aufgaben wie die Planung von Pfaden durchzuführen. Der folgende Abschnitt soll einen Überblick über mögliche Lokalisierungsprobleme geben und die zu deren Lösung bestehenden Verfahren vorstellen.

Generell gilt es zwischen den drei folgenden Arten der Problemstellung zu differenzieren. Diese werden hier zwar gesondert angesprochen, gehen in der Praxis aber oft ineinander über:

1) Lokale Lokalisierung

Bei der lokalen Lokalisierung (engl.: *pose tracking*) kennt der Roboter die initiale Roboterpose. Weitere

Positionierungen werden relativ zu dieser bestimmt. Der jeweilige Aufenthaltsort ist dabei im Vorfeld ungefähr bekannt, so dass lediglich eine kleine Korrektur der Pose vorgenommen werden muss. Dies kann durch Auswertung der Odometriedaten (vgl. Abschnitt 2.2.1) oder unter zusätzlicher Hinzunahme weiterer Sensordaten erfolgen.

2) Globale Lokalisierung

In diesem Szenario befindet sich der Roboter in einer beliebigen, ihm unbekanntem Pose in einer ihm bekannten Umgebung. Der Roboter muss eine absolute Selbstlokalisierung durchführen, ohne auf Vorwissen zurückgreifen zu können.

3) Kidnapped-Robot Problem

Das schwierigste Szenario stellt das Problem des gekidnappten Roboters dar. Dieses tritt auf, wenn der Roboter temporär die Kenntnis über seinen wahren Aufenthaltsort verloren hat, was durch ein absichtliches Versetzen des Roboters oder durch eine fehlerhafte Bestimmung der Pose hervorgerufen worden sein kann. Der Roboter muss dann in der Lage sein diesen Vorgang zu bemerken, um sich daraufhin wieder neu global lokalisieren zu können.

Loop-Closing Problem

Das Schließen von Zyklen spielt in der Robotik eine besondere Rolle. Geschieht der Aufbau einer Umgebungskarte durch inkrementelles Registrieren neuer Messungen (Scans), summieren sich die verbleibenden Fehler auf. Dies kann zu Inkonsistenzen in der Karte führen und diese für die Navigation unbrauchbar machen. Besonders deutlich zeigt sich dieses Problem, wenn der Roboter eine zyklische Umgebung vollständig erkundet hat und dabei zu einem bereits erkundeten Gebiet zurückkehrt. An diesem Punkt führen die akkumulierten Fehler zu einer Inkonsistenz des globalen Modells. Wie z.B. Stachniss [97] zeigt, können probabilistische Verfahren dazu eingesetzt werden die bereits kartierte Umgebung rückwirkend so zu deformieren, dass sich eine global konsistente Karte erstellen lässt.

Lokalisierungsverfahren lassen sich unter anderem darin unterscheiden, wie der Roboter bzw. die Welt, in der sich dieser bewegt, modelliert ist und welche Möglichkeiten dem Roboter gegeben sind, Informationen über seine Umgebung zu sammeln. So ist vorab die Wahl des Kartentyps dafür ausschlaggebend, wie eine vollständige Lokalisierung definiert wird. Während dies bei topologischen Karten die eindeutige Bestimmung eines distinktiven Ortes sein kann, bedarf es in metrischen Karten meist der Angabe von Koordinaten. Die Anzahl der zu bestimmenden Größen hängt von der Konfiguration des Roboters ab (siehe Abschnitt 2.1.1). Die Mehrheit robotischer Anwendungen beschränkt sich auf eine 2D-Modellierung der Umwelt, da dies für Anwendungen in Innenräumen ausreichend ist. Auch die verwendeten Sensoren unterliegen oftmals einer entsprechenden Einschränkung. Bei einer 3D-Modellierung der Sensorik und des Roboters wird dessen Konfiguration mit sechs Freiheitsgraden angegeben (siehe Abschnitt 2.4.2).

2.2.1 Koppelnavigation

Die Koppelnavigation (engl.: *dead reckoning*) ist ein Lokalisierungsverfahren, welches sich auf die Lösung des Problems der lokalen Lokalisierung beschränkt. Die aktuelle Pose des Roboters ergibt

sich aus der Integration der von den Radencodern³ zurückgegebenen Odometriedaten (siehe Anhang A.1). Eine Angabe der Pose ist somit bei der Bewegung des Roboters und nur relativ zur initialen Pose möglich. Zudem führen der Schlupf der Räder sowie das Aufsummieren von Messfehlern zu einem distanzabhängigen Positionierungsfehler, so dass das Verfahren nur für kurze Strecken sinnvoll einsetzbar ist.

2.2.2 Scan-Matching

Durch das Scan-Matching wird die relative Orientierung von Datensätzen D zu rekonstruieren versucht. Die in den Daten abgebildeten Umgebungsbereiche weisen dabei Überlappungen auf, durch die die Transformationsparameter für eine Abbildung der Daten aufeinander ermittelt werden können. Grundbedingung für ein erfolgreiches Matching ist, dass die kongruierenden Bereiche ausreichende geometrische Information bereitstellen können, um eindeutige Zuordnungen zu ermöglichen. Die Registrierbarkeit von Datensätzen läßt sich im Vorfeld des Scan-Matchings analysieren (vgl. [35, 67]). Bei einer Beschränkung auf den \mathbb{R}^2 kann die Registrierung als eine Starrkörpertransformation in der Ebene dargestellt werden. Diese läßt sich mit insgesamt 3 Parametern definieren, mit einer rotatorischen Komponente T_ϕ und zwei Translationen T_x und T_y entlang der Koordinatenachsen. So läßt sich ein Punkt $P'' \in D''$, gegebenen im Koordinatensystem K'' , über

$$\begin{pmatrix} P'_x \\ P'_y \end{pmatrix} = \begin{pmatrix} \cos(T_\phi) & -\sin(T_\phi) \\ \sin(T_\phi) & \cos(T_\phi) \end{pmatrix} \cdot \begin{pmatrix} P''_x \\ P''_y \end{pmatrix} + \begin{pmatrix} T_x \\ T_y \end{pmatrix} \quad (2.2)$$

nach K' transformieren.

Die momentane Pose des Sensors und damit des Roboters läßt sich ableiten, indem eine aktuelle Sensormessung dem bestehenden Umgebungsmodell zugeordnet wird.

Eines der früheren Verfahren zur Überdeckung von Scans wurde von Cox entwickelt [19]. Das Verfahren extrahiert zunächst aus den bestehenden Daten ein Linienmodell (siehe Anhang A.2). Zu jedem Punkt des zu transformierenden Datensatzes wird die Linie mit dem geringsten Lotabstand ermittelt (Abbildung 2.4a). Basierend auf dieser Zuordnung wird eine Transformation geschätzt, die die Summe der Lotabstände minimiert. Dieser Prozess wird wiederholt, bis das Verfahren konvergiert. Ein Schwellwert verhindert dabei, dass Punkte, die aufgrund der unterschiedlichen Inhalte der Datensätze, kein korrespondierendes Liniensegment besitzen, einem falschen und weiter entfernten Liniensegment zugeordnet werden und sich negativ auf die Bestimmung der Transformationsparameter auswirken können. Der bisher am meisten angewendete Ansatz zur Registrierung von Datensätzen ist der von Besl in [5] entwickelte ICP (*Iterative Closest Point*) Algorithmus. Im Gegensatz zum Verfahren von Cox, basiert das Verfahren auf einer direkten Punktzuordnung. So werden hier die nächsten Nachbarn jedes Punktes aus D'' in D' gesucht. Auch hier erfolgt die Parameterschätzung unter der Bedingung, die Abstandsquadratsumme zu minimieren.

Eine Schwäche des ICP stellt der Umgang mit größeren Rotationen dar. Der Abstand zweier korrespondierender Punkte nimmt proportional mit deren Abstand zum Rotationszentrum zu. Die Wahrscheinlichkeit einer korrekten Zuordnung dieser beiden Punkte ist damit gegenläufig. Das führt dazu, dass der ICP größere Differenzen in der rotatorischen Fehlstellung von Datensätzen durch Translationen zu kompensieren versucht, was wiederum zu fehlerhaften Ergebnissen führen kann.

Deshalb entwickelte Lu [71] mit dem IDC (*Iterative Dual Correspondences*) eine Erweiterung des ICP,

³gilt für radgebundene Roboter

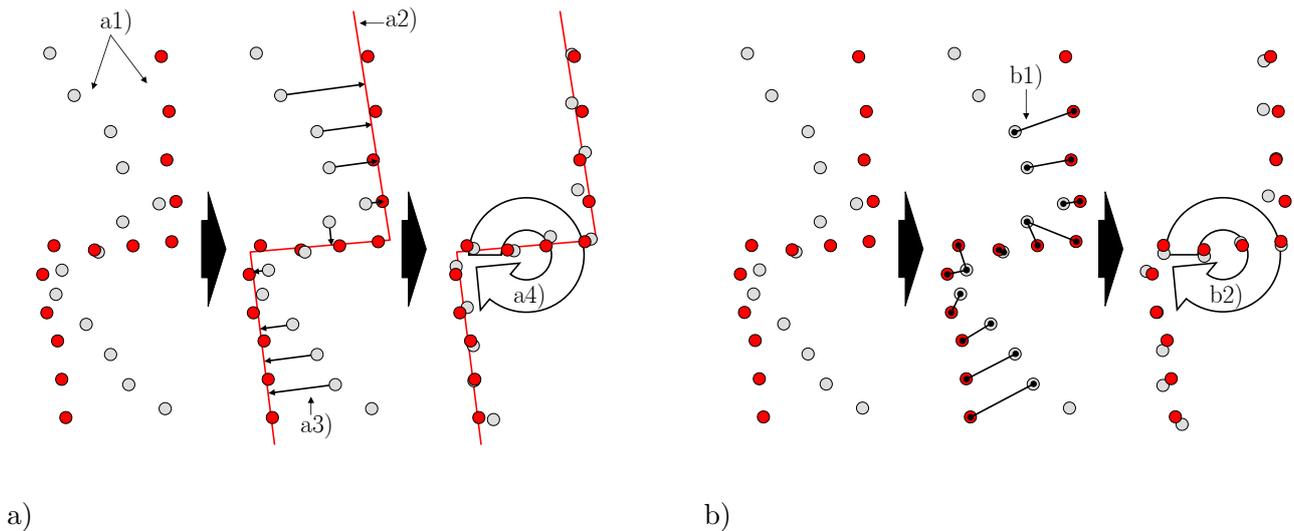


Abb. 2.4: Vergleich der Registrierungsverfahren nach Cox [19] und Besl [5]

a) Methode nach Cox [19]

a1) Zwei zueinander zu registrierende Datensätze

a2) Ableitung von Liniensegmenten aus einem Referenzdatensatz

a3) Bestimmung des nächsten Liniensegments für die Punkte des Transformationsdatensatzes

a4) Transformation basierend auf einer Parameterschätzung unter Minimierung der Summe der Lotabstände auf den Referenzdatensatz

b) Methode nach Besl [5]

b1) Bestimmung nächster Nachbarpunkte

b2) Transformation basierend auf einer Parameterschätzung unter Minimierung der Summe der Punktabstände

die sich dieser Problematik annimmt. Mit einer zweiten Heuristik werden die Abstände der Punkte zum Aufnahmezentrum betrachtet. Es werden nur die Punkte in den bestehenden Daten für eine Zuordnung in Betracht gezogen, die denselben Abstand zum Aufnahmezentrum aufweisen. Mit den beiden Korrespondenzbestimmungen „Nächster Nachbar“ und „Gleiche Entfernung“ wird so sowohl der translatorischen als auch der rotatorischen Transformationskomponente Rechnung getragen.

Auch der in [76] veröffentlichte MbICP (*Metric based ICP*) lässt sich auf die von Besl entwickelte Methodik zurückführen. Dieser Ansatz verweist auf die beim IDC durch die doppelte Bestimmung von Korrespondenzen erhöhte Rechenzeit und versucht durch die Wahl einer anderen Metrik als des euklidischen Abstandes ein stabileres und schnelleres Matching zu ermöglichen. Censi [16] stellt eine weitere ICP Variante vor, die anstatt einer Punkt-Punkt Metrik eine Punkt-Linie Metrik verwendet. In der Literatur existieren auch eine Reihe alternativer Matching-Verfahren, wie z.B. Korrelationsbasierte Verfahren, die ein Matching über ein Winkelhistogramm [111] oder über ein Belegtheitsgitter [77] ermöglichen. Diese erreichen jedoch nicht die gleichen Genauigkeits- und Robustheitsniveaus der ICP-basierten Verfahren. Für eine tiefere Recherche sei hier auf die Arbeit von Gutmann [40] verwiesen.

2.2.3 Probabilistische Lokalisierungsverfahren

Für eine erfolgreiche Exploration eines unbekanntes Gebietes muss sich der Roboter in der Umgebung selbst lokalisieren, um der Karte neu erfasste Umgebungsstrukturen hinzufügen zu können. Für die Autolokalisierung ist jedoch das Vorhandensein einer Karte notwendig. In der Fachliteratur ist dieser Umstand unter dem Begriff „SLAM“ bekannt und beschreibt ein grundlegendes Problem der mobilen Robotik. Da die zur Verfügung stehenden Sensordaten mit Fehlern behaftet sind, ergibt sich keine geschlossene Lösung für beide Aufgaben. SLAM-Algorithmen versuchen deshalb die Lokalisierung und

Kartenerstellung separat zu bearbeiten und die nötigen Informationen alternierend bereitzustellen. Im Umgang mit dieser Problemstellung haben sich probabilistische Verfahren durchgesetzt. Anstatt einer deterministischen Festlegung der Karte bzw. der Roboterposen wird zunächst einer Vielzahl nicht kausaler Konstellationen eine Wahrscheinlichkeit zugeordnet. Diese können sich mit der Zeit ändern, wenn das System weitere Umgebungsinformationen hinzugewonnen hat. Des Weiteren ist es möglich, die Informationen mehrerer Sensoren zu bündeln und gewichtet in den Lokalisierungsprozess einfließen zu lassen. So zeichnen sich probabilistische Verfahren unter anderem dadurch aus, das Loop-Closing Problem durch nachträgliche Karten- und Posekorrekturen lösen zu können. Da reine Scan-Matching Verfahren dieses Problem nicht zu lösen vermögen, werden sie nicht zu den probabilistischen Verfahren hinzugezählt.

Die im Folgenden genannten probabilistischen Verfahren basieren auf dem „*Bayesischen Filter*“. Dieser zeichnet sich dadurch aus, dass sich eine bedingte Wahrscheinlichkeit $p(a|b)$ bestimmen läßt, wenn deren umgekehrte Wahrscheinlichkeit $p(b|a)$ bekannt ist.

Markov Lokalisierung

Im Zusammenhang mit robotischen Anwendungen wird der Einsatz Bayesischer Filter als *Markov-Lokalisierung* bezeichnet. Das Lokalisierungsproblem definiert sich über $p(x_t|m_{t...0})$, der Wahrscheinlichkeit p , dass der Roboter zum Zeitpunkt t unter Berücksichtigung aller bisherigen Messungen $m_{t...0}$ die Pose x_t einnimmt. Umgekehrt beschreibt $p(m_t|x_t, m_{t-1...0})$ die Wahrscheinlichkeit, dass sich die Messung m_t ergibt, wenn die Pose x_t sowie alle bisherigen Messungen $m_{t-1...0}$ als bekannt vorausgesetzt werden. Da sich letztere Wahrscheinlichkeit relativ leicht bestimmen läßt, kann die Bayes'sche Regel angewandt werden, um den aktuellen Systemzustand $p(x_t|m_{t...0})$ abzuleiten:

$$p(x_t|m_{t...0}) = \frac{p(x_t|m_{t...0}) \cdot p(x_t|m_{t-1...0})}{p(m_t|m_{t-1...0})} \quad (2.3)$$

Eine ausführlichere Erläuterung hierzu findet sich z.B. in der Arbeit von Stiene [100].

Es existieren diverse Umsetzungsvarianten der Markov-Lokalisierung. An dieser Stelle seien die bekanntesten genannt.

- *Kalman-Filter:*

Das Kalman-Filter ist eines der am häufigsten verwendeten Filter und gut für Echtzeitanwendungen, da es rechnerisch gut handhabbar ist. Bei diesem unimodalen Filter wird die Wahrscheinlichkeit eines Folgezustands basierend auf den Informationen aller bisherigen Zustände geschätzt, wobei die Folgewahrscheinlichkeit als Gauß-verteilt angenommen wird. Aufgrund der Unimodalität ist eine Lösung des Kidnapped-Robot oder auch des globalen Lokalisierungsproblems nicht möglich. Um nicht nur lineare Zustandsübergänge schätzen zu können, wurde das Filter zum EKF (*Extended Kalman Filter*) weiterentwickelt.

- *Monte-Carlo-Lokalisierung:*

Die Monte-Carlo-Lokalisierung geht auf Fox [30] zurück. Der Systemzustand, bzw. die Roboterpose wird durch eine Wahrscheinlichkeitsdichtefunktion beschrieben, die wiederum durch ein Partikelfilter repräsentiert wird. Die einzelnen Partikel sind gewichtet und beschreiben jeweils einen möglichen Systemzustand. Damit zählt die Markov-Lokalisierung zu den multimodalen Lokalisierungsverfahren und ist in der Lage, das globale Lokalisierungsproblem zu lösen. Die Effizienz und die Robustheit des Verfahrens sind jedoch gegenläufig abhängig von der Anzahl

der verwendeten Partikel.

- *Rao Blackwellised Partikelfilter (RBPF)*:

RBPF [79] kombinieren die Effizienz eines Kalmanfilters und die Multimodalität eines Partikelfilters. Die linearen Anteile an den Bewegungsmodellen werden über das Kalman-Filter analytisch berechnet, während nur die nicht-linearen Anteile anhand eines Partikelfilters geschätzt werden. Damit sinkt die Anzahl notwendiger Partikel.

Probabilistische Verfahren und das Scan-Matching haben verschiedene Stärken. Das Scan-Matching auf der einen Seite verspricht eine möglichst hohe Genauigkeit der Datenregistrierung, da für diese alle zur Verfügung stehenden Messpunkte genutzt werden. Bei ausschließlicher Nutzung des Scan-Matchings ist jedoch nur eine unimodale Zustandsbestimmung möglich, die gegebenenfalls nicht nachträglich korrigiert wird. Probabilistische Verfahren spielen seit den 90 Jahren eine dominante Rolle im Umgang mit der SLAM-Problematik. Sie eignen sich im Umgang mit fehlerbehafteten Sensordaten gut für Lokalisierungsaufgaben, da die Fehler in der Modellierung berücksichtigt werden können. Multimodale Verfahren erlauben es die entstehenden Karten nachträglich zu korrigieren. Die Möglichkeit, Daten mehrerer Sensoren verwenden zu können, steigert die Robustheit der Lokalisierung. Laserscanner-basierte Posebestimmungen werden dabei durch Scan-Matching Techniken generiert. Für einen echtzeitfähigen Einsatz werden die Sensordaten häufig auf geometrische Primitive reduziert, so dass die Zuordnung der Messdaten basierend auf Landmarkenkorrespondenzen erfolgt. Um in der Kartierung dadurch keinen Genauigkeitsverlust zu erleiden, können die Lokalisierung bzw. die Navigation auch getrennt von der Kartierung betrachtet werden [101]. So nutzt z.B. Nüchter in [86] bei der 3D-Kartierung probabilistische Verfahren für die Exploration, registriert die 3D-Scans aber anhand eines Scan-Matching Verfahrens.

2.3 Robotische Exploration von 2D-Umgebungen

2.3.1 Bewegungsplanung

Ein wesentlicher Teil der navigatorischen Aufgaben eines robotischen Systems ist der sogenannten Bewegungsplanung (engl.: *motion planning*) zuzuschreiben. Zu den grundsätzlichen Aufgaben zählt die Bestimmung von Bewegungspfaden, über die ein System von seiner aktuellen zu einer gewünschten Pose gelangen kann. Zu unterscheiden ist dabei zwischen der Bahn- und der Routenplanung. Während in der Routenplanung zunächst innerhalb einer gegebenen Karte ein theoretischer Pfad bestimmt wird, beschäftigt sich die Bahnplanung mit der praktischen Umsetzung des zuvor bestimmten Pfades. Hierbei müssen die physikalischen Rahmenbedingungen, die durch die Umgebung gegeben sind, aber auch die Restriktionen durch das System selbst (Mechanik, Sensorik,...) berücksichtigt werden. Einen Überblick über Planungsalgorithmen ist in [65] gegeben.

Die Algorithmen der Routenplanung lassen sich in globale und lokale Verfahren aufteilen. Globale Verfahren gehen davon aus, dass dem Roboter ein Modell seiner Umgebung gegeben ist. Dieses kann bereits vollständig vorliegen oder aber erst durch die Messungen des Roboters entstehen. Lokale Verfahren arbeiten dagegen ohne Karte, sondern treffen Entscheidungen alleine basierend auf der momentanen Umgebung, wie sie durch die Sensoren wahrgenommen wird. Diese Verfahren finden z.B. bei vielen kommerziell erhältlichen Staubsauger-Robotern Verwendung, werden aber an dieser Stelle nicht weiter betrachtet (siehe z.B. [90]).

Die Routenplanung ist von der Art des Umgebungsmodells abhängig. Während topologische Modelle bereits restriktiv auf die Pfadplanung wirken, gewähren gitterbasierte Modelle mehr Freiheitsgrade. Die Applikation des Roboters gibt vor, ob ein 2D-Modell der Ebene für die Routenplanung ausreichend ist oder aber höherdimensionale Umgebungsmodelle benötigt werden.

Die im Folgenden erläuterten Verfahren beziehen sich ausschließlich auf zweidimensionale Umgebungsmodelle. Es lassen sich unter anderem folgende Verfahrensgruppen identifizieren:

1) Straßenkarten Verfahren (engl.: *roadmap*)

Die Gruppe der Roadmap-Verfahren reduziert den Konfigurationsraum auf einen Graphen, also ein Netzwerk eindimensionaler Linien. Die eigentliche Pfadfindung wird so zu einem graphentheoretischen Optimierungsproblem, für das entsprechende Suchmethoden zum Einsatz kommen. Die Verfahren lassen sich anhand der Art der Graphenbildung weiter unterscheiden.

Sichtbarkeitsgraphen (engl.: *visibility graph*) eignen sich für Umgebungen, die durch polygonale Formen repräsentiert werden (Abbildung 2.5a). Der Sichtbarkeitsgraph ist die Menge der Linien im freien Raum, die entsteht, wenn die Polygonpunkte verschiedener Objekt miteinander verbunden werden. Start- und Zielpunkt werden in die Menge der Verbindungspunkte mit aufgenommen.

Wenn der Roboter möglichst weit weg von Hindernissen bleiben soll, bietet sich ein *Voronoi-Diagramm* an. Es definiert sich als Menge der Punkte, die denselben Abstand zu zwei oder mehreren Objekten haben (Abbildung 2.5b). Die Wege vom Start- und Zielpunkt, um auf den Voronoi-Graphen zu gelangen, müssen hier gesondert ermittelt werden.

Beim *Zwischenzielverfahren* wird, ausgehend von der Startkonfiguration des Roboters, entweder über eine Heuristik oder aber auch zufällig eine Menge möglicher Folgekonfigurationen bzw. Zwischenziele (engl.: *subgoal*) ermittelt, über die das System zur Zielkonfiguration gelangen kann (Abbildung 2.5c). Die Erreichbarkeit der Zwischenziele wird überprüft. Ist das Ziel nicht erreichbar, wird das Verfahren basierend auf den Kenntnissen der bisher ermittelten Konfigurationen iteriert. Die Methode ist damit unabhängig von einer expliziten Darstellung von Hindernissen im Konfigurationsraum.

2) Zellzerlegung (engl.: *cell decomposition*)

Hierbei wird die Umgebung in Zellen unterteilt. Eine einheitliche Zellform bietet sich an, wenn dem System bereits durch die Kartierung ein Belegheitsgitter gegeben ist. Eine unregelmäßige Unterteilung hat den Vorteil, die Form der Umgebung berücksichtigen zu können (Abbildung 2.5d). Zur Ableitung eines Graphen müssen die Nachbarschaften der einzelnen Zellen bekannt sein.

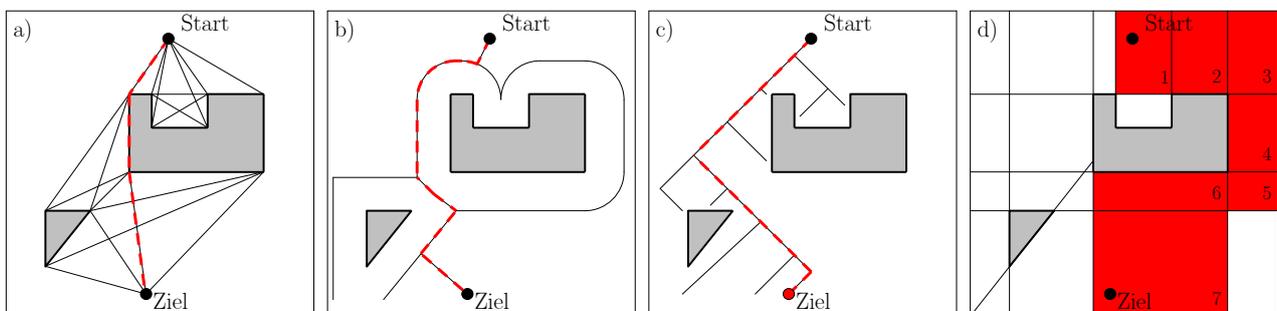


Abb. 2.5: Verfahren zur Routenplanung (Modifizierte Grafik nach Hwang [44])

- a) Sichtbarkeitsgraph
- b) Voronoi Diagramm
- c) Zwischenzielverfahren
- d) Zellzerlegung

3) Potentialfeldmethode (engl.: *potential field*)

Die Potentialfeldmethode [49] stellt die Umgebung als skalare Funktion dar, welche an der Stelle des Zielpunktes ein Minimum aufweist. Neben diesem Hauptfeld wird die Umgebung durch eine weitere Funktion modelliert. Das Umgebungsfeld bzw. -potential hat innerhalb und in der näheren Umgebung von Objekten hohe Potentialwerte. Eine Kombination dieser beiden Felder ermöglicht nun eine Routenplanung dadurch, dass das Feld in Richtung des höchsten negativen Gradienten durchschritten wird.

4) RDTs (*Rapidly exploring Dense Trees*)

Bei den RDT's [64] handelt es sich um Suchverfahren, die versuchen, effizient eine flächendeckende Baumstruktur zu erzeugen. Von einem initialen Punkt, in diesem Fall der Standort des Roboters, wird ein Baum bzw. ein topologischer Graph aufgespannt, indem iterativ freie Konfigurationen K_i gewählt werden und geprüft wird, ob diese in den Baum aufgenommen werden können. Dies gelingt, wenn eine hindernisfreie Verbindung zwischen K_i und dem nächstgelegenen Knoten des Baumes besteht. Die Baumstruktur wird verdichtet, bis auch der Zielpunkt aufgenommen werden kann. Werden die K_i zufällig gewählt, spricht man auch von RRT's (*Rapidly exploring Random Tree*) [63].

Graphenbasierte Suche

Wird durch eines der beschriebenen Verfahren ein Graph erstellt, sind weitere Suchmethoden notwendig, um im Graphen einen effizienten Weg zwischen Start- und Zielpunkt zu ermitteln. In der Literatur findet sich hierfür eine Vielzahl möglicher Verfahren wie der Dijkstra, der A*, der LPA oder der D* Algorithmus (siehe Anhang A.3).

2.3.2 Explorationsstrategien

Die Bewegungsplanung dient dazu, einen Roboter sicher und effizient von einem Start zu einem Zielpunkt navigieren zu lassen. Die Definition des Zielpunktes ist dagegen die Aufgabe übergeordneter Bewegungsstrategien. Diese unterscheiden sich darin, ob sich ein System in einer bekannten oder noch unbekanntem Umgebung bewegt. Bei Letzteren spricht man von der Gruppe der Explorationsstrategien. Prinzipiell lassen sich an diese folgende Forderungen richten:

- *Vollständigkeit:*
Wahl der Messpose derart, dass alle erfassbaren Bereiche einer Umgebung auch tatsächlich erfasst werden. Falls relevant, ist die geforderte Datendichte in allen Umgebungsbereichen einzuhalten
- *Genauigkeit:*
Die durch die Exploration gesammelten Daten werden für eine Rekonstruktion der Szene weiterverwendet. Es werden Datensätze generiert, durch die bei einer Rekonstruktion ein Abbild der Umgebung erzeugt werden kann, dessen Maße denen des Messobjektes bzw. der Messumgebung bestmöglich entsprechen
- *Effizienz:*
Minimierung der Anzahl der zur vollständigen Exploration notwendigen Posen

Im Folgenden werden bestehende Explorationsstrategien unter Verwendung von 2D-Laserscannern aufgezeigt. Yamauchi präsentiert in [115] ein grenzenbasiertes (engl.: *frontier-based*) Verfahren, das zur Repräsentation der Umgebung ein Belegheitsgitter verwendet. Über einen probabilistischen Ansatz werden die einzelnen Zellen des Gitters als *befahrbar*, *unbekannt* oder *bedeckt* klassifiziert. Nach jeder

Messung kann dann im aktualisierten Gitter ein zusammenhängender Bereich ermittelt werden, der vom System direkt zugänglich ist. Die Grenzen dieses Bereiches zu den unerkundeten oder belegten Gitterpunkten bilden die Grundlage für die weitere Exploration. Entlang der Grenzen werden zusammenhängende Bereiche als *unbekannt* klassifizierte Zellen gesucht. Ab einer gewissen Größe werden diese Bereiche als Grenzlinien (engl.: *frontiers*) gewertet und in eine Liste aufgenommen. Die Aufgabe des Systems ist es, im nächsten Schritt die nächstgelegene dieser Grenzen zu besuchen und den Schwerpunkt der Grenze anzusteuern. Ist der Zielpunkt erreicht, wird die entsprechende Grenze in eine Liste der bereits befahrbaren Grenzen eingetragen und im nächsten Schritt eine andere Grenze gewählt.

Die Wahl des jeweils Nächsten aus einer Liste möglicher Zielpunkte ist eine primitive Realisierungsmöglichkeit einer effizienten Strategie zur vollständigen Exploration einer Umgebung. Eine optimale Lösung wäre die Wahl der Messpose, die den größten Informationsgewinn als auch Daten mit höchster Qualität erbringt. Dieser Ansatz entspricht dem *next-best-view* Problem aus dem Bereich der Computervision [17]. Dort verwendete Methoden gehen davon aus, dass sich der Sensor frei um das zu erfassende Objekt bewegen kann und keine explizite Pfadplanung betrieben werden muss. Daher sind diese Methoden nicht direkt auf den Bereich der mobilen Robotik übertragbar [37]. Eine weiterer Unterschied ergibt sich aus der Verwendung von Matching-Verfahren zur Datenregistrierung, wobei sich neu gemessene Daten mit der bereits erstellten Karte überlappen müssen.

González-Baños [37] entwickelte eine Explorationsstrategie, die dieser Erfordernis Rechnung trägt und zusätzlich im Sinne der Next-Best-View Maxime agiert. Auch dieser Ansatz basiert auf der Bestimmung eines sicheren Bereichs, in dem sich der Roboter bewegen kann. Wie in [115] werden die Grenzlinien dieses Bereiches betrachtet. Anstatt der Zellen eines Belegtheitsgitters werden jedoch direkt die vom Sensor aufgezeichneten Datenpunkte analysiert. Dank der rotatorischen Datenerfassung des Scanners entsprechen die Nachbarschaften der aufgenommenen Punkte einer Messung zum Zeitpunkt q der Aufnahmereihenfolge des Scanners, so dass sich kontinuierliche Liniensegmente in den Daten direkt finden lassen. Weisen zwei benachbarte Datenpunkte dagegen einen großen Unterschied in der Distanz zum Sensor auf, handelt es sich um eine Datendiskontinuität, also eine Datenlücke. Diese werden durch ein Einfügen geometrischer Primitive aufgefüllt. So ergibt sich eine vollständig geschlossene Umgrenzung $l(q)$ des vom System befahrbaren Bereiches, die sich aus *solid curves* und *free curves* zusammensetzt, also aus Umgebungsoberflächen und Datenlücken (Abbildung 2.6).

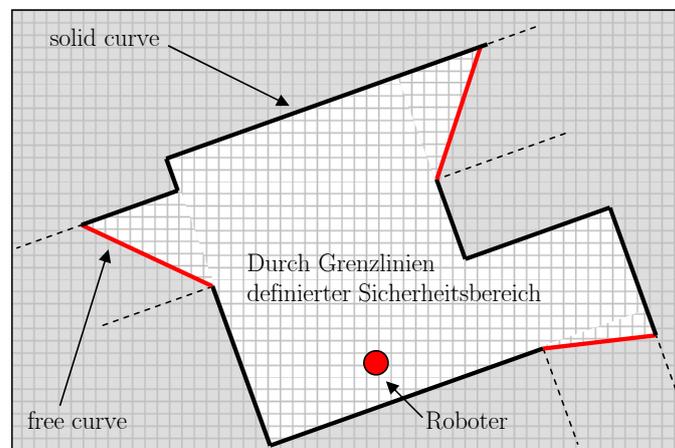


Abb. 2.6: Definition eines sicher befahrbaren Bereiches $s(q)$ über die Ableitung eines in sich geschlossenen Linienzugs $l(q)$ mit Grenzlinien in Form von *solid* und *free curves*.

Um die nächste Messpose $M(q + 1)$ zu wählen, wird ein Satz möglicher Kandidaten $c(q)$ erstellt, indem pseudozufällige Positionen in der Nähe der Datenlücken geschaffen werden (Abbildung 2.7b). Die endgültige Definition der nächsten Messpose erfolgt über eine Beurteilung jedes der Kandidaten c durch eine Gütefunktion g :

$$g(c) = A(c)\exp(-\lambda L(c)) \quad (2.4)$$

mit: $\lambda = \text{const.}$

Diese setzt sich zusammen aus einer Bewertung des Aufwands $L(c)$, der für das System notwendig ist, um zum Kandidaten zu gelangen, und einem Wert $A(c)$, der die Explorativität des Kandidaten wiedergibt. $L(c)$ ergibt sich aus der Länge des kollisionsfreien Pfades. Letzterer $A(c)$ berechnet sich aus der Größe der durch die Datenlücken einsehbaren und bisher nicht erkundeten Gebiete (Abbildung 2.7c). Mit dieser Parametrisierung lässt sich die Attraktivität von Kandidaten steigern, die eine explorative aber auch effektive Navigation in unbekannter Umgebung ermöglichen.

Sammelt das System nach dem Erreichen der nächsten Messpose neue Daten, müssen diese in das bis dahin erstellte Modell integriert und darauf der vom System sicher befahrbare Bereich $S(q)$ mit $S(q) = f(s(1), \dots, s(q))$ sowie die Umgrenzung $L(q)$ mit $L(q) = f(l(1), \dots, l(q))$ aktualisiert werden. Dazu werden $s(q + 1)$ und $l(q + 1)$ mit den bestehenden Daten verschmolzen.

Ein Problem bei der Exploration ist es zu bestimmen, welche Enden bereits erfasster Umgebungsoberflächen korrespondieren, gemeinsam also einen unexplorierten Bereich bilden. Die hier vorliegende Modellierung der Umgebung als geschlossener Linienzug l hat den Vorteil, dass diese Kenntnis bereits direkt vorliegt. Der genannte Ansatz funktioniert jedoch nur, solange sich die Umgebung auch als einzelner Linienzug darstellen lässt. Objekteinschlüsse wie z.B. Säulen können hier zu Inkonsistenzen im Modell führen.

Gleiches gilt für den Ansatz von Surmann [101]. Eine Bestimmung der Zugehörigkeiten erfolgt hier durch die Überschneidung von Polygonen. Dabei werden die einzelnen Scans zunächst separat auf eine polygonale Darstellung reduziert. Die noch nicht explorierten Umgebungsbereiche bleiben somit erhalten. Diese einzelnen Polygone werden anschließend übereinandergelegt und neu verschnitten.

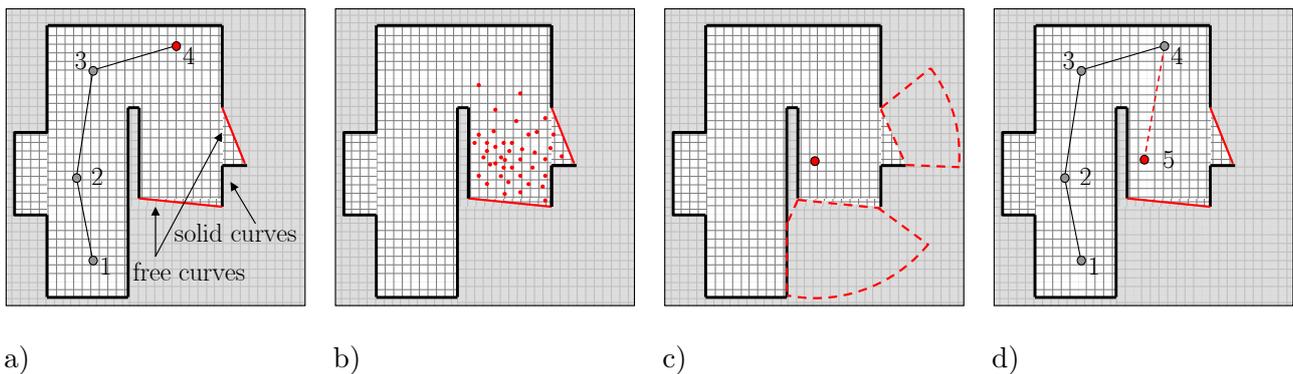


Abb. 2.7: Schritte zur Bestimmung einer neuen Messpose $M(q + 1)$ im Verlauf der Exploration (Modifizierte Grafik nach González-Baños [37])

- Ableitung der *solid curves* und *free curves*
- Generierung von Posekandidaten c
- Evaluierung der Posekandidaten abhängig vom potentiell größten Flächenertrag $A(c)$
- Wahl des besten Kandidaten zur nächsten Pose

Die genannten Strategien sind auf eine effiziente Wahl der nächsten Messpose in einer lokalen Umgebung ausgerichtet und können in komplexeren Szenarien ineffektiv werden. Hier empfiehlt sich eher ein

hierarchischer Aufbau der Explorationsstrategie, wobei eine globale Steuerung der Exploration durch übergeordnete Methoden erfolgt und eine lokale Exploration punktuell eingesetzt wird (wie z.B. in Schmidt [92]).

2.4 3D-Gebäuderekonstruktion

Die 3D-Rekonstruktion und Visualisierung von Gebäuden ist ein Forschungsgebiet, dem sich die Wissenschaft mit immer größerem Interesse zuwendet. Frei verfügbare Applikationen wie Microsoft's *Bing Maps* oder Google's *Street View* führen heute auch zu einer breiteren Wahrnehmung im öffentlichen Bewusstsein. Frühere Entwicklungen ermöglichten zunächst eine großflächige, kartenhaften Darstellung der Welt (z.B. *Google Earth*). Der aktuelle Trend geht vom Großen ins Kleine. Die bestehenden Modelle werden mit immer mehr Detailreichtum versehen, so dass eine dreidimensionale Betrachtung einzelner Gebäude von außen als auch von innen möglich wird.

Messmittel

Zur Datenaufnahme werden einerseits Laserscanner verwendet, durch die sich dichte 3D-Punktwolken der Umgebungen aufgezeichnet lassen. Aufgrund der Systemkomplexität aber auch aus Kostengründen werden diese hauptsächlich von professionellen Nutzern eingesetzt.

Eine günstigere Alternative bilden bildbasierte Rekonstruktionsmethoden durch den Einsatz von Digital- und Videokameras. Deren weite Verbreitung motiviert einerseits zur gezielten Entwicklung kommerzieller Anwendungen, führt aber gleichzeitig auch durch das Internet zu einer frei nutzbaren Datenbank, die sich als Quelle nutzen lässt (vgl. z.B. [95]).

TOF (*Time Of Flight*) Kameras stellen eine Sensortechnologie dar, die als eine Mischung aus Abstandssensor und Kamera betrachtet werden kann. Der aktive Sensor ermöglicht eine synchrone Distanzmessung zu einer Vielzahl an Punkten im Aufnahmebereich zur Erzeugung einer pixelweisen Tiefenkarte. Aufgrund der geringen Messgenauigkeit von mehreren cm [47] steht eine weitere Verbreitung dieser Technologie jedoch noch aus.

Bildbasierte Rekonstruktionsmethoden

Die Möglichkeiten einer bildbasierten Rekonstruktion von Innenräumen sind vielfältig. In der Regel erfolgt die Bestimmung der Objektgeometrie durch die Analyse von Aufnahmen, die von unterschiedlichen Standpunkten aus gemacht wurden (engl.: *structure from motion*).

Beim Einsatz einer Videokamera lassen sich Umgebungen mit einer hohen Datenrate erfassen. Die nur geringe Änderung der Bildinhalte ermöglicht den Einsatz von schnellen Algorithmen zur gleichzeitigen Merkmalsverfolgung (engl.: *feature tracking*) und 3D Punktbestimmung (z.B. PTAM [52]). Aufgrund des großen Datenvolumens beschränken sich die Anwendungen oft auf die Verwendung von Sensoren mit niedriger Auflösung, wodurch die Genauigkeit limitiert wird. Liegen nur einzelne und unsortierte Aufnahmen einer Szene vor, erschwert sich deren Rekonstruktion. Verfahren wie SIFT ermöglichen hier eine Zuordnung der Bilder (vgl. Abschnitt 2.4.1). Über die Punktkorrespondenzen lassen sich die Kameraposen zu den Aufnahmezeitpunkten sowie die Objektgeometrie ermitteln (engl.: *multi-view stereo*) und gegebenenfalls über einen Bündelausgleich (siehe Anhang A.4) präzisieren. Entsprechende Softwarelösungen sind frei verfügbar [96]. Ein entsprechender Aufwand ist nicht nötig, wenn die relative Orientierung zwischen den Kamerastandpunkten bereits „a priori“ bekannt ist, wie bei Stereokamerasystemen der Fall. Durch diese Vorkenntnis lassen sich die jeweils aufgenommenen Bildpaare

rektifizieren und über die Ableitung der Disparität Bildpunkte pixelweise zuordnen bzw. deren 3D Koordinaten rekonstruieren (engl.: *stereo matching*). Diese Vorgehensweise erlaubt die Erzeugung von hochauflösenden Tiefenkarten. Furukawa zeigt in [34], dass entsprechende Algorithmen auch erfolgreich auf Einzelbildverbände anwendbar sind, die sich durch substantiellere Perspektivwechsel auszeichnen, als dies bei Stereobildpaaren der Fall ist.

Auch eine objektseitige Rekonstruktion anhand von Einzelaufnahmen ist möglich [20]. Hierbei werden Annahmen bezüglich der Bildinhalte bzw. der geometrischen Beschaffenheit der Umgebung getroffen und darüber versucht die Abstände einzelner Bildbereiche abzuschätzen.

Modellgenerierung

Die Modellierung stellt in der Regel den letzten Rekonstruktionsschritt dar. Ziel ist eine Abstraktion der Messdaten durch die Suche nach geometrischen Strukturen, wie planaren Oberflächen (siehe z.B. [106]). Als Eingangsdaten können die Bilddaten oder die rekonstruierten Punktwolken dienen. Hybride Ansätze versuchen beide Informationsquellen vorteilhaft miteinander zu kombinieren (z.B. [11]). Der Großteil der Verfahren beschränkt sich derzeit auf Anwendungen im Außenbereich. Es existieren jedoch bereits auch Ansätze, die unter der Annahme von Manhattan-World Szenen eine vollautomatische Modellierung von Innenräumen erlauben, wie z.B. in [14] gegeben.

Gesonderte Voraussetzungen im Innen- und Außenbereich

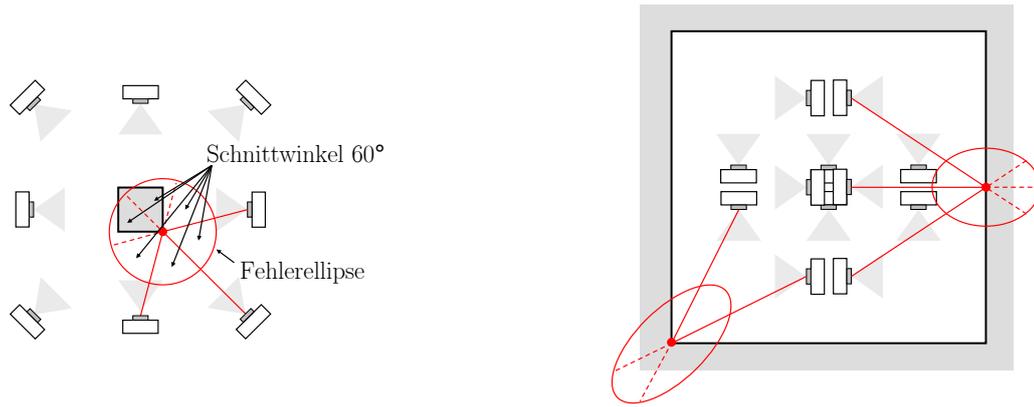
Prinzipiell zu unterscheiden ist, ob Innenraumszenen oder Objekte im Außenbereich rekonstruiert werden sollen. Letztere ist die einfachere der beiden Aufgaben. In der Regel gelingt dem Nutzer zwangsläufig eine Erfassung von Messdaten, die für eine adäquate Rekonstruktion verwendet werden können, indem er sich um das entsprechende Objekt herum bewegt und eine redundante Aufnahme aller Bereiche berücksichtigt⁴. Außenumgebungen bieten zudem für gewöhnlich vermehrt Oberflächen mit natürlichen Texturen, die sich eindeutig wiedererkennen lassen. Des Weiteren ist der Einsatz infrastruktureller Technologien wie z.B. eine Unterstützung des Messprozesses durch GPS möglich (z.B. [89]). So gehören semi-automatische bzw. automatische Rekonstruktionsverfahren im Außenbereich zum Stand der Technik [114].

Im Innenbereich bilden monochrome und texturlose Oberflächen oder aber regelmäßige Muster einen größeren Anteil der Umgebungsoberflächen. Beide Erscheinungen wirken sich negativ auf den Prozess der Bildzuordnung aus (vgl. Abschnitt 2.4.1). Die räumlichen Strukturen wie enge Flure und Türen beschränken die Positionierungsmöglichkeiten des Sensors, also der Kamera. Dadurch erschwert sich das Vorhaben, die Messposen so zu wählen, dass alle Oberflächen aus verschiedenen Perspektiven beobachtet werden und auch Verknüpfungsmessungen zwischen allen Raumbereichen vorliegen. Das den bildbasierten Methoden zugrunde liegende Triangulationsprinzip verlangt zur Optimierung der Schnittbedingungen und damit der Rekonstruktionsgenauigkeit nach möglichst großen Basisweiten zwischen den Messposen. So kann diese Forderung im Innenbereich nur bedingt erfüllt werden (Abbildung 2.8b).

Beispiele zur automatischen Rekonstruktion von Innenraumszenen

Die *Microsoft Live Labs* bieten im Internet mit der Software *Photosynth* eine Möglichkeit an, aus mehreren Aufnahmen einer Szene im Außen- oder auch Innenbereich ein 3D-Modell der Umgebung zu erstellen [74]. Zudem ist ein Regelwerk zur Aufnahmeplanung im Innenraum gegeben. Durch die Ex-

⁴in etwa der Aufnahmeconfiguration in Abbildung 2.8a entsprechend



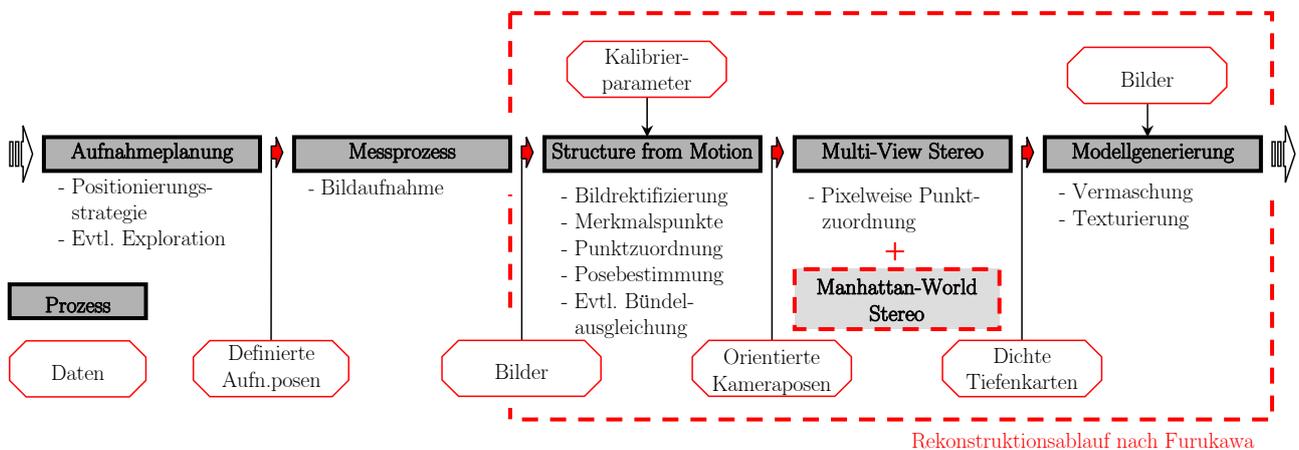
a)

b)

Abb. 2.8: Aufnahmekonstellationen im Innen- und Außenbereich für den 2D-Aufnahmefall
 a) Außenbereich: Optimale Bildstrahlschnittbedingungen und isotrope Fehlerellipsen an den Ecken eines Quadrats
 b) Innenbereich: Einhaltung optimaler Schnittbedingungen bedingt durch die Umgebungsgeometrie nicht möglich

traktion und Zuordnung von Merkmalspunkten werden die relativen Orientierungen der Kameraposen bestimmt und zugleich eine Punktwolke geringer Dichte erzeugt. Der Schwerpunkt der Applikation liegt jedoch nicht auf einer maßgetreuen Rekonstruktion, sondern vielmehr darauf dem Nutzer eine dreidimensionale Navigation durch die vorhandenen Ansichten einer Szene zu ermöglichen, um einen räumlichen Eindruck von dieser zu erhalten.

Ein vollautomatischer Ansatz zur geometrischen Rekonstruktion mit anschließender Modellbildung ist in [33] gegeben (vgl. Abbildung 2.9). Ausgangspunkt des Verfahrens ist ein Bildverband der zu rekonstruierenden Szene, der als gegeben betrachtet wird. Anhand von *structure from motion* Software [96] werden zunächst die Bilder orientiert, bzw. die Kameraposen ermittelt und bereits eine dünne Punktwolke der Umgebung erzeugt. Dies ermöglicht im Anschluss eine dichtere Objektrekonstruktion anhand von *stereo matching* Algorithmen [34]. Um eine höhere Robustheit des Verfahrens zu erreichen und Datenlücken, hervorgerufen durch texturarme Umgebungsbereiche, zu füllen, wird die Szenerie als „Manhattan-World“ [18] betrachtet und jedes Bildpixel einer zuvor geschätzten Raumebene zugeordnet. Eine Verschneidung der Raumebenen führt zu einem 3D Gitternetzmodell.



Rekonstruktionsablauf nach Furukawa

Abb. 2.9: Vollständige Prozessfolge zur automatischen Erzeugung eines Innenraummodells anhand von Bilddaten (Modifizierte Grafik nach Furukawa [33])

2.4.1 Photogrammetrische Rekonstruktion von Innenräumen

Bei einer photogrammetrischen Rekonstruktion wird von einer Szene oder einem Objekt ein Bildverbund aufgenommen, dessen einzelne Aufnahmen die zu rekonstruierenden Oberflächenbereiche redundant abbilden. Für eine 3D-Rekonstruktion der Szene gilt es die relative räumliche Lage der Bilder zum Zeitpunkt der Aufnahme zu ermitteln. Bildverbände lassen sich anhand von Pass- oder Verknüpfungspunkten in ein gemeinsames Koordinatensystem transformieren. Im Bereich der Mehrbildmessung bildet die Bündelausgleichung das meist verwendete Verfahren zur simultanen Aufnahmeorientierung und Punktreakonstruktion. Bei der Beobachtung von unbekanntem Objekten bilden Verknüpfungspunkte die einzige Möglichkeit der Bildzuordnung. Diese müssen über spezielle Verfahren ermittelt und einander zugeordnet werden.

Merkmalerkennung

Im Bereich des maschinellen Sehens dient die Merkmalerkennung (engl: *feature detection*) dazu, hilfreiche Informationen aus den gegebenen Bilddaten zu extrahieren. Die abgeleiteten Informationen bilden häufig die Grundlage für weiterführende Anwendungen wie die Bildzuordnung, die Objekterkennung oder auch die Posebestimmung.

Eine gemeinsame Anforderung an die eingesetzten Verfahren ist ein hoher Wiedererkennungswert der extrahierten Merkmale. Die Verfahren sollen Bildpunkte oder auch -bereiche definieren, die mit hoher Wahrscheinlichkeit in anderen Aufnahmen derselben Szene ebenso extrahiert werden, um mit weiteren Methoden einander zugeordnet werden zu können. Die Wiedererkennung sollte sich dabei möglichst robust gegenüber Variationen der Skalierung, der Bildrotation, des Betrachtungswinkels und Helligkeitsschwankungen verhalten. Auch der Prozessierungsaufwand und die damit verbundene Verarbeitungszeit spielt in vielen Applikationen eine wesentliche Rolle. So existieren unterschiedliche Ansätze zur Merkmalsextraktion, die auf verschiedene Merkmalstypen setzen und für eine spezielle Art der Anwendung optimiert sind. Die in der Literatur überwiegend vorfindbaren Merkmalstypen sind: *Ecken*, *Kanten* und *Blobs* [26, 42, 72].

Der von Harris und Stephens [42] publizierte Operator ist ein weit verbreitetes Beispiel für die Ecken-detektion. Bei diesem wird ein Merkmalspunkt über den ihn umgebenden Bildausschnitt beschrieben. Eine Bestimmung von Ecken erfolgt durch die Betrachtung der Gradientenverteilung bezüglich des Ursprungs innerhalb dieses Fensters.

Als populäre Verfahren im Bereich der Kantendetektion können der Canny- [26] oder auch der Sobel-Operator genannt werden. Durch die Annäherung der ersten Ableitungen entlang der Bildhauptrichtungen lassen sich mit diesen Operatoren Kantenpunkte als Maxima des entstehenden Gradientenbildes erkennen.

Unter *Blobs* versteht man Bildpunkte bzw. -bereiche, deren Farbwerte sich gegenüber ihrer Umgebung abheben [72]. Die sogenannten *Zero-Crossing*-Verfahren arbeiten mit einer Näherung der zweiten Ableitung der Bildfunktion, deren lokale Maxima wiederum zu den Merkmalspunkten führen. Ein bekanntes Beispiel stellt hier das Laplace-Filter dar. Aufgrund dessen hoher Sensibilität gegenüber Bildrauschen wird diesem meist ein Gaußfilter zur Bildglättung vorangestellt. Dieses kombinierte Filter wird als *Laplacian-of-Gaussian*, kurz LoG, bezeichnet. Auch das LoG Filter reagiert auf Ecken und Kanten. Ein Vorteil ist jedoch dessen Invarianz gegenüber der Bildskalierung.

Zuordnungsverfahren

Die Verfahren zur Zuordnung der extrahierten Merkmalspunkte in mehreren Bildern lassen sich in geometrie- und bildbasierte Verfahren unterteilen. Geometriebasierte Verfahren greifen auf die Vorkenntnis der relativen Orientierungen zwischen den Kameraposen zurück. Über das Modell der Epipolargeometrie kann dann der Suchraum zur Zuordnung eingeschränkt werden. Bildbasierte Verfahren hingegen versuchen einem Punkt aufgrund der Bildinformation in dessen Nachbarschaft eine eindeutige und wiedererkennbare Beschreibung in Form eines Merkmalsvektors, dem sogenannten Deskriptor, zuzuweisen. Eines der wohl populärsten Verfahren zur Extraktion und bildbasierten Zuordnung von Merkmalspunkten ist die skaleninvariante Merkmalstransformation, bekannt unter der Bezeichnung SIFT (engl.: *Scale Invariant Feature Transform*) und publiziert von Lowe [69, 70] (vgl. Anhang A.5). Aufgrund seiner Robustheit gegenüber Bildrotationen und Skalierung war es ein Durchbruch im Bereich der automatischen Bildererkennung und bildete die Grundlage für eine Vielzahl später veröffentlichter Merkmalsverfahren.

Aufnahmeplanung (engl.: *view planning*)

Mit dem Begriff *Aufnahmeplanung* ist im Bereich der Photogrammetrie die Konzeptionierung aller für eine photogrammetrische Rekonstruktion erforderlichen Schritte gemeint. Diese stellt eine wichtige Maßnahme dar, da sich die Qualität einer photogrammetrischen Messung aus allen beteiligten Systemparametern ergibt. Zu letzteren zählen die Aufnahmekonfiguration, die verwendete Hardware als auch die anschließenden Berechnungsverfahren. Da sowohl die Hardware als auch die Berechnungsverfahren in dieser Arbeit als gegeben angesehen werden, sollen an dieser Stelle nur die Aufnahmekonfigurationen näher betrachtet werden. Es sei hier auf die „ 3×3 rules“ von Waldhäusl [107] verwiesen, die eine Zusammenfassung der wichtigsten Grundregeln zur Aufnahmeplanung geben.

Ein klassisches Anwendungsgebiet der Photogrammetrie ist die Vermessung aus der Luft. Dabei werden die Gebiete in der Regel streifenweise, in konstanter Flughöhe und mit senkrecht blickender Kamera abgetastet. Im Gegensatz dazu sind in der Nahbereichsphotogrammetrie prinzipiell beliebige Aufnahmekonstellationen möglich. Grundsätzliches Ziel ist es die Messkonstellation so zu wählen, dass bei minimaler Standpunktzahl eine hohe und in allen Richtungen gleichmäßige Koordinatengenauigkeit erreicht werden kann. Die Gleichmäßigkeit ist abhängig von den Schnittbedingungen am Objekt. Wie in Abbildung 2.8a zu sehen, sind isotrope Fehlerverteilungen mit einer entsprechenden Winkelaufteilung der Schnittstrahlen möglich. Aber auch hier ergeben sich Einschränkungen aus den technischen Parametern der Sensorik sowie der Form und Beschaffenheit des zu vermessenden Objektes.

Eine Zusammenstellung von Randbedingungen, die bei der Platzierung von Sensoren im Rahmen photogrammetrischer Anwendungen zu beachten sind, ist in [73] gegeben. Die Arbeit beschäftigt sich mit der Entwicklung eines Programms zur automatischen Wahl optimaler Sensorposen, um die photogrammetrische Rekonstruktion einer Menge von Merkmalspunkten mittels eines Bündelausgleichs durchzuführen. Die Zuordnung der Merkmalspunkte wird dabei als gegeben betrachtet. Zur Definition einer Merkmalspunktmenge wird das zu rekonstruierende Objekt, von dem im Vorfeld ein CAD-Modell verfügbar ist, in geometrische Primitive zerlegt. Für diese werden zunächst getrennte Posenkonstellationen bestimmt. Diese Subkonfigurationen werden durch die Definition weiterer Kameraposen später miteinander verknüpft. Für die Wahl der Sensorposen werden folgende Bedingungen aufgestellt:

- *Auflösung und Skalierung:*

Bildmerkmale müssen mit einer minimalen Auflösung erfasst werden, um messbar zu sein. Der maximale Aufnahmeabstand sollte eingeschränkt sein, da die Genauigkeit der Merkmalsmessung

abhängig von der Bildskalierung ist

- *Fokussierung:*
Bildmerkmale müssen in einem Abstandsintervall zum Kamerasensor liegen, das in etwa dessen Schärfentiefebereich entspricht
- *Suchraum und Sichtbarkeit:*
Bei der Wahl der Sensorposen müssen mögliche Einschränkungen des Suchraumes durch Hindernisse berücksichtigt werden. Die Merkmalspunkte müssen im Sichtfeld der Kamera liegen und dürfen nicht durch Abschattungen verdeckt sein
- *Beobachtungswinkel:*
Der Aufnahmewinkel gegenüber des Normalenvektors eines Merkmalspunktes bzw. dessen lokaler Oberfläche sollte gering gehalten werden, da ansonsten die Messbarkeit des Merkmals negativ beeinträchtigt werden kann
- *Merkmalsverteilung:*
Eine ausreichende Anzahl an Merkmalspunkten pro Bild sowie deren gleichmäßige Verteilung im Bildbereich ist notwendig, um die Parameter der äußeren Orientierung jeder Kamerapose bestimmen zu können. Insbesondere bei einer Simultankalibrierung der Kamera, um zusätzlich deren Kalibrierparameter bestimmen zu können

Abbildung 2.10 soll hier für eine Veranschaulichung dienen.

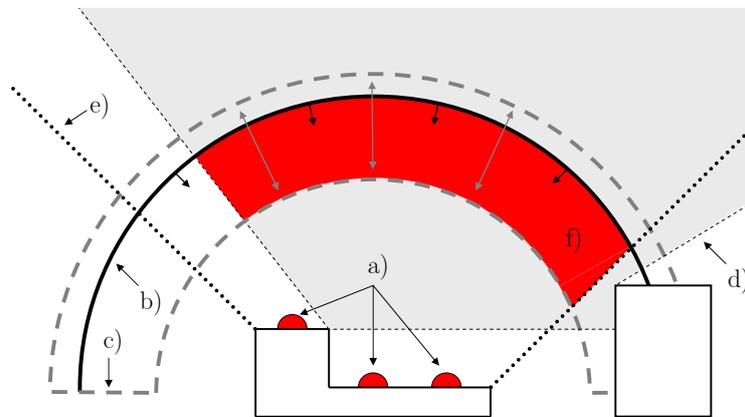


Abb. 2.10: Einschränkung des Suchraumes bei der Wahl von Kameraposen zur Erfassung einer Menge von Merkmalspunkten als Schnittmenge der Einzelbedingungen

- a) Merkmalspunkte
- b) Einschränkung des maximalen Abstands aufgrund einer geforderten Mindestauflösung
- c) Definition eines Abstandsintervalls entsprechend des Schärfentiefebereichs
- d) Einschränkung der Sichtbarkeit durch Hindernisse
- e) Einschränkung des Beobachtungswinkels
- f) Verbleibender Suchraum

Subkonfigurationen

In einem Bündelausgleich kann ein Bildverband nur dann mit einem gemeinsamen Datum ausgeglichen werden, wenn alle Bilder ausreichende Verknüpfungen zueinander aufweisen. Dabei müssen sich zwischen allen Bildern direkte oder indirekte Verbindungen herstellen lassen. Besteht ein Bildverband aus mehreren Bildgruppen, deren Bilder zwar untereinander verknüpft sind, gruppenübergreifend jedoch

keine Verbindungen vorhanden sind, spricht man von sogenannten Subkonfigurationen. Diese müssen bei der Planung der Aufnahmeconfiguration erkannt und behoben werden.

Datumsdefekt

Eine gleichzeitige Schätzung aller Kameraposen und der zu rekonstruierenden Objektpunkte führt zu einem Datumsdefekt im Bündelausgleich, wenn in die Ausgleichung nicht weitere Restriktionen eingeführt werden. Lage, Orientierung und Maßstab des Bildverbandes sind „a priori“ unbestimmt. Somit ergeben sich hier 7 Freiheitsgrade. Eine gängige Möglichkeit zur Behebung des Datumsdefekts ist es, eine Kameraposition samt Orientierung sowie eine Koordinate einer weiteren Pose als gegeben zu betrachten und somit im Bündelausgleich festzuhalten.

2.4.2 Robotische Ansätze zur 3D-Umgebungserfassung

Während sich Abschnitt 2.4 bisher mit der 3D-Rekonstruktion von Gebäuden im Allgemeinen beschäftigte, sollen die Problematiken nun von robotischen Gesichtspunkten aus betrachtet und mögliche Lösungsansätze anhand von Beispielen erklärt werden.

Umgang mit der Erweiterung der Aufgabenstellung auf den \mathbb{R}^3

Die Zielstellung ein robotisches System zur 3D-Rekonstruktion von Innenräumen zu konzipieren führt dazu, dass die in den Kapiteln 2.1-2.3 beschriebenen, zweidimensionalen Problemstellungen eines Roboters auf den \mathbb{R}^3 erweitert werden müssen. Weil zur vollständigen Definition der Roboterconfiguration im \mathbb{R}^3 nicht mehr 3 (x, y, ϕ) , sondern 6 Freiheitsgrade $(x, y, z, \omega, \phi, \kappa)$ benötigt werden, steigen Komplexität und Rechenaufwand für das Lokalisierungsverfahren, die Kartierungsmethodik als auch die Bewegungsplanung, die entsprechend erweitert werden müssen. Aus diesem Grund gibt es nur wenige Veröffentlichungen über Systeme, die in der Lage sind, restriktionsfrei dreidimensionale Umgebungen zu explorieren und entsprechend zu kartieren (z.B.[60]). Zur Repräsentation der Umgebung werden 3D-Belegtheitsgitter, 3D-Punktwolken oder auch DEMs (*Digital Elevation Maps*) verwendet.

Die Mehrzahl der Ansätze nimmt eine Abstraktion der Daten vor (z.B. [100, 109]) oder reduziert einen Teil der robotischen Navigationsaufgaben auf den 2D-Fall (z.B. [101, 113]), da hier bereits erprobte Strategien existieren (Abbildung 2.11). In [101] wird z.B. eine 3D-Punktwolke der Umgebung erzeugt, indem einzelne 3D-Scans anhand des ICP Algorithmus in einem gemeinsamen Koordinatensystem registriert werden. Auf diesem Weg wird zwar ein 3D-Modell der Umgebung erstellt, der Roboter selbst nutzt zur Navigation jedoch eine 2D-Karte. Diese ergibt sich über mehrere Horizontalschnitte, die durch die 3D-Umgebung gelegt werden. So kann die Bestimmung der nächsten Messpose anhand von 2D-Methoden erfolgen. Ein vergleichbarer bildbasierter Ansatz ist in [38] gegeben. Auch der hier verwendete Roboter navigiert durch den Aufbau einer 2D-Karte mittels eines Laserscanners. Mit einer zusätzlich angebrachten Kamera werden Bildsequenzen von ausgewählten Umgebungsbereichen aufgenommen. Durch die Detektion von Ecken werden korrespondierende Punkte in den Aufnahmen ermittelt und ein Drahtgittermodell dieser Bereiche abgeleitet.

Weingarten vereinfacht in [109] die Komplexität durch eine Abstraktion der Umgebung. Die gesammelte Punktwolke wird in gleich große Abschnitte eingeteilt, durch die Ebenen geschätzt werden. Durch die Fusion gleichgerichteter Ebenen ergibt sich eine abstrahierte und vereinfachte Darstellung der Umgebung, die für die SLAM Methoden effektiv weiterverwendet werden kann. Es existieren Ansätze, die in der Lage sind, eine Echtzeit-Prozessierung mit 6 Freiheitsgraden durchzuführen (z.B. [86, 61]).

Der in [86] verwendete mobile Roboter „Kurt3D“ ist in der Lage, die anhand eines 3D-Laserscanners gesammelten Punktdaten bekannten Objektklassen zuzuordnen und somit die Umgebung anhand von abstrahierten Strukturen in semantischen dreidimensionalen Karten darzustellen.

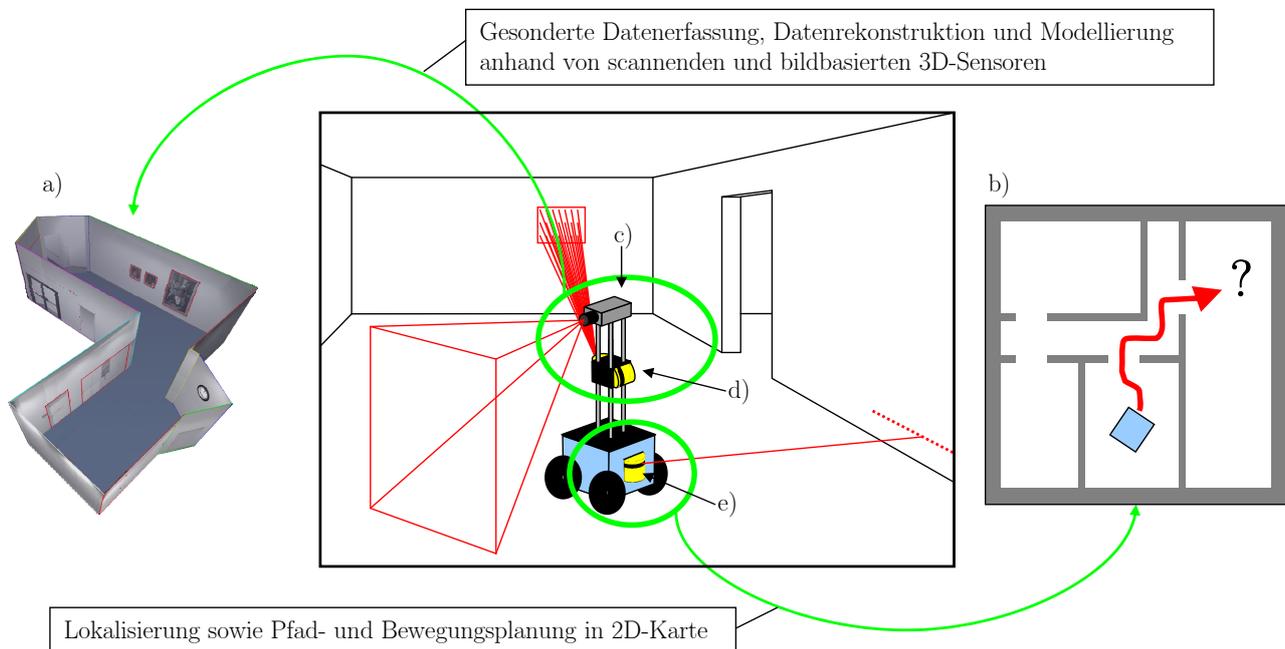


Abb. 2.11: Aufgabenverteilung auf 2D-Navigation und 3D-Rekonstruktion

- a) Texturiertes 3D-Modell [45]
- b) 2D-Grundrisskarte für Navigationszwecke
- c) Kamerasensor zur Bildaufnahme
- d) 3D-fähiger Laserscanner
- e) 2D-Laserscanner

Automatische Aufnahmeplanung für robotische Applikationen

Wie in diesem Kapitel aufgezeigt, stellt die Aufnahmeplanung einen wesentlichen Schritt des Rekonstruktionsprozesses dar. Für robotische Anwendungen müssen automatisierte Strategien zur Sensorplatzierung gefunden werden.

Prinzipiell ist bei der Planung zu unterscheiden, ob die Geometrie des Messobjekts bzw. der zu erfassenden Umgebung bereits „a priori“ bekannt ist. Ist dies der Fall, können alle Planungen vor Durchführung der ersten Messung getätigt werden. Andernfalls muss eine Neueinschätzung der Situation nach jedem Messschritt erfolgen.

Entsprechend den robotischen Navigationsaufgaben ist auch bei der Aufnahmeplanung im \mathbb{R}^3 die sehr hohe Anzahl an Konfigurationsmöglichkeiten ein grundlegendes Problem. Der Berechnungsaufwand möglicher Posen steigt mit der Komplexität des Objekts bzw. des Umgebungsmodells. Ein Hauptgrund dafür ist, dass die Bestimmung von Sichtbarkeiten im \mathbb{R}^3 einen oftmals notwendigen und rechenaufwendigen Bearbeitungsschritt darstellt [68]. Entsprechend sind die in Abschnitt 2.3.2 gestellten Forderungen im 3D-Fall um eine Prozessierbarkeitsbedingung zu erweitern.

Ein wesentlicher Teil bisheriger Arbeiten konzentriert sich auf die Erfassung kleinerer Objekte. Hier ist es möglich die Menge der Aufnahmeposes auf eine Kugel zu beschränken, die um das zu erfassende Objekt gelegt wird (z.B. [17]). Durch eine Diskretisierung der Kugel läßt sich die Menge aller möglichen Posen definieren und jede Pose separat evaluieren. Für die Erfassung einer größeren Szene ist diese Vorgehensweise zu rechenaufwendig.

Surmann nutzt in [101] dagegen randomisierte Planungsverfahren zur Ableitung von 2D-Posen in einer Ebene, vergleichbar mit dem Vorgehen in [37] (vgl. Abschnitt 2.3.2), um das Kombinatorik-Problem⁵ zu umgehen. Eine entsprechende Vorgehensweise im Sinne des *Next-Best-View*-Theorems erlaubt eine effiziente Bestimmung von Posen, durch die sich ein möglichst großer Anteil an bisher unbekanntem Umgebungsbereichen erfassen läßt. Bei dieser Strategie werden jedoch die Registrierbarkeit der neuen Aufnahmen als auch die aus der Rekonstruktion resultierende Genauigkeit vernachlässigt.

Grundlegende Regeln für eine photogrammetrische Objektrekonstruktion wurden bereits in Abschnitt 2.4.1 genannt [73]. Diese beziehen sich vorwiegend auf die einzuhaltenden Bedingungen bei der Wahl einzelner Kameraposen, beachten aber nicht die Abhängigkeiten zwischen den Aufnahmen. Die gemeinsame Prozessierung von Aufnahmen, sei der Sensor eine Kamera oder ein Laserscanner, führt zu Nebenbedingungen bezüglich der Datenregistrierung. Im Fall eines Laserscanners ist eine ausreichende Überlappung zwischen den Aufnahmen notwendig (vgl. Abschnitt 2.2.2). Bei Verwendung einer Kamera müssen dagegen ausreichend Verknüpfungspunkte zwischen den Aufnahmen ableitbar sein (vgl. Abschnitt 2.4.1). Nur wenige Strategien berücksichtigen diese Registrierungsbedingung (z.B. [53, 68, 93]). Die Arbeiten von Klein [53] und Low [68] beschäftigen sich mit der Entwicklung von Sensorplatzierungsstrategien zur Erfassung initial unbekannter 3D-Umgebungen. Während Klein, dessen Strategie sowohl für Kameras als auch für Laserscanner ausgelegt ist, lediglich eine Mindestüberlappung fordert, verwendet Low, der sich mit einer rein Laserscanner-basierten Anwendung beschäftigt, eine explizite Analyse der Registrierbarkeit (vgl. [67]).

2.5 Fazit

Die Laserscanner-basierte 2D-Kartierung von Innenraumumgebungen ist ein Wissenschaftsgebiet, in dem bereits intensive Forschungsarbeit geleistet wurde. Folglich bestehen für die meisten der sich durch die Aufgabenstellung ergebenden Teilprobleme⁶ viele spezialisierte Lösungsansätze. Es existieren zahlreiche Systeme, die die Erzeugung von 2D-Umgebungskarten ermöglichen (z.B. [19, 37, 39, 41, 98]). Bei Betrachtung der bestehenden Bewegungsstrategien kann ein Defizit im Bereich der praktischen Evaluierung erkannt werden. Die bekannten Ansätze wurden nur unter Verwendung synthetischer Daten getestet (z.B. [92]) oder basieren auf restriktiven Annahmen in Bezug auf die Messumgebung (z.B. [37]).

Ein Großteil dieser Systeme verwendet Sick Laserscanner der LMS Serie [94], die eine rapide Datenerfassung in einem Blickfeld von 180° ermöglichen, jedoch eine Distanzmessgenauigkeit > 10 mm aufweisen. Das Genauigkeitsniveau einer damit erzeugten Umgebungskarte ist entsprechend restringiert und nur bedingt für Vermessungszwecke geeignet. Konkrete Aussagen bezüglich der Kartierungsgenauigkeit sind in den bekannten Veröffentlichungen im Themenbereich der autonomen Erfassung von Innenraumszenen, sowohl für 2D als auch für 3D Applikationen, kaum zu finden. Gegebenenfalls beschränken sich die Untersuchungen auf den Abgriff bzw. den Vergleich einzelner Maße [81]. Dies läßt sich unter anderem mit dem Verwendungszweck der Karten erklären. Dieser liegt in der Regel auf Seiten des Roboters, der die Karte zur Selbstlokalisierung nutzt, um mit dieser Grundinformation weiterführende Aufgaben ausführen zu können. Dementsprechend fehlt in vielen Anwendungen auch das Bestreben, die Art der Datenerfassung bzw. -verwaltung dahingehend auszurichten, dass sich die bei der Umgebungskartierung entstehende Punktwolke gut zu Modellierungszwecken eignet.

⁵vgl. voriger Abschnitt

⁶z.B. Navigation, Bewegungsplanung, Kartierung, Lokalisierung oder auch Loop-Closing

Auch kamerabasierte Robotersysteme gehören zum Stand der Technik. Kameras bieten durch ihre flächenhafte und farbige Darstellung der Umgebung eine optimale Datengrundlage zur Umgebungsbeobachtung durch einen Roboter. Für die Bestimmung metrischer Messgrößen werden oftmals Stereomessköpfe eingesetzt. Des Weiteren existieren Ansätze, die mit einer einzelnen Kamera arbeiten. Es zeigt sich, dass weder für robotische noch für handgehaltene Systeme explizite Positionierungsstrategien zur photogrammetrischen Aufnahmeplanung im Innenbereich existieren. Einfache Grundregeln, wie z.B. in [74] gegeben, stellen nur eine behelfsmäßige Lösung dar und lassen sich nicht direkt auf eine Robotikanwendung übertragen.

Es bestehen vollautomatische Verfahren zur Gebäuderekonstruktion wie z.B. [33]. Die Bereitstellung des Datenmaterials wird hier jedoch als gegeben betrachtet. Zudem gehen diese häufig von orthogonalen Beziehungen⁷ zwischen den Elementen der Umgebung aus, wodurch die Rekonstruktion robuster gemacht werden kann, das Rekonstruktionsergebnis jedoch verfälscht wird und eine Verwendung für vermessungstechnische Zwecke nicht in Frage kommt.

Die 3D-Umgebungserfassung anhand robotischer Systeme kann als eine Erweiterung der zweidimensionalen Aufgabenstellung betrachtet werden. Die bestehenden Systeme sind meist nur teilweise 3D-fähig sind. Aufgrund der erhöhten Komplexität reduziert die Mehrzahl der Systeme einen Teil der zu bewältigenden Aufgaben wie auch die Bewegungsplanung auf den \mathbb{R}^2 . Es existieren Positionierungsstrategien für den \mathbb{R}^3 , diese sind jedoch entweder für Laserscannerapplikationen ausgelegt (z.B. [68]), oder sie vernachlässigen die Bedürfnisse einer photogrammetrischen Rekonstruktion (z.B. [53]). Im Nahbereich gibt es Arbeiten wie z.B. [73], die die Kameraposen in Abhängigkeit der Rekonstruktionsgüte durch einen Bündelausgleich wählen. Diese Ansätze konzentrieren sich allerdings auf die Erfassung kleiner Objekte anstatt auf weitläufige Umgebungen.

⁷vgl. Manhattan-World

3 Exploration und Vermessung von Innenraumszenen im \mathbb{R}^2

Einleitung und Zielsetzung

Dieses Kapitel beschreibt einen Ansatz zur vollständigen, autonomen und zweidimensionalen Vermessung einer Innenraumszene mittels einer robotischen Plattform, 2D-RDM mobile genannt, unter Verwendung eines elektrooptischen Sensors. Zielsetzung ist die Aufnahme einer 2D-Punktwolke der Umgebung, die dazu genutzt werden kann, mit weiterführenden Softwaretools möglichst vollständige und genaue Innenraummodelle erzeugen zu können.

Abschnitt 3.1 präsentiert zunächst die verwendete Hardware. In den Abschnitten 3.2 bis 3.5 werden die softwareseitigen Verfahren vorgestellt, die dem System die Erledigung der Messaufgabe ermöglichen.

Eine empirische Evaluierung des Systems sowie eine Diskussion erfolgt in Kapitel 4.

Vorab soll die generelle Vorgehensweise anhand von Abbildung 3.1 erläutert werden. Das System fährt iterativ Posen an, die durch eine Explorationsstrategie definiert wurden, und führt an diesen Messungen durch. Die einzelnen Messungen werden durch ein Scan-Matching Verfahren in einem gemeinsamen Koordinatensystem registriert, so dass eine vollständige 2D-Punktwolke der Umgebung aufgebaut wird. Benachbarte Punkte werden in den Messdaten zu Liniensegmenten zusammengefügt. Deren Enden werden als Datenlücken definiert, da diese auf unexplorierte Bereiche hinweisen. Die Exploration gilt als abgeschlossen, wenn keine einmessbaren Datenlücken mehr gefunden werden. Solange dieser Zustand nicht erreicht ist, werden iterativ weitere Messposen angefahren.

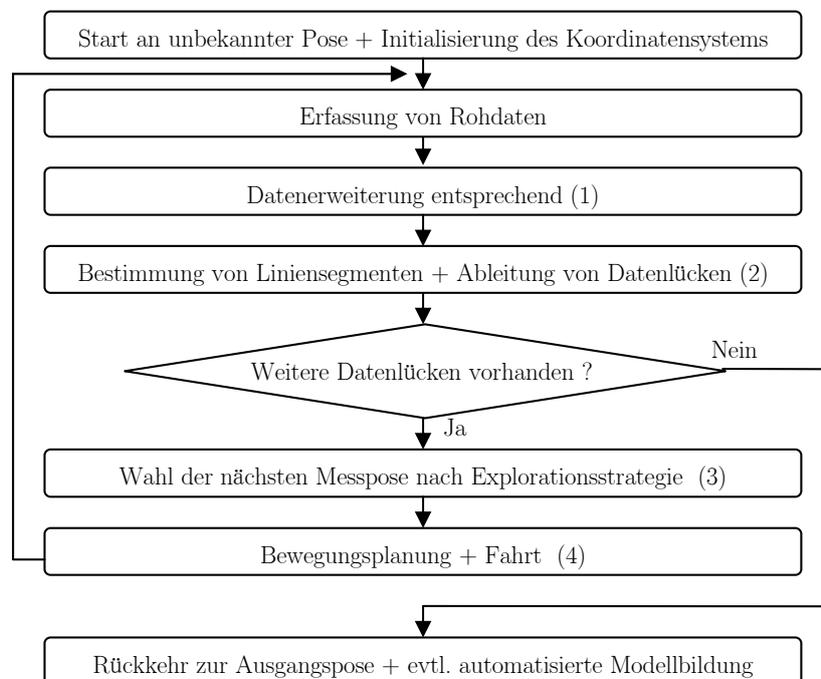


Abb. 3.1: Iterativer Gesamtablauf der Messprozedur im Fall der 2D-Vermessung

(1) vgl. Abschnitt 3.5

(2), (3) vgl. Abschnitt 3.4

(4) vgl. Abschnitt 3.3

3.1 Hardware 2D-RDM mobile

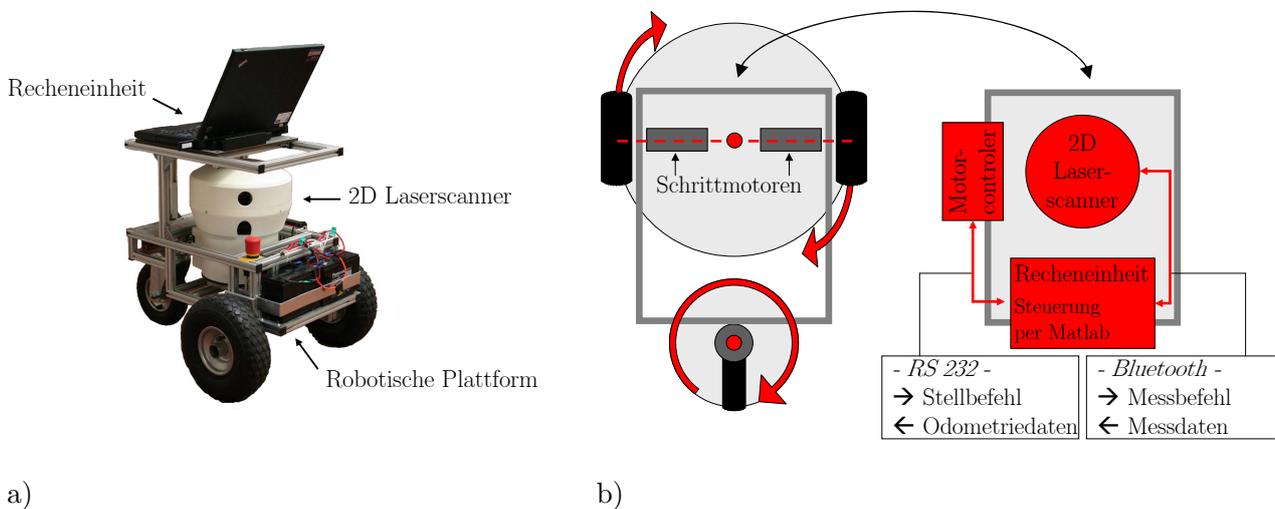


Abb. 3.2: Hardwareaufbau 2D-RDM mobile

a) Bild des 2D-RDM mobile

b) Schematische Darstellung *links*: Freiheitsgrade der Räder *rechts*: Vernetzung der Hardwarekomponenten

Der Hardwareaufbau des Systems ist in Abbildung 3.2 dargestellt. Die Basis bildet eine dreirädrige, mobile Plattform des Fraunhofer Instituts, der Volksbot RT3 [31]. Zwei Räder sind fest aufgehängt und lassen sich durch Elektromotoren antreiben. Ein drittes, nicht angetriebenes Rad ist um die senkrechte Achse frei beweglich. Zentraler Baustein der Bewegungssteuerung ist ein Motorcontroller, an den Stellbefehle gesendet und von dem Odometriedaten ausgelesen werden können. Zusätzlich sind auf der Plattform ein Laserscanner sowie ein Notebook installiert, welches als Recheneinheit und Steuerzentrale dient. Notebook und Laserscanner sind so auf der Plattform angebracht, dass letzterer über ein möglichst hindernisfreies Sichtfeld verfügt. Die verbleibenden Abschattungen, in Gestalt der senkrechten Verstrebungen zum oberen Aufbau, müssen in der Datenverarbeitung berücksichtigt werden.

Spezifikation des Messsystems	
Abmaße:	Länge: ca. 60 cm / Breite: ca. 45 cm / Höhe: ca. 50 cm
max. Fahrgeschwindigkeit:	0.5 m/s
Messdauer des Laserscanners:	ca. 60 s

2D-Laserscanner

Der verwendete Laserscanner ist ein Prototyp, der für die präzise Vermessung von Innenräumen entwickelt wurde (Abbildung 3.2a). In einem Messzyklus vermag der Sensor eine Punktwolke von 3600 Punkten aufzunehmen. Mit Winkelintervallen von je 0.1° wird die Umgebung in einer horizontalen Ebene im vollen 360° Sichtfeld erfasst. Der Sensor beruht auf dem Prinzip der Phasenmessung. Die Bestimmung der Messdistanzen erfolgt durch die Kombination jeweils dreier Phasenwerte. Eine Evaluierung der Distanzmessgenauigkeit wurde nicht für den verwendeten jedoch für einen baugleichen Prototyp durchgeführt (siehe Anhang A.6). Über das Genauigkeitsniveau der Winkelmessung liegen keine quantifizierbaren Kenntnisse vor. Der Mess- bzw. Eindeutigkeitsbereich liegt zwischen 0.5 m und 7.5 m. Eine Nivelliereinheit ermöglicht es den Messkopf des Laserscanners mit einer Genauigkeit

von ± 0.1 mm/m zu horizontieren¹. Die Winkelbestimmung erfolgt nicht durch einen direkten Abgriff der Werte. Stattdessen wird der Sensorkopf auf eine vordefinierte Rotationsgeschwindigkeit gebracht. Um diese zu erreichen, sind mehrere *Preturns* notwendig. Die gesammelten Messdaten werden per Bluetooth an die Recheneinheit gesendet. Die gesamte Messdauer² beträgt ca. 60 Sekunden.

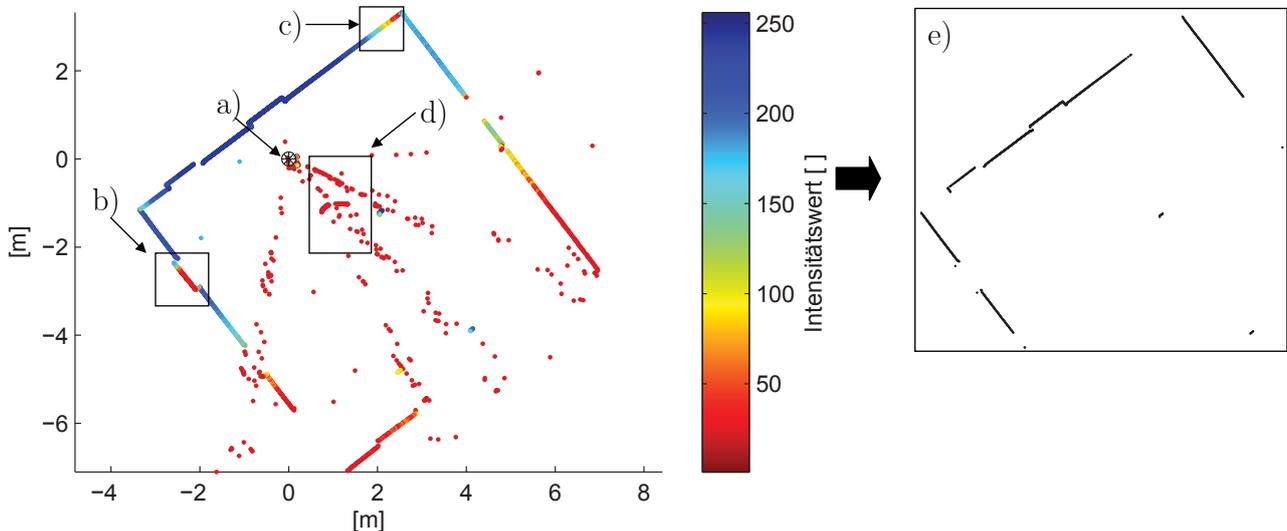


Abb. 3.3: Messdaten des Laserscanners

- a) Standpunkt
- b) schwache Reflektion an dunkler Oberfläche
- c) schwache Reflektion durch flachen Auftreffwinkel
- d) Artefakte durch Mehrdeutigkeit der Phasenmessung in Entfernungen > 7.5 m
- e) Verbleibende Daten nach Filterung

Charakterisierung des 2D-Laserscanners

Ein nicht zu vernachlässigender Teil der vom Sensor zurückgegeben Messwerte weist grobe Fehler auf, die der sehr schnellen elektrooptischen Distanzmessung zuzuschreiben sind. Während die Winkelmessung umgebungsunabhängig abläuft, ergeben sich in der Distanzmessung Messfehler in Abhängigkeit von der Beschaffenheit des Sensorumfelds. So können die Beschaffenheit der Umgebungsoberflächen, der Signalauftrittswinkel oder auch die Entfernung der Oberflächen zum Sensor einen nachteiligen Einfluss auf den Messprozess haben. Die genannten Fehlerquellen führen zu einer verminderten oder auch fehlerhaften Reflexion des Messsignals.

Prinzipiell verringert sich die Signalstärke bzw. das Signal-Rausch Verhältnis mit zunehmender Messdistanz aufgrund der Divergenz des Laserstrahls und der damit verbundenen Erhöhung der Spotgröße. Auch der Auftreffwinkel und die Beschaffenheit der Oberfläche beeinflussen diese Größe. Spiegelnde und transparente Oberflächen können zu einer ungenügenden bzw. fehlgerichteten Reflexion des Signals führen. Da die im Sensor verbaute Laserdiode rotes Licht der Wellenlänge 653 nm emittiert, reflektieren dunkle Oberflächen und Oberflächen komplementärer Farben wie blau und grün das Messsignal nur ungenügend.

Trifft der Messspot auf eine Raumkante³, so befindet sich ein Teil des Spots auf der in Bezug zum Messstandort näheren und der andere Teil auf der weiter entfernten Objektfläche. Das zum Detektor

¹bei 25° C

²Nivellierung + Preturns + Phasenmessung + Datenübertragung

³Vertiefung, Abschattung, Raumecke

(APD⁴) zurückkehrende Signal kann dann verzerrt sein, so dass ein mit der Umgebung nicht konformer Messpunkt ermittelt wird.

Das Prinzip der Phasenmessung fordert zur Bestimmung der absoluten Distanz eine Messung mehrerer Frequenzen. Die Wahl der Frequenzen wirkt sich auf die Messgenauigkeit als auch auf den Eindeutigkeitsbereich der Entfernungsmessung aus.

Um Fehlmessungen aus den Rohdaten extrahieren zu können, wird ein Intensitätswert⁵ analysiert, der aus der Signalamplitude des im Laserscanner eingehenden Messsignals abgeleitet wird. Ist die Intensität kleiner als ein vordefinierter Schwellwert, wird die Messung als Fehlmessung klassifiziert und aus den Daten gelöscht. Abbildung 3.3 zeigt die Datenpunkte einer Messung des Laserscanners farblich kodiert in Abhängigkeit vom Intensitätswert. Bei der Wahl des Schwellwertes muss ein Kompromiss eingegangen werden, da entweder unnötig viele Messungen entfernt oder aber Fehlmessungen beibehalten werden. Der Umgebungsbereich in b) stellt eine dunkel gefärbte Tür dar und wird aufgrund der geringen Signalreflektion herausgefiltert. Ähnlich verhält es sich mit Ausschnitt c), bei dem aufgrund des flachen Auftreffwinkels nur ein geringer Anteil des Signals zum Detektor wiederkehrt. In Bereich d) sind dagegen Artefakte zu erkennen, die Objekte außerhalb des Eindeutigkeitsbereiches abbilden. Der Schwellwert muss ausreichend streng gewählt werden, um diese Messungen zu eliminieren. Dabei entfallen jedoch auch die Messungen in den Bereichen c) und d).

Der Sensor erhitzt sich bei längerer Betriebsdauer, wodurch sich die Sensitivität des Detektors und damit die resultierenden Signalintensitäten über die Zeit ändern. Dieser Effekt wurde durch eine Messreihe erfasst in der eine Szene über einen längeren Zeitraum wiederholt vermessen und die ermittelten Signalintensitäten verglichen wurden. Basierend auf den Ergebnissen dieser Messreihe wird der Filterschwellwert beim Einsatz des Laserscanners zeitabhängig variiert. Generell wird der Schwellwert konservativ gewählt, so dass tendenziell zu viele Punkte gefiltert werden, jedoch möglichst wenige Fehlmessungen in den Daten verbleiben.

Zusätzlich erfolgt eine geometriebasierte Datenfilterung mittels eines Medianfilters, die davon ausgeht, dass die erfasste Umgebung aus kontinuierlichen Oberflächen besteht (vgl. Abschnitt 3.4.1). Es werden die Distanzen aufeinander folgender Messpunkte verglichen. Weist ein Messpunkt eine erhöhte Entfernungsdifferenz zum vorangehenden als auch zum Folgepunkt auf, wird er als Messfehler klassifiziert und aus den Messdaten entfernt. Teilabbildung 3.3e zeigt die nach der Filterung verbleibenden Daten der Beispielmessung.

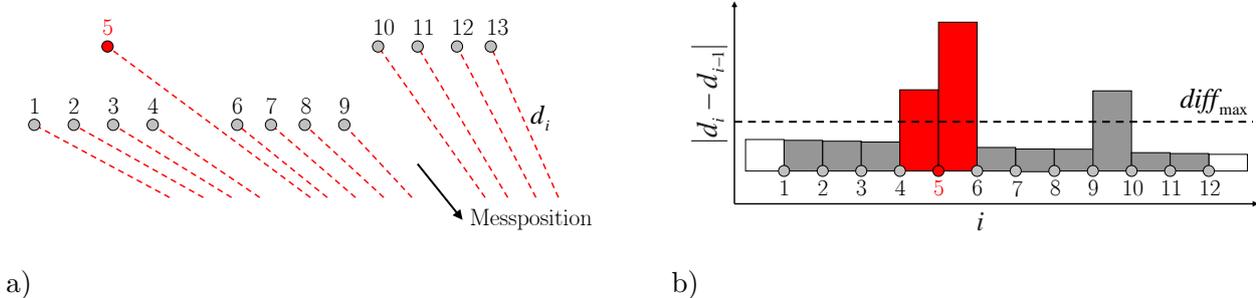


Abb. 3.4: Beispiel zur geometriebasierten Datenfilterung anhand eines Schwellwertes $diff_{max}$. Filterung des Messpunktes 5 da $|d_4 - d_5| > diff_{max}$ & $|d_5 - d_6| > diff_{max}$.

a) Räumliche Lage der Messpunkte

b) Betrachtung der Distanzdifferenzenbeträge $|d_i - d_{i-1}|$ zu den Nachbarpunkten

⁴Lawinenfotodiode (engl.: *Avalanche Photo Diode*)

⁵Wertebereich: 0-255 []

3.2 Belegtheitsgitter

Um die Aufgaben der Navigation und der Lokalisierung erfüllen zu können, verwendet das mobile Messsystem ein Belegtheitsgitter mit einer Zellgröße von 10×10 cm. Das Belegtheitsgitter ist im selben Koordinatensystem wie auch die Messdaten referenziert, Ursprung und Ausrichtung sind abhängig von der initialen Messpose des Sensors. Die Ausdehnung des Gitters passt sich während der Messprozedur dynamisch der Ausdehnung der Messdaten an.

Die einzelnen Gitterzellen $c_{m,n}$ können als *belegt* oder *unbelegt* klassifiziert werden. Die Klassifizierung ist abhängig vom Wahrscheinlichkeitswert s mit $P(s(c_{m,n}) = bel) \in [0;1]$. Dieser wiederum ergibt sich aus der Anzahl der Messstrahlen, die eine Zelle im Laufe des Einmessvorganges passieren. Überschreitet die Anzahl der Messstrahlen einen zuvor definierten Wert, wird die Gitterzelle als *unbelegt* klassifiziert. Wird im Raumbereich der Zelle ein Punkt gemessen, wird der Wert s dagegen auf 0 bzw. *belegt* zurückgesetzt. Damit entspricht die Vorgehensweise einer wahrscheinlichkeitsbasierten Gitterverfügung in vereinfachter Form.

Das mobile Messsystem erhält in der Karte aus Vereinfachungsgründen eine kreisförmige Repräsentation. Auf eine Modellierung des Konfigurationsraumes für die dreirädrige Plattform wurde verzichtet. Stattdessen wird das System auf einen einzelnen Punkt in der Karte reduziert und ist mit 3 Freiheitsgraden (x, y, ϕ) versehen. Die Ausdehnung d_{sys} ⁶ des Systems wird dagegen als Pufferbereich im Belegtheitsgitter berücksichtigt. Alle *unbelegten* Gitterzellen, die einen Abstand $\leq d_{sys}$ zu einer als *belegt* klassifizierten Zelle aufweisen, behalten ihre Klassifizierung zwar bei, werden in der Pfadplanung jedoch als nicht befahrbar angesehen. Die Menge der tatsächlich befahrbaren Gitterzellen C_{bef} ergibt sich aus der Menge der *unbelegten* Gitterzellen abzüglich der Pufferbereiche.

In Abbildung 3.5 ist beispielhaft das Belegtheitsgitter nach einer initialen Messung des Systems dargestellt. Der Sicherheits- bzw. Pufferbereich ist grau markiert.

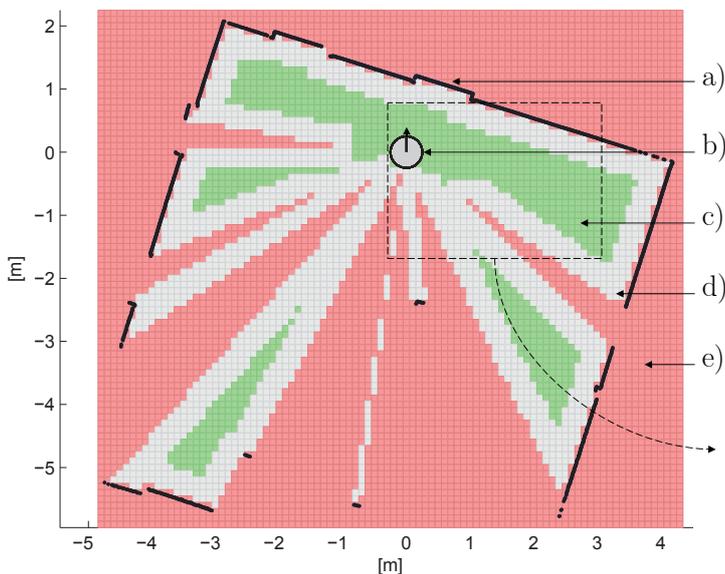


Abb. 3.5: Belegtheitsgitter und Konfigurationsraum

- a) Messdaten
- b) Kreisförmige Repräsentation des Roboters
- c) Befahrbare Gitterzellen
- d) Sicherheitsbereich des Konfigurationsraums
- e) Unexplorierte und nicht befahrbare Gitterzellen

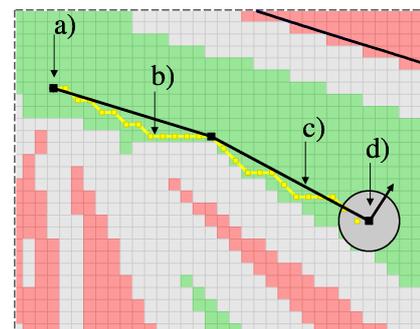


Abb. 3.6: Routenplanung im Belegtheitsgitter

- a) Ausgangspunkt
- b) Ergebnis der A* Suche
- c) Reduzierter Vektorpfad
- d) Finale Pose

⁶ $d_{sys} \hat{=} 35$ cm: definiert über das Bauteil mit maximalem horizontalem Abstand zum Achsmittelpunkt der Plattform

3.3 Lokale Bewegungsplanung

Routenplanung

Der Laserscanner greift jeden der drei Phasenwerte zur Bestimmung eines Entfernungswertes in einer gesonderten Umdrehung ab (vgl. Abschnitt 3.1). Dieser Umstand setzt voraus, dass das Messsystem während einer Messung an einer festen Position verbleibt. So erfolgt die Exploration einer Umgebung durch das sukzessive Anfahren definierter Posen. Die Vorgabe dieser Posen erfolgt durch die Explorationsstrategie (vgl. Abschnitt 3.4.2).

Die Bewegungsplanung hat die Aufgabe, einen sicheren und vom System abfahrbaren Pfad zwischen der aktuellen und der ermittelten nächsten Messpose zu bestimmen. Da die Wahl der nächsten Messpose auf den Zellen des Belegheitsgitters beruht, bietet es sich an, diese auch für die Routenplanung zu verwenden. Die Gitterzellen sind kongruent und die Nachbarschaften eindeutig definiert. So lässt sich aus der Menge der befahrbaren Gitterzellen der für die Pfadsuche notwendige Graph ableiten. Für die Pfadsuche selbst wird der A* Algorithmus eingesetzt (vgl. Anhang A.3).

Abbildung 3.6 stellt die Routenplanung anhand eines Beispiels dar. Zu sehen ist der durch die A* Suche ermittelte Kantenzug b) zwischen der Ausgangspose a) und der Zielpose d). Die Pfadsuche erfolgt im aus den Gitterzellen abgeleiteten Graphen. Die Menge möglicher Konfigurationen ist somit diskret. Da die aktuelle Roboterpose über das Scan-Matching bestimmt wird, stimmt diese in der Regel nicht mit den Koordinaten einer der Gitterzellen überein. So muss die Pfadsuche von der Gitterzelle, die der aktuellen Position nächstgelegenen ist, erfolgen und die Wegstrecke von der aktuellen Position zur Gitterzelle in der Routenplanung berücksichtigt werden.

Pfadbereinigung (engl.: *path smoothing*)

Der Pfad des A* Algorithmus wird anschließend zur Optimierung des Weges bereinigt. Die Befahrung des A* Pfades durch das System wäre aufgrund des Bewegungsmodells mit einem hohem Aufwand bzw. einer Abfolge vieler kurzer Fahrten und unnötiger Drehbewegungen verbunden (siehe Bahnplanung). Eine einfache Methode zur Bereinigung bzw. Optimierung des Pfades ist durch einen sogenannten Sichtbarkeitstest gegeben. Bei diesem wird zwischen den Knoten des Pfades nach möglichst langen Sichtverbindungen gesucht, also direkten Verbindungen zwischen zwei Knotenpunkten, die ausschließlich als *befahrbar* klassifizierte Gitterzellen überstreichen. Im Beispiel von Abbildung 3.6 besteht der bereinigte Pfad zur finalen Pose d) aus zwei Vektoren.

Bahnplanung

Zur Bahnplanung ist ein einfaches Bewegungsmodell hinterlegt, welches es dem System ermöglicht geradeaus zu fahren oder sich auf der Stelle bzw. um den Achsmittelpunkt der motorisierten Räder zu drehen. Diese Restriktionen müssen in der Bahnplanung beachtet werden. Der Pfad zur gewünschten Zielkonfiguration ergibt sich durch eine Aneinanderreihung von Vektoren.

Während der Bewegung des Systems werden in diskreten Zeitschritten die Encoderwerte ET der Schrittmotoren abgefragt und aufgezeichnet. Beim Abfahren eines Pfades erfolgt nach dem Beenden jedes Bewegungselementes⁷ anhand der Encoderwerte eine Posebestimmung nach dem Prinzip der Koppelnavigation (Herleitung siehe Anhang A.1). Im Vorfeld ist eine manuelle Vermessung des Roboters zur Ableitung des Radabstands D_{Rad} und der Radumfänge $U_{l/r}$ notwendig. Zusätzlich müssen die für eine Radumdrehung benötigten Encoderwerte $ETU_{l/r}$ anhand von Referenzfahrten ermittelt

⁷Drehung oder Geradeausfahrt

werden. Wie in Kapitel 4.3 erläutert, wurde die Genauigkeit der odometriebasierten Lokalisierung anhand von weiteren Versuchen optimiert.

Da nach dem Abfahren jedes Bewegungselementes die ermittelte Pose in der Regel von der geplanten Pose abweicht, werden alle folgenden Bewegungselemente so angepasst, dass das System auf den geplanten Pfad zurückkehren kann. Die Ausrichtung des Systems am Ende des Pfades im Sinne eines Richtungswinkels⁸ wird durch die Explorationsstrategie vorgegeben. Diese ist abhängig von der zu schließenden Datenlücke, die die kürzeste Entfernung zur neuen Position des Systems aufweist.

3.4 Explorationsstrategie

Dieser Abschnitt stellt eine Strategie vor, die es einem robotischen System, wie es hier verwendet wird, ermöglichen soll, eine Innenraumszene anhand der durch den Laserscanner aufgezeichneten Daten zu explorieren und daraus ein weitestgehend vollständiges Abbild der Umgebung in Form einer 2D-Punktwolke zu erzeugen. Die Punktwolke soll dabei in allen Bereichen eine vorgegebene Datendichte D_{gap} aufweisen.

3.4.1 Repräsentation der Umgebung

Generell wird davon ausgegangen, dass die zu erfassende Umgebung statisch ist, also keinen temporären Änderungen unterliegt. Da das System für die Vermessung von Innenräumen konzipiert ist, kann zudem die Annahme getroffen werden, dass sich die Oberflächen der Messumgebung als kontinuierliche und in sich geschlossene Liniensegmente L_i beschreiben lassen (Abbildung 3.7a). Mit dieser Annahme kann der Zeitpunkt, an dem die Exploration einer Szene vollendet ist, eindeutig festgelegt werden. Das ist der Fall, wenn alle Liniensegmente vollständig erfasst worden sind. Dieser Zustand ist nicht erfüllt, solange dem System fragmenthafte Liniensegmente l_i vorliegen, zwischen denen sich noch nicht erfasst Umgebungsoberflächen befinden.

Liniensegmente l_i definieren sich als Abfolgen von Messpunkten, zwischen denen ein definierter Abstand d_{max} nicht überschritten wird (Abbildung 3.7b). Auf der anderen Seite enden diese Segmente an den Punkten, für die kein weiterer Punkt innerhalb eines Abstands d_{max} gefunden werden kann. Diese Punkte werden als Datenlücken $g(l_i)$ bezeichnet.

Dem Messsystem obliegt die Aufgabe, die Datenlücken $g(l_i)$ bzw. die Bereiche $U(l_i, l_j)$ zwischen den Datenlücken $g(l_i)$ durch zusätzliche Messungen aus sich dafür eignenden Posen zu füllen und die Punktwolke zu vervollständigen. Die zweckmäßige Posewahl ist Aufgabe der Explorationsstrategie.

3.4.2 Globale Bewegungsplanung

Die generellen Anforderungen an eine Explorationsstrategie wurden bereits in Kapitel 2.3.2 definiert. Daraus lassen sich für den hier genutzten Systemaufbau die in Tabelle 3.1 aufgelisteten Anforderungen ableiten. Enthalten ist eine Begründung der geforderten Punkte. Zudem werden Lösungsansätze erörtert, wie sich die Anforderungen erfüllen lassen.

Auf dieser Grundlage wurde eine Explorationsstrategie erstellt, die über eine Kostenfunktion aus einer Menge möglicher Messpositionen die Bestmögliche wählt. Die Anforderungspunkte 1 bis 4 der Tabelle geben der Explorationsstrategie allgemeine Regeln vor, die die Auslegung der Score-Funktion beeinflussen. Die Punkte 5 bis 7 beziehen sich nicht auf die Strategie selbst, sondern schränken die Zahl der

⁸Der Richtungswinkel bezeichnet den rechtsläufig angegebenen Winkel zwischen einer gerichteten Geraden und der y-Achse des Koordinatensystems, in der die Gerade dargestellt wird

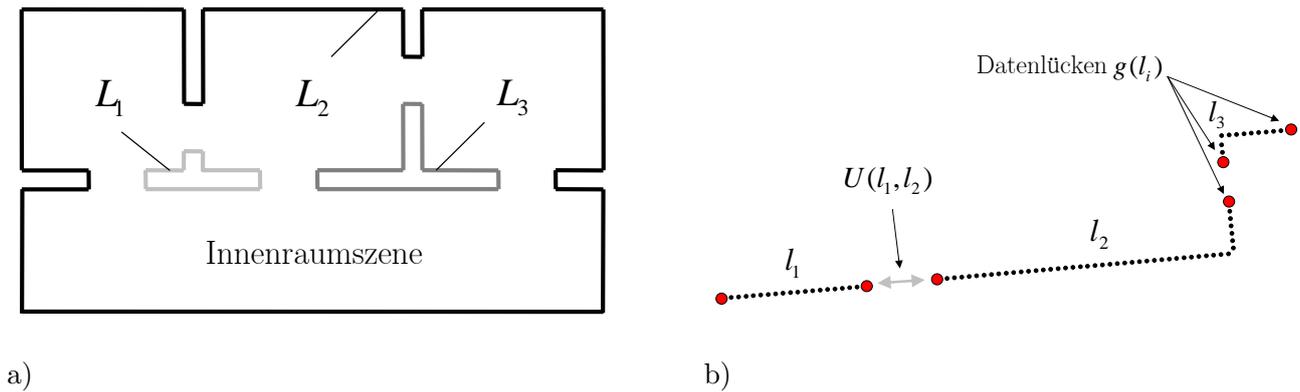


Abb. 3.7: Repräsentation der Umgebung für das System

a) Kontinuierliche und in sich geschlossene Liniensegmente L_i

b) Im Verlauf der Messprozedur gemessene Fragmente von Liniensegmenten l_i

möglichen Positionskandidaten ein.

Nr.	Anforderung	Begründung (Auswirkung auf ...)	Lösungsansatz
1	Messposen sollen so gewählt werden, dass möglichst viele Datenlücken erfassbar sind.	Messsystem soll möglichst wenige Messungen zur Einmessung des gesamten Innenraumes benötigen. <i>Effizienz</i>	Wahl der dazu optimalen Messpose durch eine Score-Map.
2	Datenlücken sollen aus möglichst explorativem Öffnungswinkel erfasst werden.	Verdeckte Raumecken können vom System nur exploriert werden, wenn sich das System jenseits des Normalenvektors einer Wand positioniert. Ansonsten besteht die Möglichkeit, dass das System diese Raumbereiche nicht exploriert. <i>Explorativität</i>	Definition von Sichtbarkeitsbereichen bezüglich der Nachbarknoten der Datenlücke. Berücksichtigung in Score-Map (Abbildung 3.10).
3	Datenlücken sollen möglichst durch Messungen aus nächster Nähe eliminiert werden.	Signal-Rausch Verhältnis und damit Sensormessgenauigkeit nehmen mit steigender Distanz ab. <i>Genauigkeit</i>	Bevorzugung von Messposen mit geringer Entfernung zu den Datenlücken im Aufbau der Score-Map.
4	Messposen, die nahe an der aktuellen Pose liegen, sollten bevorzugt werden. Messposen, die zu weit voneinander entfernt sind sollen vermieden werden.	Vermeidung von unnötig langen Fahrwegen. Wahrscheinlichkeit, dass Scan-Matching fehlschlägt, steigt mit zunehmender Distanz zwischen den Messpositionen. Lange Fahrten erhöhen Ungenauigkeit der odometriebasierten Posebestimmung. Abweichungen von Solltrajektorie führen zu Kollisionen des Systems mit Umgebung. <i>Robustheit, Sicherheit, Effizienz</i>	Berücksichtigung durch D_{cp} in Score-Map. Einführung maximal zulässiger Entfernungen bzw. Fahrten. Einführung von Zwischenmessungen bei längeren Fahrten (vgl. Kapitel 4.3).
5	Wiederholte Messungen von denselben oder sehr nahe beieinander liegenden Positionen sollten vermieden werden.	Vermeidung von Messungen ohne Informationsgewinn. Datenlücken, die aus nicht erfassbaren Oberflächen resultieren oder rein geometrisch nicht erfassbare Bereiche, lassen sich nicht einmessen, so dass eine erneute Messung unnötig ist. <i>Explorativität, Effizienz</i>	Eine neue Messpose muss eine Mindestentfernung MD_{min} zu allen bisherigen Messposen aufweisen.
6	Nicht vermessbare Raumbereiche sollen erkannt und gemieden werden.	Siehe Anforderung 4. <i>Effizienz</i>	Datenlücken erhalten Counter. Nach max. Anzahl an Einmessversuchen EMV_{max} wird Bereich als nicht einmessbar klassifiziert.
7	Die Definition unnötig vieler Datenlücken soll vermieden werden.	Siehe Anforderung 4. Fein detaillierte Oberflächen wie z.B. Pflanzen würden perspektivabhängig zu immer neuen und nahe beieinander liegenden Datenlücken führen. <i>Effizienz</i>	Neue Datenlücken dürfen nur im Mindestabstand DL_{min} zu alten Datenlücken entstehen.

Tab. 3.1: Anforderungen an die Explorationsstrategie

Score-Map

Wie in Tabelle 3.1 erläutert, soll das System versuchen, mit jeder neuen Messpose möglichst viele der vorhandenen Datenlücken zu eliminieren. Mögliche Messpositionen $p_{m,n}$ ergeben sich aus der Menge erreichbarer Gitterzellen $p \in C_{err}$ mit $C_{err} = \{p_{m,n} \mid c_{m,n} \hat{=} \text{erreichbar}\}$ bzw. deren Zellmittelpunkte $C_{err}(x, y)$. Nur direkt erreichbare Zellmittelpunkte aus C_{bef} kommen in Frage, was sich über eine *Region-Growing* Suche (vgl. [88]) ausgehend vom aktuellen Systemstandort prüfen läßt.

Grundlage zur Wahl der nächsten Messposition bildet eine Kostenkarte (*Score-Map*), durch die jeder möglichen Messposition $p_{m,n}$ ein Wert S_p zugewiesen wird, der die Eignung des Punktes als mögliche nächste Messposition ausdrückt. S_p ergibt sich über folgende Kostenfunktion:

$$S_p = f_1 \cdot k \cdot \frac{1}{D_{cp}^2} + f_2 \cdot \sum_{i=1}^k \frac{1}{D_{pg}^i} + f_3 \cdot \sum_{i=1}^k D_{gg}^i \quad (3.1)$$

wobei k der Anzahl der von $p_{m,n}$ sichtbaren Datenlücken entspricht. Als nächste Messposition wird der Positionskandidat mit maximalem S_p gewählt (Abbildung 3.8).

Erläuterung der Parameter:

D_{cp} : Entfernung zum Positionskandidaten

Um unnötig lange Fahrten zwischen den einzelnen Messungen zu vermeiden, geht der Kehrwert der euklidischen Distanz D_{cp} zwischen der momentanen Position der Plattform x_{cur} und dem jeweiligen Positionskandidaten $x_{pos} = p_{m,n}(x, y)$ quadratisch in die Bewertung ein.

D_{pg} : Entfernung zur Datenlücke

Der Wert D_{pg}^i beschreibt den Abstand zwischen der momentanen Position der Plattform x_{cur} und einer von dort aus sichtbaren bzw. einmessbaren Datenlücke g_i . Da sich das Signal-Rausch Verhältnis mit zunehmender Distanz verringert, werden kurze Distanzen bevorzugt (vgl. Abschnitt 3.1). Die Definition der Sichtbarkeit von Datenlücken folgt im gleichnamigen Abschnitt (vgl. Abbildung 3.10).

D_{gg} : Abstand von Datenlücken

D_{gg} beschreibt den Abstand $|g_m(l_i) - g_n(l_j)|$ zwischen den Datenlücken untereinander. Gemäß der Umgebungsrepräsentation nach Abschnitt 3.4.1 ergibt sich immer eine gerade Gesamtanzahl der g_i . Somit lassen sich jeweils zwei Datenlücken, wie im folgenden Abschnitt „Annahme der Zuordnung“ erläutert, zuordnen. D_{gg} ist also ein Maß für die Größe eines noch nicht explorierten Umgebungsbereichs und gibt Auskunft über die Relevanz einer Datenlücke im Hinblick auf die Exploration einer Szene.

Faktorisierung f_1 - f_3

Die Teilterme aus Gleichung (3.1) werden durch die Faktoren f_1 - f_3 individuell gewichtet, um deren Einfluss auf die Wahl der Messposition zu regulieren. Zur Optimierung der Faktoren wurden anhand einer virtuellen Testumgebung mehrere Explorationsreihen unter Variation der Faktorisierung durchgeführt, um diese zu optimieren (siehe Kapitel 4.1). Darauf basierend wurden folgende Faktoren gewählt:

$$f_1 = 1.3 \quad f_2 = 1 \quad f_3 = 0.6 \quad (3.2)$$

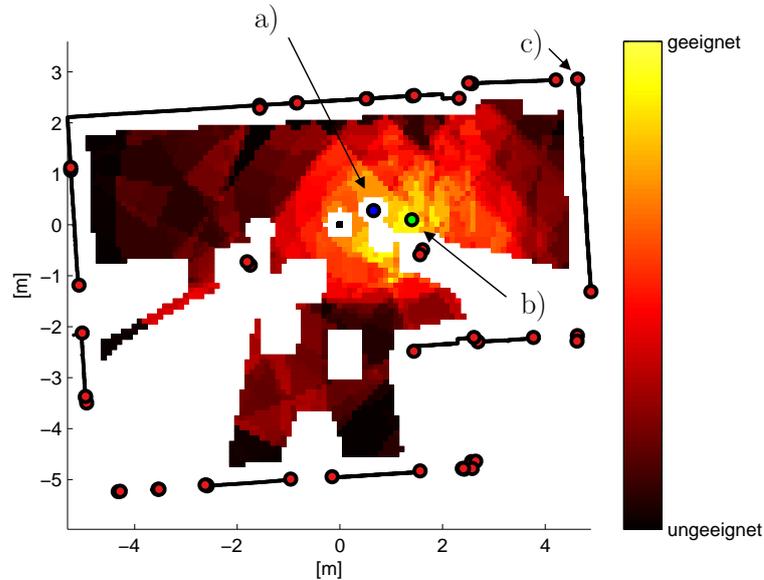


Abb. 3.8: Score-Map mit Vorschlag der nächsten Messpose basierend auf dem Belegtheitsgitter

a) Momentane Position des Roboters $C_{mom}(x, y)$

b) Gitterzelle $C_{err}(x, y)$ mit maximalem S_p

c) Datenlücke

Sichtbarkeit von Datenlücken

Die Definition der Sichtbarkeit⁹ von Datenlücken ist wesentlich für die vorliegende Messstrategie. Jeweils abzuleiten ist der *Sichtbarkeitsbereich* einer Datenlücke. Das ist die Menge der Gitterzellen bzw. der Zellmittelpunkte, von denen aus eine Datenlücke sichtbar ist. Mit dieser Information lassen sich umgekehrt alle von einem Zellmittelpunkt sichtbaren Datenlücken bestimmen.

Um die Sichtbarkeitsbereiche abzuleiten, muss zunächst festgestellt werden, von welchen Orten direkte Sichtverbindungen zu den Datenlücken bestehen. Dies geschieht, indem die Umgebung jeder Datenlücke in radial auseinanderlaufende Zonen Z unterteilt wird (Abbildung 3.9). Die Ausdehnung der Zonen ist begrenzt durch den nächstgelegenen Datenpunkt innerhalb einer Zone oder durch die maximale Messdistanz des Sensors, falls kein Datenpunkt innerhalb dieser Distanz auftritt. Alle Zonen weisen denselben Öffnungswinkel V_z auf.

Diese *generelle Sichtbarkeit* einer Datenlücke wird zu Gunsten der Explorationsstrategie weiter eingeschränkt. Es wird versucht den Normalenvektor \vec{N} der Umgebungsfläche, auf der eine Datenlücke liegt, zu rekonstruieren. Dafür wird über die nächstgelegenen Datenpunkte des Liniensegments, dessen Ende die Datenlücke bildet, die lokale Segmentrichtung abgeleitet. Wie in Abbildung 3.10 zu sehen, erfolgt die Definition des *explorativen Sichtbarkeitsbereichs* in Abhängigkeit von der Position der entsprechenden Datenlücke, sowie der lokalen Segmentrichtung. Um zu vermeiden, dass das System versucht Objekte von der Rückseite zu erfassen, ist die Ausrichtung von \vec{N} abhängig von der Richtung aus der die Messpunkte des Liniensegments l_i erfasst wurden¹⁰.

Die Intensität des reflektierten Messsignals verringert sich mit zunehmender Abflachung des Messwinkels gegenüber der Oberflächennormalen. Zur Einmessung von Datenlücken wurde darum mit α_2 eine maximal zulässige Winkelabweichung gegenüber der Oberflächennormalen eingeführt. Bei der Wahl der Messpositionen ist ein exploratives Verhalten des Messsystems zu gewährleisten. Daher wird der Sichtbarkeitsbereich bezüglich des aktuellen Plattformstandortes jenseits von \vec{N} mit einer minimalen

⁹sichtbar durch den Sensor und damit einmessbar

¹⁰vergleichbar mit Abbildung 5.8

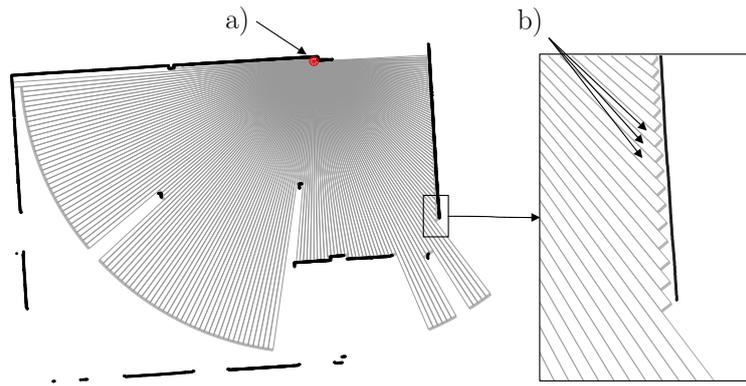


Abb. 3.9: Festlegung der Sichtbarkeit von Datenlücken durch radial von der Datenlücke fortführende Sichtbarkeitszonen mit einer Ausbreitung entsprechend des Sensormessbereichs oder beschränkt durch den nächstgelegenen Datenpunkt

a) Datenlücke

b) Radiale Sichtbarkeitszonen Z

Winkeldifferenz von α_1 aufgespannt.

Die konservative Datenfilterung (vgl. Abschnitt 3.1) führt dazu, dass auch Punkte, die eigentlich sichtbar sind und korrekt gemessen wurden, aus den Daten herausgefiltert werden. Um den Einfluss dieses Effekts auf die Explorationsstrategie zu minimieren, wurde die maximale Distanz zur Einmessung von Datenlücken mit dem Parameter d_2 begrenzt.

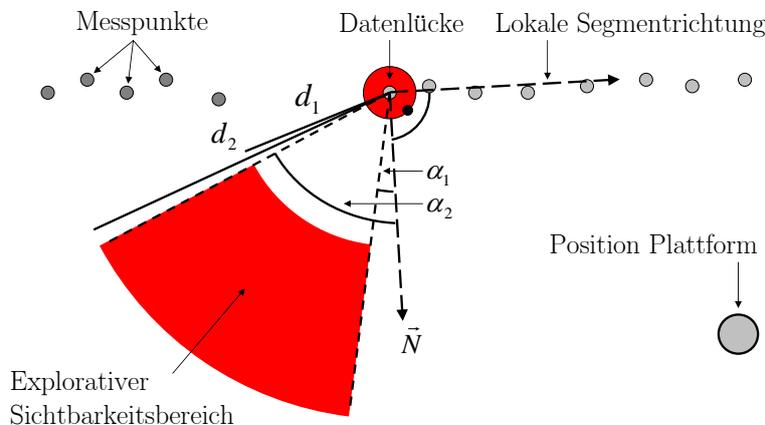


Abb. 3.10: Definition des explorativen Sichtbarkeitsbereichs, von dem aus eine Datenlücke eingemessen werden kann. Abhängig von der Position der Datenlücke, sowie der lokalen Segmentrichtung, ergibt sich der Sichtbarkeitsbereich über das Entfernungsintervall $[d_1; d_2]$ sowie das Winkelintervall $[\alpha_1; \alpha_2]$.

Annahme der Zuordnung

Eine korrekte Zuordnung von Datenlücken $U(g_m(l_i) \leftrightarrow g_n(l_j))$ wäre eine wertvolle Kenntnis im Hinblick auf die Explorationsstrategie, weil damit auch eine Information über die unbekannteren Raumbereiche, die die Lücken begrenzen, gegeben wäre. Die vorzugsweise Exploration großer unbekannter Bereiche ergäbe eine einfache und effiziente Explorationsstrategie. Messpositionen mittig zwischen den zugeordneten Lücken wären leicht ableitbar und effektiv (vgl. Surmann [101]). Es sollte daher versucht werden diese Information in die Explorationsstrategie einfließen zu lassen.

Die korrekte Zuordnung von Datenlücken stellt jedoch eine nicht triviale Aufgabe dar (vgl. Kapitel

2.3.2). Während Punktnachbarschaften innerhalb einer Messung bekannt sind, geht diese Information durch die Datenverwaltung verloren (vgl. Abschnitt 3.4.3). Es ist kein Verfahren bekannt, welches eine zuverlässige Rekonstruktion der Lückenzugehörigkeiten ermöglicht. Bekannte Ansätze beschränken sich auf die Darstellung der Umgebung auf ein einziges geschlossenes Liniensegment. Um weder einer solchen Einschränkung zu unterliegen, noch eine verbindliche und eventuell falsche Zuordnungsaussage treffen zu müssen, wird für die Strategiebewertung nur eine Vermutung möglicher Zuordnungen aufgestellt. Die geometrische Verbindung zweier Datenlücken soll nicht direkt die Wahl einer entsprechenden Einmesspose vorgeben, sondern nur die „Attraktivität“ der Lücken regeln.

Ein Versuch die Datenlücken zuzuordnen erfolgt über die *Ungarische Methode* (siehe Anhang A.7). Für deren Anwendung muss eine Kostenmatrix $KM_{n \times n}$ gefüllt werden, die einen bipartiten Graphen darstellt. Die Einträge $km_{i,j}$ in KM entsprechen den Kantengewichten des Graphen. In Bezug auf die Lückenzuordnung sind dies die euklidischen Abstände der Lückenpunkte zueinander. Die Abstände der so zugeordneten Lückenpaare gehen über D_{gg} in Gleichung 3.1 ein.

$$km_{i,j} = \begin{cases} |g_i - g_j|, & \text{if } l(g_i) \neq l(g_j), \\ \infty & \text{else.} \end{cases} \quad (3.3)$$

Die Zuordnung der beiden Enden desselben Liniensegments l_n soll dabei vermieden werden. Diese Annahme ist gültig, solange keine nahezu vollständig erfassten Segmente L_i vorliegen, die geschlossen werden könnten. Ist dies der Fall, erhöht sich die Wahrscheinlichkeit von Fehlzusordnungen wie im Beispiel der Abbildung 3.11 zu sehen.

Das Verfahren vollführt eine optimale Zurdnung im Sinne einer Minimierung der Summe aller Lückenabstände. In den praktischen Experimenten konnte ein hoher Grad ($> 90\%$) korrekter Zuordnungen festgestellt werden.

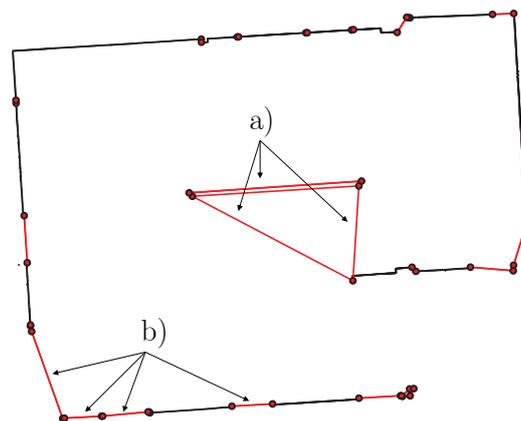


Abb. 3.11: Zuordnung von Datenlücken $U(g_m(l_i) \leftrightarrow g_n(l_j))$ unter Verwendung der Ungarischen Methode

a) Beispiel für Fehlzusordnungen

b) Beispiel für korrekte Zuordnungen

Weitere Vorkehrungen

Datenlücken, die laut Strategie sichtbar sind, aber aufgrund ihrer Oberflächenbeschaffenheit oder aus anderen Gründen nicht erfasst werden können, werden nach einer gewissen Anzahl an Einmessversuchen EMV_{max} verworfen. Somit kann verhindert werden, dass das System in eine Endlosschleife gerät und immer wieder versucht, dieselbe Datenlücke zu tilgen. Dazu wurde eine Lückenhistorie eingeführt,

die die Anzahl der Einmessversuche jeder Datenlücke mit Hilfe eines Counters verwaltet. Für EMV_{max} wurde ein Wert von 3 gewählt. Dieser stellt einen Kompromiss zwischen einer möglichst schnellen und einer möglichst lückenlosen Einmessung der Szene dar. Um möglichst wenige Datenlücken zu unrecht zu verwerfen, wurde zudem die Bedingung eingeführt, den letzten Einmessversuch aus einer geringeren Distanz, also einem geringeren Wert d_2 durchzuführen. Der Einsatz von Countern muss in der Datenverwaltung berücksichtigt werden (vgl. Abschnitt 3.4.3). Bestehende Datenlücken können durch Messungen aus kürzeren Distanzen verworfen und durch neue Daten ersetzt werden. Um ein Zurücksetzen des Counters zu verhindern, werden die bestehenden Counterwerte an neu auftretende Lücken vererbt, falls sich diese in nächster Nähe befinden. Haben zwei Datenlücken einen geringen Abstand zueinander, werden diese wie eine einzelne Lücke gewertet. So soll vermieden werden, dass in kurzen geometrischen Abständen immer wieder neue Lücken entstehen und das System dadurch ineffektiv wird.

Eine zusätzliche Restriktion gibt vor, dass das System nur Messpositionen anfahren darf, die einen Mindestabstand MD_{min} von allen bisher verwendeten Messpositionen aufweisen. Auch dadurch soll eine effektivere Vorgehensweise erzielt und unnötig lange Zyklen vermieden werden.

Passiert das Messsystem eine Tür und wechselt damit den Raum, ändert sich die Umgebung abrupt, so dass bereits nach kurzer Strecke nur noch eine geringe Überlappung zur bekannten Umgebung vorhanden ist. Da Matching-Verfahren eine gewisse Überlappung der Daten voraussetzen, stellen diese Übergänge eine besondere Herausforderung dar und müssen in der Exploration entsprechend berücksichtigt werden. Um Übergänge oder Portale erkennen zu können, werden der Pfad zur nächsten Pose als auch die im Umgebungsmodell enthaltenen Geradensegmente (siehe Anhang A.2) betrachtet. Passiert der Pfad zwei beidseitig des Pfades gelegene Geradensegmentenden, die ähnlich bzw. gleich gerichtet sind und einen definierten Abstand DP_1 unterschreiten, wird diese Stelle als Portal eingestuft (Abbildung 3.12). Ist dies der Fall, wird die Bewegung im Abstand DP_2 vor diesem Kreuzungspunkt abgebrochen, um eine zusätzliche Sensormessung durchzuführen. So kann bereits ein Teil der Umgebung jenseits des Portals erfasst werden, während das System noch genügend bekannte Umgebungsinformation erhält. Wie in Kapitel 4.7 erläutert, konnte diese Methodik erfolgreich in der Praxis angewandt werden.

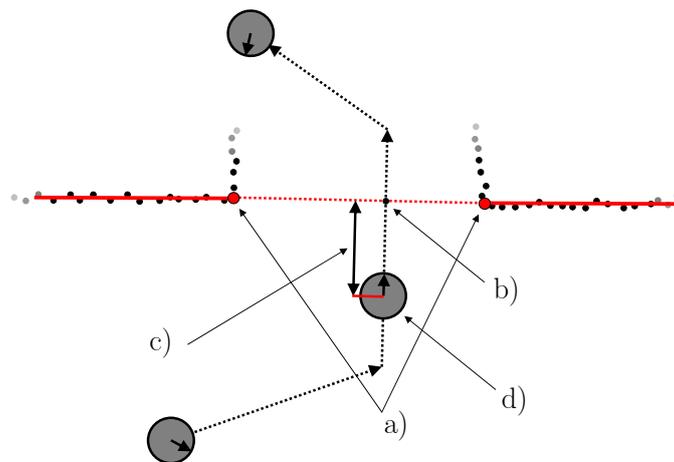


Abb. 3.12: Erkennung von Portalen für eine robuste Exploration neuer Räume

- a) Geradensegmentenden
- b) Kreuzungspunkt zwischen Segmentenden und geplantem Pfad
- c) Definierter Abstand DP_2 zum Kreuzungspunkt mit dem Portal
- d) Eingeführte Zwischenmessung

3.4.3 Verwaltung von Messdaten

Die Abtastdichte¹¹ D_{gap} , mit der die Umgebung erfasst werden soll, kann vom Systemnutzer vor Beginn des Messvorgangs angegeben werden (vgl. Abschnitt 3.4.1). In einer gesonderten Datenverwaltung wird überprüft, welche Messpunkte für die Einhaltung der Abtastdichte notwendig sind. Alle weiteren Punkte werden eliminiert. Die Wahl von beizubehaltenden Messpunkten erfolgt, indem die Entfernungen zur Messposition (kurz: EZM), aus der die einzelnen Punkte aufgezeichnet wurden, verglichen werden. Dieser Ansatz legitimiert sich aus mehreren Gründen. Über eine EZM abhängige Dateneliminierung kann zum Einen gewährleistet werden, dass bevorzugt Messpunkte verwendet werden, die eine vergleichsweise höhere Lagegenauigkeit versprechen. Wie in Kapitel 3.1 erläutert, verringert sich die Genauigkeit der Laserdistanzmessung mit steigender Entfernung aufgrund einer Vergrößerung des Messflecks und eines geringeren SNR¹². Ein weiterer nachteiliger Effekt einer fehlenden Datenverwaltung wäre die mit der Datenmenge ansteigende Rechenzeit. Mehrere der angewandten Algorithmen greifen auf alle gespeicherten Messpunkte zu. Aufgrund des zumindest linearen Zusammenhangs zwischen der Anzahl der Messpunkte und dem benötigten Rechenaufwand, erhöhte sich die Bearbeitungszeit wesentlich.

Der Datenverwaltung voran geht eine Registrierung der neu aufgenommenen Daten anhand des Scan-Matchings (siehe Abschnitt 3.5). Dabei werden alle Datenpunkte der neuen Messung verwendet, da alle zur Verfügung stehenden Informationen zur Steigerung der Robustheit und der Genauigkeit genutzt werden sollen. Sind Alt- und Neudaten im selben Koordinatensystem registriert, kann eine EZM basierte Filterung erfolgen. Dazu werden während des Messvorgangs die EZM Werte der Punkte gemeinsam mit deren Koordinaten gespeichert.

Die einzelnen Filterungsschritte der Datenverwaltung sind in Abbildung 3.13 anhand von zwei aneinander grenzenden Messungen dargestellt. Dabei sollen die von Position P_N aus aufgezeichneten Neudaten $N_1 = \{n_1, n_2, \dots, n_i\}$ einem bereits existierenden, also alten Datensatz $A_1 = \{a_1, a_2, \dots, a_j\}$, aufgenommen von der Position P_A , hinzugefügt werden.

Schritte der Datenverwaltung entsprechend Abbildung 3.13:

- a) unbereinigte, zueinander registrierte Messungen vor der Datenverwaltung.

$$D_1 = \{N_1 \cup A_1\}$$

- b) Löschen und Zurücklegen aller Neupunkte n_i , die eine größere EZM aufweisen als deren nächstgelegene Altpunkte.

$$N_1 \rightarrow N_2 ; D_2 = \{N_2 \cup A_1\}$$

- c) Suche Liniensegmente l in den nach Schritt b) verbleibenden Daten D_2 . Ableiten von Punktnachbarschaften $d_{k-1} \leftrightarrow d_k \leftrightarrow d_{k+1}$ basierend auf l . Löschen aller Altpunkte a_j bzw. d_k , die nicht zu einer notwendigen Verdichtung der Punktwolke beitragen, für die gilt:

$$|d_k - d_{k-1}| \leq D_{gap}$$

¹¹maximaler Abstand benachbarter Messpunkte

¹²Signal-Rausch Verhältnis

$$\begin{aligned} |d_k - d_{k+1}| &\leq D_{gap} \\ |d_{k-1} - d_{k+1}| &\leq D_{gap} \end{aligned}$$

$$A_1 \rightarrow A_2 ; D_3 = \{N_2 \cup A_2\}$$

d) Löschen aller Neupunkte n_i , die nicht zu einer notwendigen Verdichtung der Punktwolke beitragen, für die gilt:

$$\begin{aligned} |n_i - n_{i-1}| &\leq D_{gap} \\ |n_i - n_{i+1}| &\leq D_{gap} \\ |n_{i-1} - n_{i+1}| &\leq D_{gap} \end{aligned}$$

$$N_2 \rightarrow N_3 ; D_4 = \{N_3 \cup A_2\}$$

e) Einfügen von Neupunkten $N_{1 \setminus 2} = \{N_1 \setminus N_2\}$, die zu einer notwendigen Verdichtung bzw. Erweiterung der bestehenden Punktwolke D_4 beitragen und in b) zunächst zurückgelegt wurden. Für diese muss gelten:

$$|n_i - d_{next}| \geq D_{gap}$$

wobei d_{next} dem nächsten Nachbar von n_i in D_4 entspricht.

$$N_3 \rightarrow N_4 ; D_{fin} = \{N_4 \cup A_2\}$$

f) Verbleibende Datenpunkte D_{fin} nach Datenverwaltung.

Die Nachbarschaften $n_{i-1} \leftrightarrow n_i \leftrightarrow n_{i+1}$ von Messpunkten innerhalb eines neu aufgezeichneten Datensatzes sind aufgrund der zeitlichen Messabfolge des Sensors bekannt. Sobald jedoch mehrere Datensätze miteinander registriert werden, geht diese Information verloren. Punktnachbarschaften $d_{k-1} \leftrightarrow d_k \leftrightarrow d_{k+1}$ müssen dann über eine gesonderte Nächste-Nachbar-Suche¹³ und die darauf folgende Bildung von Liniensegmenten rekonstruiert werden. Dieser Umstand sowie die Vorgaben, eine konstante Abtastdichte zu erreichen und dabei Messpunkte mit möglichst geringer EZM zu verwenden, bedingen die aufwendige, hier angeführte Art der Datenverwaltung.

Einen alternativen Ansatz könnte eine geometriegebundene Datenverwaltung bilden, in der eine Datenausdünnung entsprechend des geometrischen Informationsgehaltes der einzelnen Messpunkte erfolgt. Repräsentiert beispielsweise ein Teil der Punktwolke ein gerades Umgebungssegment, erbringen weitere Messungen dieses Bereiches der Umgebung keine zusätzlich geometrische Information. Somit könnte hier ohne Informationsverlust eine intensive Filterung durchgeführt werden. In fein strukturierten Umgebungsbereichen sollten dagegen möglichst alle Messpunkte erhalten bleiben. Dafür notwendig wären übergeordnete Algorithmen für eine Klassifizierung der Bereiche. Zudem müssten die ausgedünnten Bereiche im Scan-Matching Verfahren entsprechend berücksichtigt werden.

Parametrisierung

In Tabelle 3.2 findet sich eine Zusammenfassung der in der Explorationsstrategie sowie der im Folgenden erläuterten Scan-Matching Methodik benötigten Systemparameter, sowie einer typischen, in den Versuchen aus Kapitel 4 verwendeten Wertebelegung.

¹³z.B. durch einen kd-Tree [87]

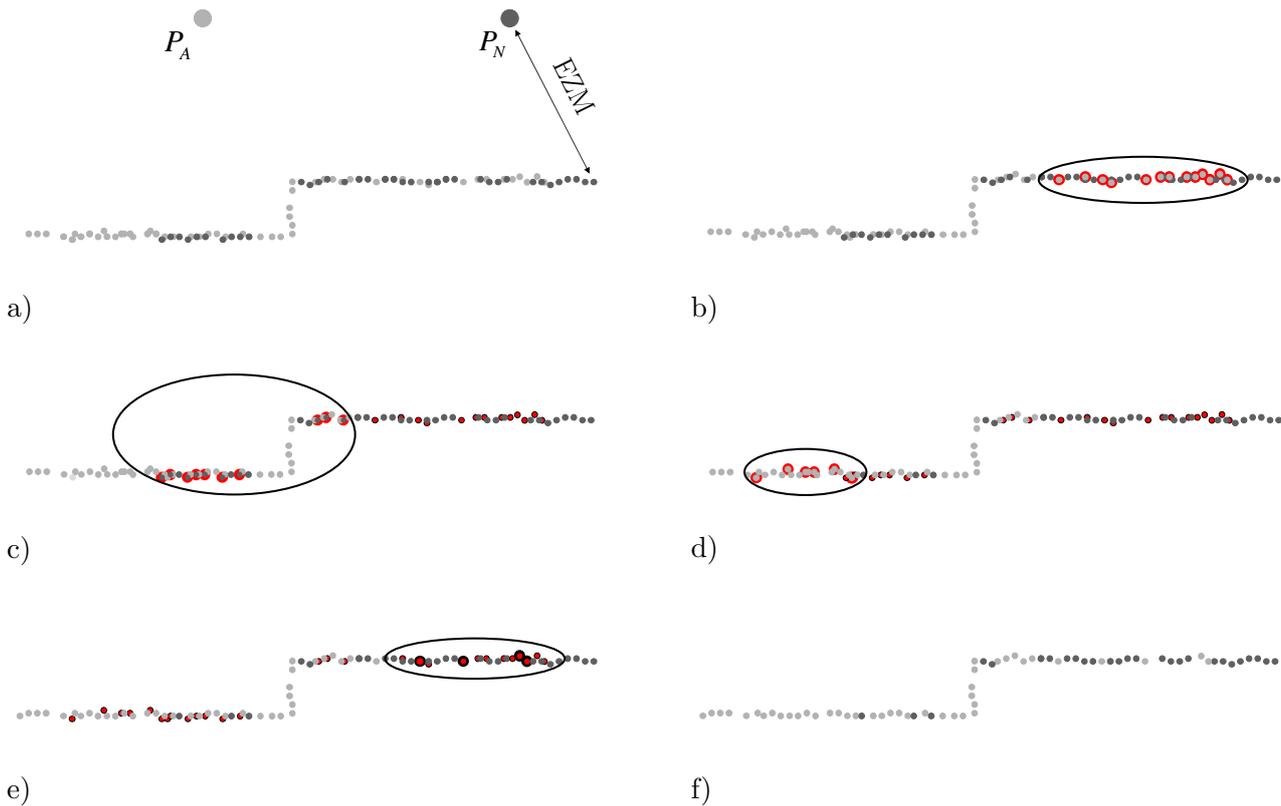


Abb. 3.13: Teilschritte der Datenverwaltung

3.5 Scan-Matching

Zur vollständigen Erfassung einer Szene ist es in der Regel notwendig, dass Messungen von unterschiedlichen Positionen ausgeführt werden müssen. Das System muss daher in der Lage sein, diese Messungen in einem gemeinsamen Modell zu registrieren. Im \mathbb{R}^2 sind dafür 2 translatorische $\Delta_{trans} = [T_x \ T_y]$ sowie ein rotatorischer Transformationsparameter $\Delta_{rot} = T_\phi$ notwendig. Das Scan-Matching ist ein Arbeitsschritt, der sich wesentlich auf die Genauigkeit des vom System erstellten Innenraummodells auswirkt. So wird der Einsatz eines präzisen Matching-Verfahrens notwendig.

Eine Auslegung hin zu einer optimierten Genauigkeit und Robustheit verlangsamt das im Folgenden vorgestellte Verfahren. Die im Stop&Go Betrieb verlaufende Messprozedur macht laufzeitstarke Algorithmen jedoch unnötig. Da der verwendete Laserscanner nur einen Phasenwert pro Umdrehung misst, können genaue Messungen nur von festen Positionen während eines Stillstands der Plattform durchgeführt werden. Dieser Umstand birgt Schwierigkeiten für die Datenregistrierung. Bei einem Positionswechsel kann es vorkommen, dass sich bei zunehmender Distanz die Inhalte neuer Messdaten wesentlich von den bis dato aufgezeichneten unterscheiden. Zudem erhöhen sich bei größer werdender Distanz die Ungenauigkeiten der odometriebasierten Lokalisierung. Die Odometrie stellt jedoch die einzige Informationsquelle für eine Vororientierung der Aufnahmen dar. Die vorliegende Applikation benötigt also ein Verfahren, welches auch unter den genannten Bedingungen eine exakte und robuste Datenregistrierung ermöglicht.

Hierbei wird ein Scan-Matching Verfahren eingesetzt, welches im Folgenden erläutert werden soll. Das

Parameter	Wert	Beschreibung
Allgemein		
D_{gap}	2 cm	Maximaler Punktabstand bzw. Datendichte
s_{grid}	0.1 m	Zellgröße des Belegtheitsgitters $c_{m,n}$
EMV_{max}	3	Maximale Anzahl an Versuchen eine Datenlücke zu schließen
MD_{min}	30 cm	Mindestentfernung einer Messpose zu allen bisher besuchten Messposen
DL_{min}	3	Mindestabstand neuer Datenlücken zu bestehenden Datenlücken
V_Z	1°	Öffnungswinkel der radialen Sichtbarkeitszonen
DP_1	1.5 m	Maximaler Abstand gleich gerichteter Geradensegmente zur Definition von Portalen
DP_2	30 cm	Abstand zum Kreuzungspunkt mit dem Portal
Explorativer Sichtbarkeitsbereich (vgl. Abschnitt 3.4)		
α_1	5°	Winkelintervall für Sichtbarkeitsbereich
α_2	60°	Winkelintervall für Sichtbarkeitsbereich
d_1	0.5 m	Distanzintervall für Sichtbarkeitsbereich
d_2	4.0 m	Distanzintervall für Sichtbarkeitsbereich
Scan-Matching (vgl. Abschnitt 3.5)		
Δ_{maxLot}	5 cm	Größe der Einzugsgebiete für die Suche der im Matching verwendeten Datenpunkte (initialer Wert)
Δ_{maxGer}	2 cm	Maximaler Lotabstand der Punkt zu ihrem Geradensegment G_i (initialer Wert)
D_{view}	10 cm	Sichtbarkeitsintervall für Datenvorverarbeitung
DV_{max}	90°	Maximale Winkeldifferenz zum Oberflächennormalenvektor im Projektionsfilter
s_{thin}	200	Punktanzahl auf die die Datensätze bei der Bestimmung von Δ_{trans} reduziert werden
ND_{max}	20 cm	Maximaler Punktabstand nächster Nachbarn für Berücksichtigung in der Gütebewertung des ENM

Tab. 3.2: Parametrisierung typischer Werte für Explorationsstrategie und Scan-Matching des 2D-RDM mobile

zweistufige Verfahren führt zunächst ein gröberes Matching¹⁴ 1. Näherung (ENM) durch, bevor in einem zweiten Schritt eine möglichst exakte Registrierung der neu gemessenen Daten anhand eines iterativen kleinste Quadrate Matchings (IKQM) erfolgt. Klassische Innenraumumgebungen weisen viele gerade Elemente auf. Diesen Umstand versucht das Verfahren hinsichtlich der erreichbaren Registrierungsgenauigkeit vorteilhaft in den Matching-Prozess mit einzubeziehen.

Dem Scan-Matching vorangestellt ist eine Datenvorverarbeitung, die eine Vorauswahl der im Matching verwendeten Messpunkte trifft. Es wird versucht die Punkte der bestehenden Daten zu extrahieren, die mit den Neudaten korrespondieren. Dies soll dazu dienen den Berechnungsaufwand zu reduzieren und die Robustheit der Registrierung im Rahmen des Scan-Matchings zu erhöhen. Anhand der Odometriedaten läßt sich die Pose des Systems, die es nach Abfahrt des Pfades zur nächsten Messpose tatsächlich eingenommen hat, im Rahmen der durch die Koppelnavigation gegebenen Genauigkeit bestimmen. Basierend auf dieser Lokalisierungsinformation kann anhand eines Projektionsfilters (vgl. Anhang A.8) überprüft werden, welche bereits erfassten Umgebungsbereiche in der folgenden Messung abgebildet sein werden.

Die nachfolgende Datenverwaltung wurde bereits in Abschnitt 3.4.3 vorgestellt. Eine Gesamtübersicht über den Prozess der Datenerweiterung ist in Abbildung 3.14 gegeben.

3.5.1 Matching 1. Näherung (ENM)

Neu aufgezeichnete Messdaten lassen sich anhand der aus den Odometriedaten resultierenden Transformationsparameter $\Delta_{rot\ 1}$ und $\Delta_{trans\ 1}$ bereits vor dem Scan-Matching grob zueinander ausrichten.

¹⁴bzw. Grobregistrierung

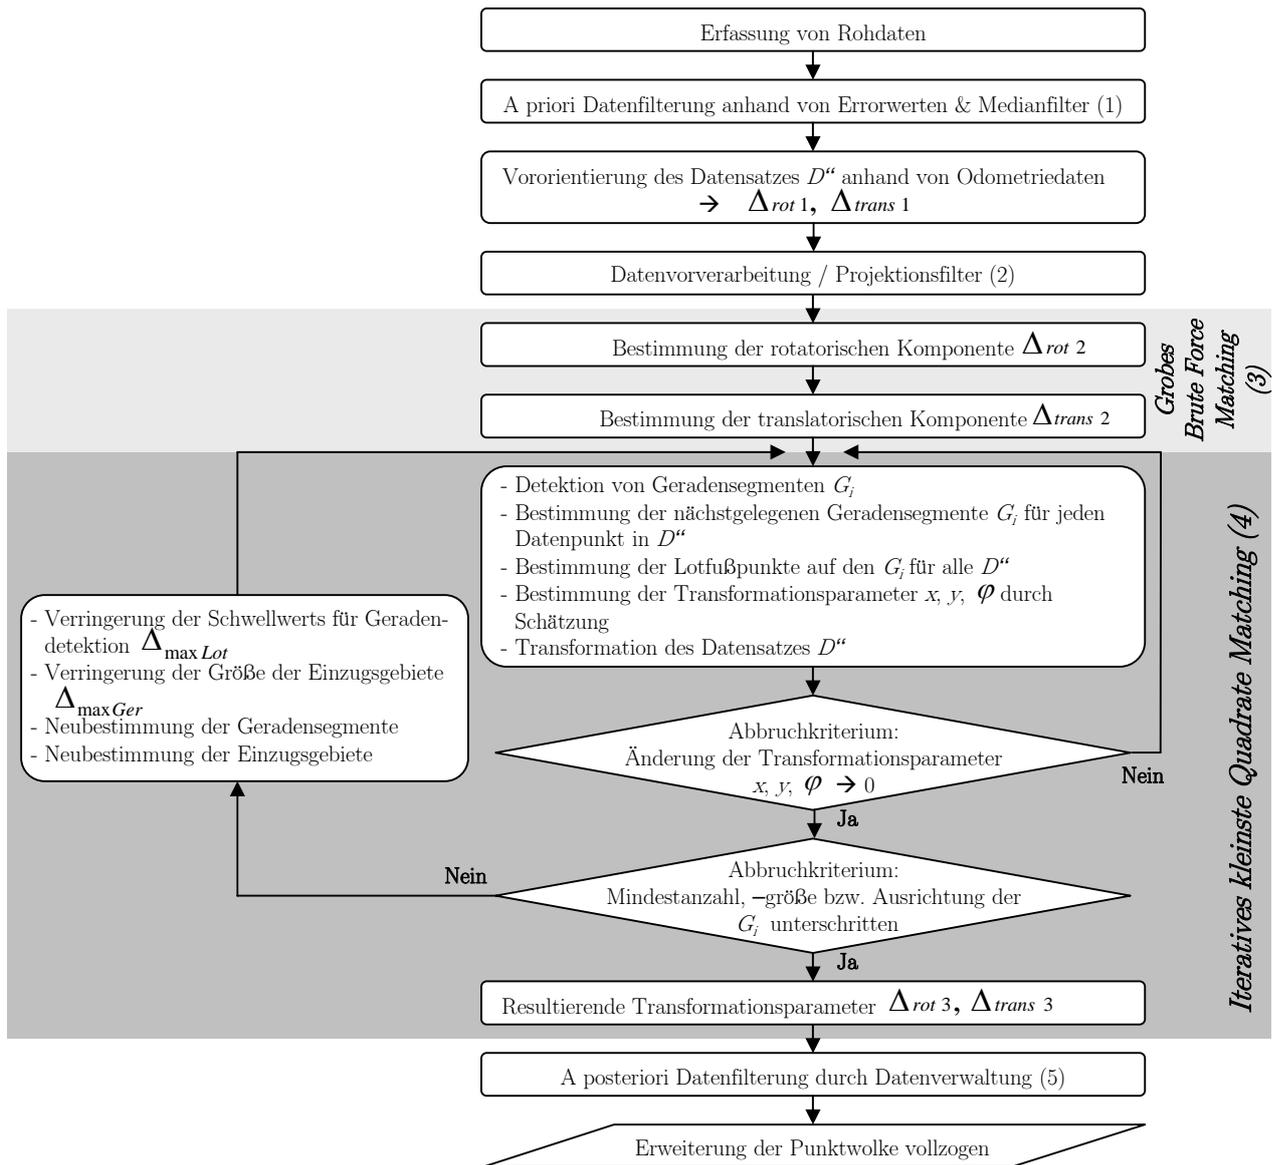


Abb. 3.14: Ablaufdiagramm: Erweiterung der Punktwolke durch eine weitere Sensormessung.

- (1) vgl. Abschnitt 3.1
 (2) vgl. Anhang A.8
 (3) vgl. Abschnitt 3.5.1
 (4) vgl. Abschnitt 3.5.2
 (5) vgl. Abschnitt 3.4.3

Davon ausgehend, soll die Überlagerung der Datensätze in einem ersten Matching Schritt weiter verbessert werden. Dieser Schritt ist notwendig, da sich die Robustheit des IKQM erhöht, wenn diesem bereits präzise orientierte Datensätze übergeben werden (siehe Abschnitt 3.5.2). Die verwendete Methode ermittelt in zwei Teilschritten separat die rotatorischen und die translatorischen Orientierungsdifferenzen zwischen den Datensätzen.

Rotatorische Komponente $\Delta_{rot\ 2}$

Die Methodik zur Bestimmung von $\Delta_{rot\ 2}$ stützt sich auf Annahmen hinsichtlich der vorliegenden Innenraumgeometrien, ähnlich der „Manhattan-World“ Annahme [18]. Rechte Winkel zwischen den geraden Elementen sind im Gegensatz zur Manhattan-World nicht notwendig, aber förderlich.

Gegeben sei ein Datensatz D'' , der im Koordinatensystem eines bereits vorhandenen Datensatzes D' registriert werden soll (Abbildung 3.15). Zunächst wird D' mit Hilfe der Datenvorverarbeitung auf die für das Matching relevanten Dateninhalte reduziert. Die Datensätze werden nach vorhandenen Geradensegmenten G'_i und G''_j durchsucht und deren Richtungswinkel R'_i und R''_j bestimmt. Es werden die Richtungswinkeldifferenzen dR_{ij} zwischen allen R'_i und R''_j gebildet. Der Orientierungsfehler $\Delta_{rot\ 2}$ läßt sich schließlich aus dR_{ij} ableiten.

Die Ähnlichkeit von D' und D'' führt auch dazu, dass in G'_i und G''_j korrespondierende Segmente enthalten sind, die alle dieselbe Richtungswinkeldifferenz aufweisen. Diese entspricht gleichzeitig dem gesuchten $\Delta_{rot\ 2}$. Diese Werte treten in der Menge aller dR_{ij} vergleichsweise häufig auf. Somit vereinfacht sich die Bestimmung von $\Delta_{rot\ 2}$ zu einer Suche des Maximums in der Häufigkeitsverteilung $H(dR)$ von dR_{ij} .

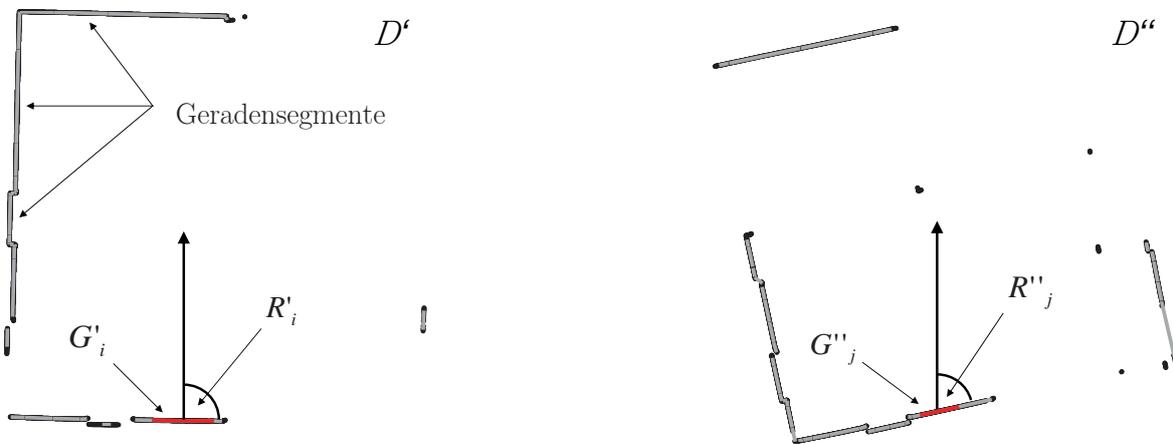


Abb. 3.15: Orientierung zweier Datensätze D' und D'' anhand von Richtungswinkeldifferenzen

Unter bestimmten Umständen kann es dazu kommen, dass das gesuchte Maximum nicht dem absoluten Maximum von $H(dR)$ entspricht. Das ist der Fall, wenn die Umgebungsoberflächen erhebliche Symmetrien aufweisen. Die enthaltenen Geradensegmente bzw. deren Richtungen sind dann nicht mehr zufällig verteilt. Gerade künstlich geschaffene Umgebungen zeichnen sich durch das Auftreten vieler, gleich gerichteter oder orthogonaler Flächen aus. Dieser Sachverhalt wirkt sich mehrdeutig auf $H(dR)$ aus. So führen auf der einen Seite nicht nur korrespondierende Geradensegmente, die dem gesuchten $\Delta_{rot\ 2}$ entsprechen, zu dR_{ij} , sondern auch Geradensegmente, die auf gleichgerichteten Wänden liegen. Auf der anderen Seite werden jedoch auch vermehrt durch orthogonal zueinander oder parallel gegenüberliegender Geradensegmente Differenzen gebildet. Durch diese entstehen in $H(dR)$ weitere Maxima, die zum gesuchten $\Delta_{rot\ 2}$ um 90° , 180° und 270° versetzt sind. Diese Konzentration der dR_{ij} auf vier Maxima bildet zwar eine globale Mehrdeutigkeit, führt aber bei einer Einschränkung des Suchraumes auf ein maximal zulässiges Intervall von $\pm 45^\circ$ zu eindeutigen Ergebnissen. In Abbildung 3.16 ist die Häufigkeitsverteilung von dR_{ij} am Beispiel von D' und D'' dargestellt. Bei 55 detektierten G'_i und 33 G''_j wurden 1848 dR_{ij} ermittelt. Es zeigen sich vier, um jeweils 90° zueinander versetzte, lokale Maxima. Mit der Einschränkung des Suchraumes verbleibt nur eines der Maxima. Für das gesuchte $\Delta_{rot\ 2}$ läßt sich hier bei einer Diskretisierung in 1° Schritten ein Wert von 18° ableiten.

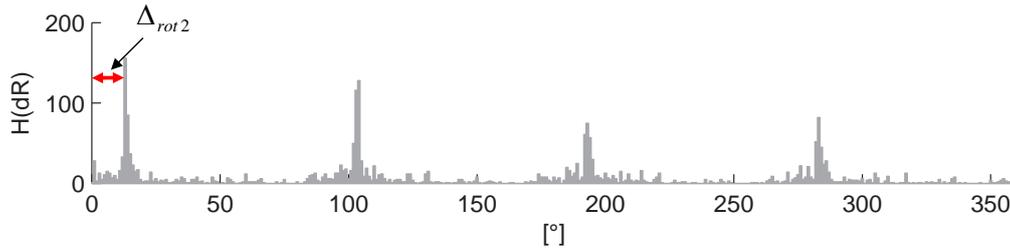


Abb. 3.16: Häufigkeitsverteilung der Richtungswinkeldifferenzen dR_{ij}

Translatorische Komponente $\Delta_{trans\ 2}$

Für die Bestimmung von $\Delta_{trans\ 2}$ kommt eine *brute-force* Strategie zum Einsatz, in der die nun korrekt orientierten Datensätze versuchsweise verschoben und die dabei resultierenden Überlagerungen evaluiert werden. Das verwendete Verfahren orientiert sich an der Arbeit von Winkelbach [112], in der eine effiziente Möglichkeit zur Überlagerung von 3D-Fragmenten vorgestellt wird. Da jedoch ausschließlich eine Translation im \mathbb{R}^2 gesucht wird, verringert sich der kombinatorische Aufwand deutlich. Für eine weitere Reduktion der Rechenzeit werden D' und D'' vorab ausgedünnt, indem s_{thin} Punkte zufällig ausgewählt werden ($\rightarrow D'_2, D''_2$). Eine Iteration k des Algorithmus besteht aus folgenden Grundschrinen:

1. Wähle das Punktepaar $p_r \in D'_2$ und $p_s \in D''_2$.
2. Nimm eine Korrespondenz dieser Punkte an. Verschiebe D''_2 anhand der Translation $\Delta_{trans\ r,s}(k)$ so, dass p_s auf p_r abgebildet wird ($D''_2 \rightarrow D''_3$).
3. Bestimme die nächsten Nachbarn aller s_{thin} Datenpunkte D''_3 in D'_2 , sowie die Distanzen $d_{r,s}$ zu diesen.
4. Bestimme $G_{r,s}(k)$, die Güte der Translation, über:

$$G_{r,s}(k) = \sum_{n=1}^{s_{thin}} ND_{max} - d_{r,s}(n) \quad (3.4)$$

Wobei der Parameter ND_{max} eine maximal zulässige Distanz der gefundenen nächsten Nachbarn angibt. Punktepaare mit einem Abstand $d_{r,s} > ND_{max}$ werden nicht in die Wertung mit aufgenommen. Die Schritte 1-4 werden für alle möglichen Kombinationen r, s wiederholt. Letztlich wird die Translation mit dem höchsten Gütewert gewählt und auf D'' angewendet.

3.5.2 Iteratives kleinste Quadrate Matching (IKQM)

Das IKQM basiert auf bereits publizierten Ansätzen [5, 19] und versucht deren Stärken in den Matching-Vorgang einfließen zu lassen. Verwendet wird ein iterativer Algorithmus, der eine optimale¹⁵ Transformation von Punkten aus D'' zu den Lotfußpunkten L'_i auf den Geradensegmenten bestimmt, die in D' gefunden wurden. Anhand der Abbildungen 3.17 und 3.18 soll die Vorgehensweise näher erläutert werden. Ziel ist es, D'' in das Koordinatensystem von D' zu überführen. So stellt D'' eine neue Messung des Systems dar, während D' für bereits vorliegende Daten steht. Aus Anschauungszwecken wurde hier auf ein vorangestelltes ENM verzichtet, so dass die Datensätze zu Beginn einen

¹⁵optimal im Sinne der Minimierung der Abstandsquadratsumme

deutlicheren Versatz aufweisen, als dies in der Praxis der Fall ist.

Im Algorithmus werden in den bestehenden Daten Geradensegmente G'_i detektiert. Um jedes G'_i wird ein sogenanntes Einzugsgebiet $E(G)$ gelegt. Dieses definiert sich über einen festen Abstand Δ_{maxLot} senkrecht zu beiden Seiten der G'_i . Die $E(G)$ bilden den Suchbereich für die Datenpunkte aus D'' , die für die Berechnung der Transformationsparameter verwendet werden ($D'' \rightarrow D2''$). Punkte außerhalb der $E(G)$ werden zunächst außer Acht gelassen. Mit der Einschränkung des Suchbereichs soll gewährleistet werden, dass nur tatsächlich korrespondierende Punkte bzw. Geradensegmente zueinander registriert werden. Für die gefundenen Datenpunkte werden deren L'_i auf den entsprechenden G'_i bestimmt.

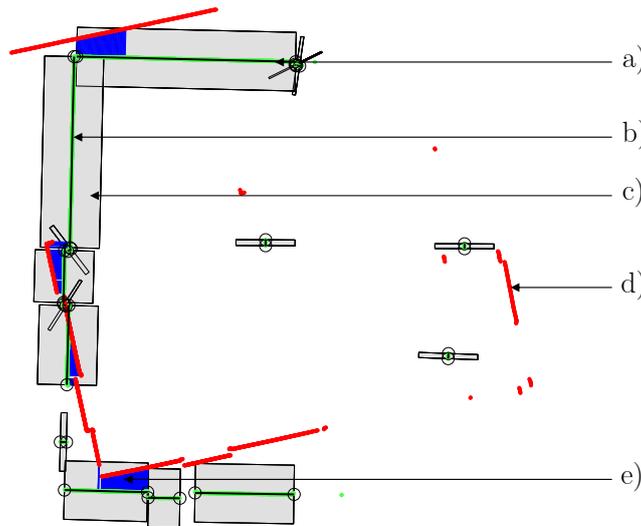


Abb. 3.17: Erläuterung der für das IKQM relevanten Parameter
Lage der Datensätze vor 1. Iteration: $\Delta_{maxLot} = 50$ cm; $\Delta_{maxGer} = 4$ cm
a) Datensatz D' (grün)
d) Datensatz D'' (rot)
b) Geradensegmente G'_i (schwarz)
c) Einzugsgebiete $E(G)$ (grau)
e) Verbindung von $D2''$ zu deren Lotfußpunkten L'_i (blau)

Parameterschätzung

Wie bereits beim ENM ist die Registrierung von D'' im Koordinatensystem von D' das Ziel. Das Matching soll unter der Anforderung erfolgen, die Summe der Abstände zwischen den Datenpunkten $D2''$ mit $D2'' \subseteq D''$ und den diesen zugeordneten Lotfußpunkten L'_i zu minimieren. Die Transformation läßt sich gemäß Gleichung 2.2 anhand von drei Parametern T_x , T_y und T_ϕ definieren.

Die Parameterschätzung erfolgt über eine Ausgleichung nach dem Modell von Gauß-Markoff (siehe Anhang A.4). Das Ausgleichungsmodell benötigt das Aufstellen funktionaler Beziehungen f zwischen Beobachtungen und den gesuchten Parametern der Transformation, den sogenannten Beobachtungsgleichungen. Diese ergeben sich über die Datenpunkte $D2''$, für die ein korrespondierendes Geradensegment gefunden wurde. Die zu minimierende Größe bildet die Summe der Lotabstände zwischen den Datenpunkten aus $D2''$ und ihren zugehörigen L'_i .

Anhand von Gleichung 2.2 lassen sich die Lotabstände, welche in Form des Vektors der Beobachtungen Δ_{Lot} in die Ausgleichung eingehen, in Abhängigkeit von den gesuchten Transformationsparametern darstellen. Sei z.B. O'' ein beliebiger Punkt aus $D2''$ und O' dessen zugeordneter Lotfußpunkt im

Koordinatensystem von D' , kann dessen Abstand $\Delta_{O'O''}$ beschrieben werden über:

$$\Delta_{O'O''} = \sqrt{(O'_x - (\cos(T_\phi)O''_x - \sin(T_\phi)O''_y + T_x))^2 + (O'_y - (\sin(T_\phi)O''_x + \cos(T_\phi)O''_y + T_y))^2} \quad (3.5)$$

Der gesuchte Parametervektor \hat{x} kann gemäß Gleichung A.10 geschätzt werden über:

$$\hat{x} = (A^T P A)^{-1} A^T P \Delta_{Lot}^T = \begin{pmatrix} T_\phi \\ T_x \\ T_y \end{pmatrix} \quad (3.6)$$

Für das Aufstellen der Koeffizientenmatrix $A_{(n,3)}$ werden die partiellen Ableitungen des funktionalen Modells, also Gleichung 3.5, nach den 3 unbekanntem Parametern benötigt:

$$A_{n,3} = \begin{pmatrix} a_{1,1} & a_{1,2} & a_{1,3} \\ a_{2,1} & a_{2,2} & a_{2,3} \\ \vdots & \vdots & \vdots \\ a_{n,1} & a_{n,2} & a_{n,3} \end{pmatrix} \quad (3.7)$$

mit:

$$a_{n,u} = \left(\frac{\delta f_n}{\delta \hat{x}_u} \right)$$

Es ergeben sich folgende Ableitungen:

$$\begin{aligned} \frac{\delta f}{\delta T_\phi} &= \frac{p_1 p_4 + p_2 p_5}{p_{12}^{\frac{1}{2}}} \\ \frac{\delta f}{\delta T_x} &= -\frac{p_1}{p_{12}^{\frac{1}{2}}} \\ \frac{\delta f}{\delta T_y} &= -\frac{p_2}{p_{12}^{\frac{1}{2}}} \end{aligned} \quad (3.8)$$

mit:

$$\begin{aligned} p_1 &= O'_x - (\cos(T_\phi)O''_x - \sin(T_\phi)O''_y + T_x) \\ p_2 &= O'_y - (\sin(T_\phi)O''_x + \cos(T_\phi)O''_y + T_y) \\ p_3 &= p_1^2 + p_2^2 \\ p_4 &= \sin(T_\phi)O''_x + \cos(T_\phi)O''_y \\ p_5 &= -\cos(T_\phi)O''_x + \sin(T_\phi)O''_y \end{aligned}$$

Die einzelnen Lotabstände können und sollen an dieser Stelle mit einem individuellen Gewicht in die Ausgleichung eingehen, um die Genauigkeit und die Robustheit des Matchings zu verbessern. Eine gezielte Steuerung der Gewichtung kann über die Inverse der Kofaktormatrix Q_{ll} , der Gewichtsmatrix P (vgl. Anhang A.20) erfolgen. Beobachtungen mit L'_i , die von längeren G'_i herrühren, sollen ein entsprechend höheres Gewicht erhalten. Von diesen Geradensegmenten kann angenommen werden, dass sie mit einer höheren Genauigkeit bestimmt werden konnten, als kürzere Segmente, da der Einfluss von Ausreißern und Messrauschen auf deren Regression geringer ist. Die Gewichtung der Beobachtungen

d über die Spur von P erfolgt in Abhängigkeit vom längsten Geradensegment G_{max} , das in den Daten enthalten ist:

$$P_{(i,i)} = \frac{G'_i}{G_{max}} \quad (3.9)$$

Bei den aufgestellten Beobachtungsgleichungen (Gleichung 3.5) handelt es sich nicht um lineare Beziehungen, so dass eine vorangehende Linearisierung notwendig ist. So werden für die initiale Schätzung Näherungswerte für den Parametervektor \hat{x} benötigt. In der vorliegenden Anwendung wird dem eigentlichen Matching eine Überlagerung der Daten, basierend auf den Odometriedaten, vorangestellt. Dadurch lassen sich die Parameter T_x , T_y und T_ϕ als erste Näherung mit einem Wert von 0 belegen. Eine Wahl von schlechten Näherungswerten kann unter Umständen zu einer Konvergenz des Matchings hin zu einem lokalen Maximum und damit zu einem falschen Ergebnis führen. Solche groben Fehler konnten in den praktischen Versuchen nicht festgestellt werden.

Aufgrund der Linearisierung kann die Schätzung der Parameter nicht durch einen einmaligen Ausgleichungsprozess erfolgen. Vielmehr muss das Verfahren bis zur Konvergenz, bzw. einer Abbruchschranke iteriert werden (vgl. Abbildung 3.14). Dabei fließen die geschätzten Parameter der jeweils letzten Iteration als Näherungswerte in die folgende Iteration ein. Zwischen den Iterationsschritten erfolgt eine Neubestimmung des Vektors der Beobachtungen Δ_{Lot} . Die erneute Berechnung der Lotabstände basiert auf einer aktualisierten Zuordnung der Datenpunkte $\rightarrow D2''$. Eine Transformation von D'' anhand der Zwischenergebnisse erlaubt eine erneute Betrachtung der Zuordnungen zwischen den Datenpunkten aus D'' und der Geradensegmente G'_i . So kann es sein, dass neue Punkte unter den Schwellwert Δ_{maxLot} fallen, während andere nicht mehr in Betracht gezogen werden können. Diese zusätzliche Maßnahme entspricht dem Vorgehen während des klassischen ICP-Algorithmus gemäß [5], bei dem jeder Iterationsschritt eine erneute Betrachtung der Nachbarschaften mit sich bringt.

Iterative Parameteranpassung

Der bisher erläuterte Ansatz birgt Problematiken. Sowohl die Detektion von G'_i über den Schwellwert Δ_{maxGer} ¹⁶ als auch die Größe der $E(G)$, geregelt über Δ_{maxLot} , ist parameterabhängig. Für beide gibt es jedoch keine global optimalen Werte. Hinsichtlich der G'_i kann eine zu streng gewählte Parametrisierung dazu führen, dass keine oder zu wenige Geradensegmente gefunden werden. Auf der anderen Seite kann eine großzügige Parametrisierung zu Ungenauigkeiten bei der Definition der Segmente und damit auch im Ergebnis des Matching-Vorganges führen. Im Fall der Einzugsgebiete verhält sich dies ähnlich. Die Wahl großer $E(G)$ steigert die Wahrscheinlichkeit Datenpunkte zu finden, auch wenn die Datensätze zu Beginn größere Diskrepanzen bezüglich der Überlagerung aufweisen. Dadurch erhöht sich die Wahrscheinlichkeit, dass Punkte auf nicht korrespondierende G'_i transformiert werden sollen und die Bestimmung der Transformationsparameter damit negativ beeinträchtigt wird. Aufgrund der genannten Problematiken ist die Matching-Algorithmik so erweitert, dass der bereits beschriebene Prozess des Punkt-Lotfußpunkt Matchings wiederholt und unter Variation der genannten Parameter durchgeführt wird. Ausgehend von einer großzügigen Wahl der Parameter werden diese in jeder Iteration des Gesamtprozesses strenger gewählt. Die Iterationen werden fortgesetzt bis entweder nicht mehr genügend G'_i gefunden oder genügend Datenpunkte in die Einzugsgebiete fallen. Die gefundenen Geradensegmente werden bezüglich ihrer Anzahl, Größe und Ausrichtung überprüft. Dies ist notwendig, um einen Verbleib von ausreichend geometrisch eindeutigen Daten gewährleisten zu können. Würden dem Matching nur gleichgerichtete G'_i zur Verfügung stehen, bedeutete dies einen Freiheitsgrad bei

¹⁶Gibt den maximalen Abstand an, den ein Datenpunkt zur Ausgleichsgerade des Geradensegmentes haben darf

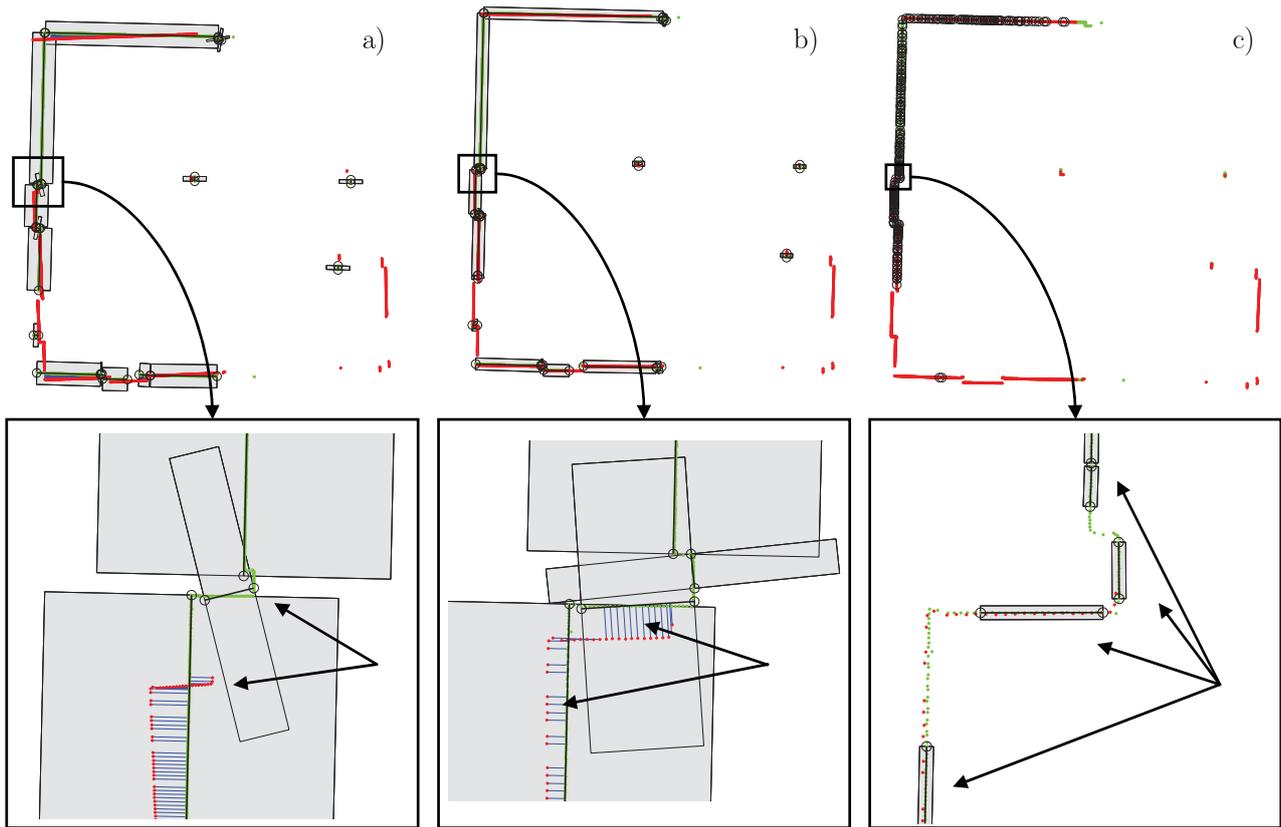


Abb. 3.18: Fortschritt des Matchingvorgangs mit Änderung der Parameter

- a) vor 2. Iteration: $\Delta_{maxLot} = 12.5$ cm; $\Delta_{maxGer} = 20.0$ mm; Korrespondierende Bereiche sind noch weit voneinander entfernt
 b) vor 3. Iteration: $\Delta_{maxLot} = 6.25$ cm; $\Delta_{maxGer} = 10.0$ mm; Ein Großteil korrekter Korrespondenzen wird gefunden
 c) vor 6. Iteration: $\Delta_{maxLot} = 7.81$ mm; $\Delta_{maxGer} = 1.25$ mm; Korrespondierende Bereiche liegen sehr nahe zusammen. Verwendung von sehr feinen und kleinflächigen Einzugsgebieten

der Parameterschätzung und führte zu ungenauen Resultaten in der Registrierung.

Auf der einen Seite lässt sich mit dieser Reduktion der Parameter eine robuste Konvergenz des Verfahrens ermöglichen. Auf der anderen Seite führt eine Wahl sehr kleiner $E(G)$ dazu, dass nur tatsächlich korrespondierende Punkte für die Bestimmung der Transformationsparameter genutzt werden. Eine strengere Definition der G'_i führt dazu, dass ein Matching nur an den Strukturen des Datensatzes erfolgt, die auch Geraden darstellen. Durch beide Maßnahmen wird eine Registrierung mit hoher Genauigkeit möglich.

Der iterative Prozess soll anhand von Abbildung 3.18 dargestellt werden. Während in Abbildung 3.17 der Ausgangszustand der Registrierung zu sehen ist, zeigen die Teilabbildungen in 3.18 den Zwischenstand des Matchingprozesses nach verschiedenen Iterationsstufen. D'' überlagert sich mit D' von der ersten bis zur 6. Iterationsstufe immer besser. Deutlich zu erkennen ist, wie sich die Größe der $E(G)$ um die Geradensegmente bei jedem Iterationsschritt verringert. Vor Iteration 6 ist zu erkennen, dass anstatt weniger großer, nun viele kleinere G'_i detektiert werden, was sich auf den strengeren Parameter Δ_{maxGer} zurückführen lässt. Die sehr kleinen Einzugsbereiche sorgen dafür, dass nur noch tatsächlich korrespondierende Datenpunkte zum Matching-Ergebnis beitragen.

4 Evaluierung des 2D-Messsystems

Zur Untersuchung der Leistungsfähigkeit des Systems, wie es in Kapitel 3 beschrieben ist, wurden in einer realen Umgebung verschiedene Testreihen durchgeführt. Als Testumgebung dienten mehrere, miteinander verbundene und leere Räume (Abbildung 4.1).



Abb. 4.1: Reale Versuchsumgebung zur Evaluierung des 2D Messsystems

Ein wesentlicher, zu untersuchender Aspekt sind die grundsätzlichen explorativen Fähigkeiten des Systems. Die Explorationsstrategie muss in der Lage sein, das Messsystem in alle Bereiche einer Innenraumszene zu führen. Dies bildet die Grundlage für eine vollständige Vermessung im Detail, also der Minimierung der im Datensatz auftretenden Datenlücken. Ist ein Datensatz einer Szene erstellt, ist zu überprüfen mit welcher Genauigkeit dieser die wahren Objektgeometrien abbildet. Diese resultiert, basierend auf der Güte der Sensordaten, aus der Robustheit und der Genauigkeit des Registrierungsverfahrens.

4.1 Gewichtungsoptimierung der Kostenfunktion

Die Einflussgrößen der Kostenfunktion zur Bestimmung der nächsten Messpose in der 2D-Bewegungsstrategie sind mit den Gewichtungen f_1 - f_3 versehen (vgl. Kapitel 3.4.2). Zielsetzung des folgenden Tests war es f_1 - f_3 so anzupassen, dass die aus der Messstrategie resultierenden Größen T_1 und T_2 (siehe Tabelle 4.2) minimiert werden. Aufgrund der Komplexität der funktionalen Abhängigkeiten zwischen den Parametern f_1 - f_3 und der Zielgröße $z(T_1, T_2)$ wurde auf das vorliegende kombinatorische Optimierungsproblem eine lokale Suche, ähnlich einer *Tabu-Suche* (vgl. [36]) angewandt. Als Startlösung diente eine Faktorisierung mit f_1 - $f_3 = 1$. Von dieser aktuellen Lösung ausgehend wurde in einer ersten Testiteration eine Nachbarschaft von Lösungen $F_{50}(f_1$ - $f_3)$ generiert, indem die Gewichtung der Startlösung in 50 Subiterationen durch Zufallswerte mit einer Standardabweichung von $\sigma_i = f_i$ variiert wurde. Im Anschluss wurden die Algorithmen der Explorationsstrategie unter Verwendung aller F_{50} auf einen virtuellen Testraum angewandt. Basierend auf den resultierenden Explorationen wurden zwei Ranglisten in Abhängigkeit von T_1 und T_2 mit den Platzierungen P_j von 1 bis 50 gebildet. Die Summe beider Ranglistenplatzierungen führt zur Zielgröße $z(T_1, T_2)$:

$$z_j = P_j^{T1} + P_j^{T2} \quad (4.1)$$

In Abbildung 4.2a ist die finale Rangliste der z_j den entsprechenden Faktorvariationen F_{50} gegenübergestellt. Diese Darstellung ermöglicht es Zusammenhänge zwischen der Variation der Parameter und dem damit verbundenen Einfluss auf die Zielfunktion in Form von Regressionsgeraden abzubilden. Zu

sehen ist ein Verbesserung der Zielfunktion bei einer höheren Gewichtung von f_1 und gleichzeitiger Gewichtungssenkung von f_3 .

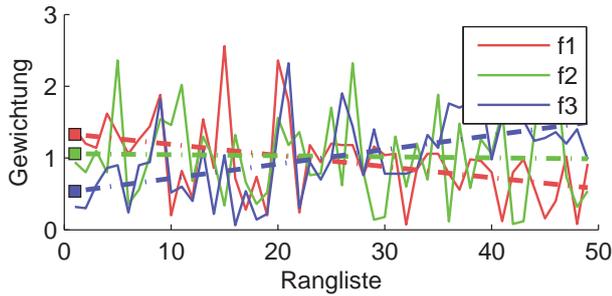
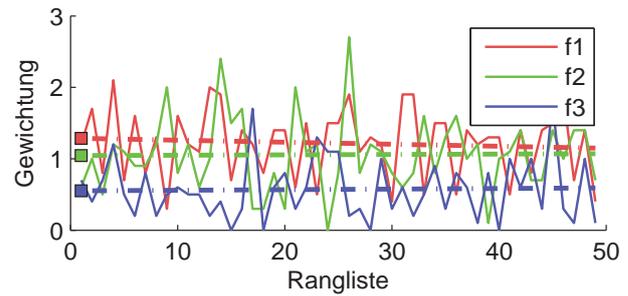
a) F_{50} Testiteration 1b) F_{50} Testiteration 2

Abb. 4.2: Ranglisten der Gewichtungsvariationen f_{50}

Es gehen die optimierten Gewichtungen f_i hervor (siehe Tabelle 4.1). Diese wurden in einer zweiten Testiteration erneut in 50 Subiterationen mit $\sigma_i = f_i$ variiert. Die finale Rangliste ist in Abbildung 4.2b dargestellt. Die geringen Steigungen der Regressionsgeraden bilden das Abbruchkriterium für die Gewichtungsoptimierung, da diese darauf schließen lassen, dass hier zumindest ein lokales Minimum erreicht wurde.

Auf eine ausführlichere, eventuell globale Parameteroptimierung wurde an dieser Stelle verzichtet. Die aus der zweiten Testiteration resultierenden Gewichtungen wurden für die weiteren Untersuchungen beibehalten.

Faktoren	f_1	f_2	f_3
Ausgangsgewichtungen	1.0	1.0	1.0
Gewichtungen nach 1. Testiteration	1.3	1.1	0.5
Gewichtungen nach 2. Testiteration	1.3	1.0	0.6

Tab. 4.1: Gewichtung f_1 - f_3 der 3 Einflussgrößen vor und nach den Optimierungsschritten

Testgröße T_i	Gewichtung G_i
T_1 : Anzahl der Messposen	1
T_2 : Geamtstrecke	1

Tab. 4.2: Evaluierte Testgrößen und deren Gewichtungen in der Zielfunktion

4.2 Lokalisierungsgenauigkeit des Scan-Matchings

Im folgenden Test wurde die Genauigkeit des implementierten Scan-Matching Verfahrens evaluiert. Das Scan-Matching steht in direktem Zusammenhang mit dem Kartenaufbau und der Selbstlokalisierung des Systems in der Karte. Neue Messdaten werden über eine 2D-Starrkörpertransformation in der bestehenden Karte registriert und diese erweitert. Die aktuelle Pose des Messsystems in der Karte läßt sich daher direkt aus den ermittelten Transformationsparametern ableiten. Umgekehrt lassen sich also Aussagen über das Scan-Matching durch eine Untersuchung der Selbstlokalisierung des Systems treffen. Dies ist möglich, wenn die Posen des Messsystems während des Messvorgangs von einem Referenzsystem mit übergeordneter Genauigkeit beobachtet und mit den vom Messsystem selbst bestimmten Posen verglichen werden.

Realisiert wurde dies durch den Einsatz eines Tachymeters (siehe Anhang A.9). Da mit diesem der Sensorursprung des Scanners nicht direkt beobachtet werden kann, wurde auf der mobilen Plattform ein Festpunktfeld installiert. So ließen sich durch die Einmessung der jeweils sichtbaren Punkte des Festpunktfeldes die relativen Poseveränderungen der Plattform während einer Messfahrt beobachten und mit den durch das Scan-Matching ermittelten Werten vergleichen (Abbildung 4.3). Ausgehend von der Annahme fehlerloser Tachymetermessungen konnte eine Analyse der Lokalisierungsgenauig-

keit des Systems durchgeführt werden.

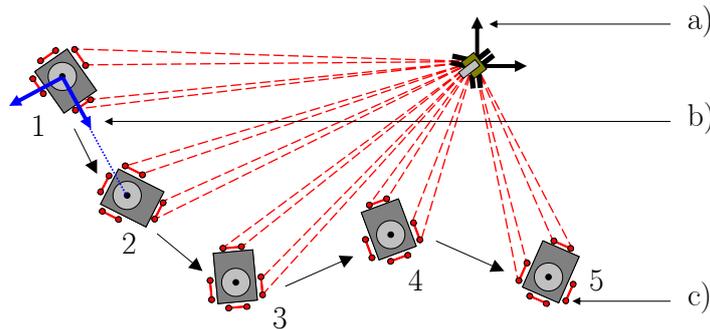


Abb. 4.3: Ermittlung der Plattformpose mit einem Tachymeter durch die Beobachtung des Festpunktfeldes
a) Tachymeterkoordinatensystem
b) Plattformkoordinatensystem
c) Festpunktfeld

In mehreren Messfahrten wurden 93 Posebeobachtungen in einem Entfernungintervall von 0 m - 11 m durchgeführt. Das Koordinatensystem der Plattform wurde bei jeder Messfahrt im jeweils ersten Standort der Plattform gelagert und relativ zum zweiten Standort orientiert. Die Abbildungen 4.4 und 4.5 stellen die Ergebnisse der Testreihe dar. Unter Annahme fehlerloser Beobachtungen kann bezüglich der Positionsabweichungen der Wert 0 als wahrer zu erwartender Wert \tilde{X} angenommen werden. Nach Gleichung A.37 ergab sich für die Messwerte eine empirische Standardabweichung von $s_0 = 6.7$ mm bei einer maximalen Differenz von 21 mm.

Eine weitere Messgröße stellt die Korrelation zwischen den Differenzen und den Distanzen der Plattformpositionen zur jeweils ersten Position dar. Im Idealfall sollte hier keine Korrelation erkennbar sein, was aber allein aufgrund der mit Fehlern behafteten Messdaten auszuschließen ist. In Abbildung 4.5 sind die ermittelten Abweichungen gegen die jeweilige Distanz zum Systemursprung aufgetragen. Zu erkennen ist eine Abhängigkeit von Genauigkeit und Distanz.

Quantitativ erfassen lässt sich eine Abhängigkeit zweier Parameter über den Korrelationskoeffizienten (siehe Anhang A.10). Für diesen wurde ein Wert von $r_{xy} = 0.57$ ermittelt. So lässt sich hier eine leichte Abhängigkeit zur Distanz erkennen. Unterstellt man dem Anwachsen des Fehlers zudem ein lineares Wachstum, kann für diesen über eine Regressionsgerade ein metrischer Wert bestimmt werden. Die für die Messwerte ermittelte Regressionsgerade (Abbildung 4.5) weist eine Steigung von 0.78 mm/m auf.

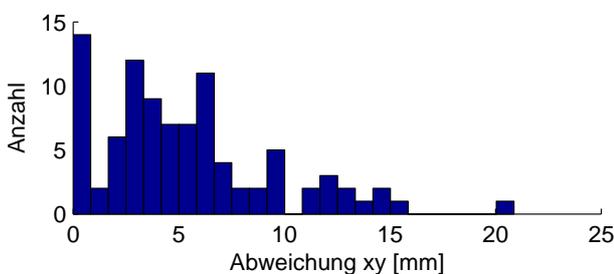


Abb. 4.4: Histogramm der Koordinatendifferenzen

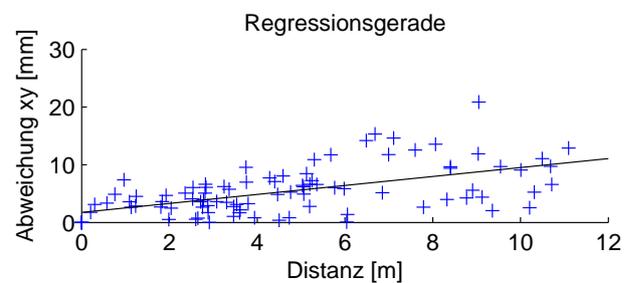


Abb. 4.5: Entfernungabhängige Darstellung der Koordinatendifferenzen samt Regressionsgerade

Zusätzlich zur Positionsgenauigkeit erfolgte eine Evaluation der rotatorischen Orientierungskomponente, welche in den Abbildungen 4.6 und 4.7 illustriert ist. Es wurde eine empirische Standardabweichung

chung von $s_0 = 0.45^\circ$ ermittelt, womit hier eine unerwartet hohe Streuung auftritt. Eine entsprechende Orientierungs- bzw. Matchinggenauigkeit ließe die Erzeugung von Umgebungsdatensätzen mit der in Abschnitt 4.7 nachgewiesenen Genauigkeit nicht zu. Erklären lässt sich die hohe Streuung mit der sensorinternen Referenziergenauigkeit. In einer weiteren Untersuchung, in der die Wiederholgenauigkeit des Sensors geprüft wurde, konnte eine rotatorische Streuung der Datenpunkte mit vergleichbarer Streuung nachgewiesen werden. Die vorliegenden Testergebnisse der rotatorischen Komponente lassen folglich keine verlässliche Genauigkeitsaussage zu.

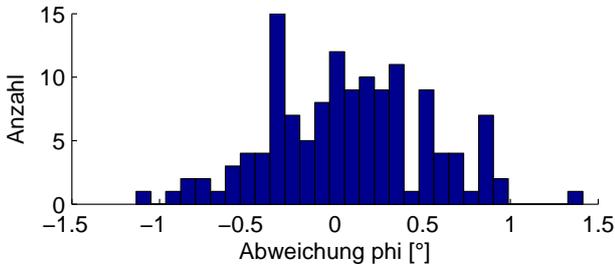


Abb. 4.6: Histogramm der Orientierungsdifferenzen

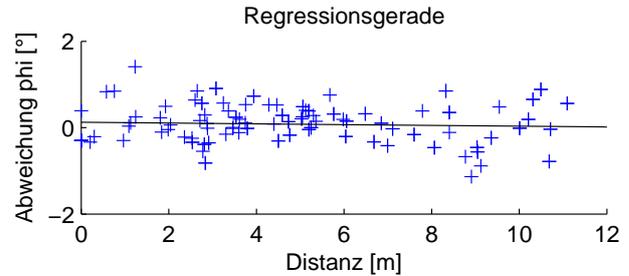


Abb. 4.7: Entfernungsabhängige Darstellung der Orientierungsdifferenzen samt Regressionsgerade

Die Positioniergenauigkeit hängt mit der Genauigkeit des Scan-Matchings zusammen, welches wiederum die Genauigkeit der Kartenerstellung beeinflusst. So gibt dieser Test Auskunft über das Fehlverhalten bei der Kartierung einer Szene bei zunehmender Ausdehnung. Relevant ist dieser Test für die angewandte Explorationsstrategie und deren Parametrisierung. Die hier vorliegenden Testergebnisse dienen zudem zur Bestätigung der Ergebnisse aus Abschnitt 4.7, da die resultierenden Umgebungsdatensätze ein vergleichbares Genauigkeitsniveau erreichen.

4.3 Lokalisierungsgenauigkeit der Odometrie

Die Schrittmotoren der Plattform geben Encoderwerte zurück, über die die gefahrene Strecke zurückgerechnet werden kann. Diese Odometriedaten erlauben eine Kontrolle der Pose während der Fahrt und ermöglichen bereits vor der Messung eine Prädiktion der aktuellen Messpose. Die Odometrie als einzige sensorische Datenquelle während der Fahrt ist also verantwortlich für deren korrekten und reibungslosen Verlauf. Mit der Prädiktion wird eine Vororientierung der neuen Messung für das Scan-Matching bestimmt. Die Robustheit des Scan-Matchings ist somit abhängig von deren Güte.

Da die Bewegungsalgorithmik des Systems ausschließlich Geradeausfahrten und Drehungen um die eigene Achse vorsieht (vgl. Kapitel 3.3), wurden diese Bewegungsmodelle separat analysiert. In jeweils 50 Durchläufen wurden Geradeausfahrten über 4 m sowie Drehungen um 360° beobachtet¹. Mit einer zusätzlichen Messreihe wurden die sich aufsummierenden Abweichungen bei einer längeren Fahrt bestehend aus Drehungen und Geradeausfahrten beobachtet. Die Messungen wurden auf Teppichbelag durchgeführt, weshalb die Wahrscheinlichkeit für das Auftreten von Schlupf als gering einzustufen ist. Ein metrisches Maß wird bei der Odometrie durch die Angabe der Radumfänge $U_{l/r}$ und dem Abstand der Räder D_{Rad} eingeführt (vgl. Kapitel 3.3). Diese Parameter müssen für eine möglichst präzise Odometrie optimiert werden, was durch die beschriebenen Messungen geschehen ist. Die Versuchsergebnisse zur Evaluierung der Odometrie genaugkeit finden sich in Anhang A.11. Basierend auf diesen Ergebnissen wurden der Pfadplanung folgende Restriktionen hinzugefügt, um eine kollisionsfreie Navigation des Systems gewährleisten zu können:

¹entsprechend der Vorgehensweise in Abschnitt 4.2

- Erweiterung des Konfigurationsraumes um einen Sicherheitsbereich von 10 cm
- Unterbrechung von Fahrten mit einer Gesamtlänge > 10 m, um zwischenzeitliche Scannermessungen für eine präzise Relokalisierung durchzuführen

4.4 Variation der Datendichte

Die Algorithmik des Messsystems ist so ausgelegt, dass die Datendichte, mit der die Umgebung aufgezeichnet werden soll, anfangs gewählt werden kann (vgl. Kapitel 3.4.3). Diese Eigenschaft soll die Möglichkeit geben eine schnelle und grobe oder aber eine feine und eventuell aufwendigere Einmessung durchführen zu lassen, je nachdem welcher Detaillierungsgrad benötigt wird.

Der für die Datendichte reservierte Schwellwert D_{gap} definiert zugleich die Existenz von Datenlücken. Findet sich für einen Messpunkt kein nächster Nachbar innerhalb einer durch den Schwellwert gegebenen Distanz, wird dieser als Lückenknoten klassifiziert.

Die Anwendbarkeit der Explorationsstrategie ist abhängig von der Definition der Größe von Datenlücken und den Messeigenschaften des Sensors. Der hier durchgeführte Test klärt, welchen Messaufwand eine entsprechende Wahl von D_{gap} mit sich bringt. Zudem wird aufgezeigt, inwiefern die Wahl von D_{gap} Einschränkungen unterliegt.

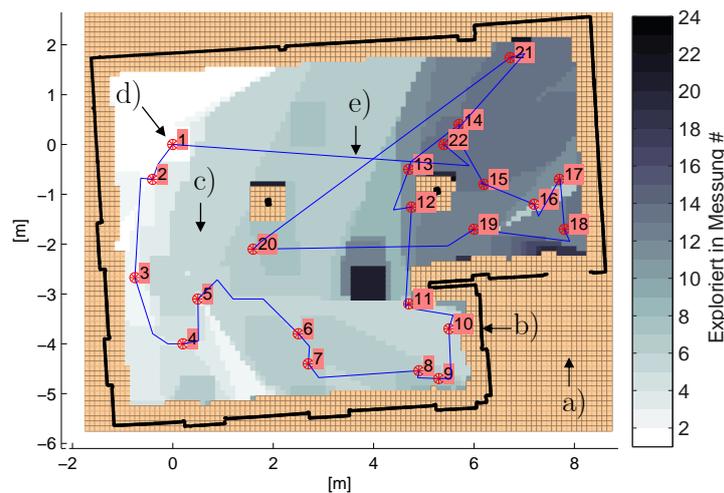


Abb. 4.8: Schematische Darstellung der Messfahrt bei $D_{gap} = 4$ cm

- unexplorierte Bereiche
- Raummodell
- befahrbare Bereiche
- Messpositionen
- Fahrstrecke

Wird D_{gap} zu klein gewählt, führt die Messunsicherheit des Sensors zu einem wesentlichen und negativen Einfluss auf die Explorationsstrategie. Allein durch das Messrauschen entstehen Abstände zwischen den sukzessiv gemessenen Punkten, die als Datenlücken deklariert werden. Durch die Datenverwaltung, in der gegebenenfalls die Daten bereits vorhandener Umgebungsbereiche durch Neudaten ersetzt werden, können so in bereits lückenfreien Bereichen erneut Datenlücken auftreten. Diese sogenannten „virtuellen“ Datenlücken können die Dauer von Messfahrten signifikant erhöhen.

Es wurde ein ca. 60 m^2 großer Raum der Versuchsumgebung wiederholt und mit gleicher Startposition eingemessen. Für D_{gap} wurden folgende Werte gewählt: 4 cm, 2 cm, 1 cm, 0,5 cm. Eine detailliertere

Darstellung der Testreihe findet sich in den Abbildungen 4.8 und 4.9 sowie in Anhang A.12.

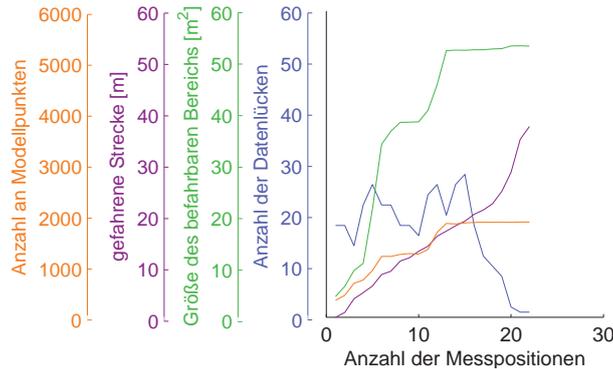


Abb. 4.9: Parameterverlauf bei $D_{gap} = 4$ cm

Der Test ergab bei den Werten 4 cm, 2 cm und 1 cm jeweils eine Erhöhung der Anzahl der benötigten Messpositionen und damit der insgesamt zurückgelegten Strecke (siehe Tabelle 4.3). Der Messaufwand erhöhte sich nicht mit demselben Faktor wie die resultierende Datenmenge. Während eine Halbierung von D_{gap} eine Verdoppelung der Datenmenge bedeutet, stiegen die Anzahl der Messpositionen und die zurückgelegte Strecke nur relativ gering an.

Die Messfahrt bei Verwendung von $D_{gap} = 0.5$ cm wurde nach 12 Messungen abgebrochen. Hier trat der Effekt der virtuellen Datenlücken in Erscheinung und zeigte sich bei der Mehrzahl der wiederholt eingemessenen Oberflächen. In einem weiteren, hier nicht aufgezeigten Test mit $D_{gap} = 0.75$ cm traten virtuelle Datenlücken nur sehr vereinzelt auf, während dieser Effekt bei dem Versuch mit $D_{gap} = 1$ cm nicht auftrat. Die mit der Systemkonfiguration maximal erreichbare Modelldichte beträgt folglich 1 cm. Eine Wahl von D_{gap} größer als 4 cm wäre zwar denkbar, wurde aber nicht berücksichtigt, da entsprechend grobe Repräsentationen von Innenräumen Vermessungszwecken nur noch unzulänglich dienen können.

Ein weiterer Effekt, der sich bereits in der Theorie ableiten lässt, betrifft die Anzahl entstehender Datenlücken. Die laterale Auflösung des Sensors von 0.1° führt zu einem entsprechenden distanzabhängigen Abstand zweier benachbarter Messpunkte. Dieser liegt bei lotrechtem Auftreffen des Messstrahles in einer Entfernung von 7.5 m (Messbereich des Sensors) bereits bei über 1 cm. Bei zu kleiner Wahl von D_{gap} führt also allein eine Erfassung von Oberflächen aus großer Entfernung zu Datenlücken. Auch dieser Effekt kann sich auf die Explorationsstrategie auswirken und zu einer Erhöhung des Messaufwandes führen. So stieg z.B. die Anzahl der Datenlücken beim Versuch mit $D_{gap} = 0.5$ cm bereits nach 6 Messungen auf beinahe 500 an.

Schwellwert Datenlücken D_{gap}	Anzahl Messpositionen	Anzahl Modellpunkte	Gefahrene Strecke	Befahrbarer Bereich
4 cm	22	1865	37.4 m	53.7 m ²
2 cm	24	4611	39.5 m	54.7 m ²
1 cm	28	9328	53.0 m	50.4 m ²
0.5 cm	12	9654	12.1 m	34.9 m ²

Tab. 4.3: Resultierende Testgrößen unter Variation der Schwellwertes für Datenlücken D_{gap}

4.5 Variation der Startposition

In einem weiteren Versuch sollte geklärt werden, welchen Einfluss die Startposition des Messsystems auf die Exploration hat. Dazu wurden Einmessvorgänge mit drei unterschiedlichen Startpositionen evaluiert. Das Messsystem startete von der Mitte des Raumes, von einer Raumecke und von der Mitte einer der Wände. Die Ergebnisse sind in Anhang A.13 grafisch dargestellt. Quantitative Ergebnisse finden sich in Tabelle 4.4. In allen drei Fällen war die Einmessung erfolgreich, so dass eine nahezu vollständige Erfassung der Umgebung erfolgte. Nicht erfasst werden konnte jeweils eine Tür, die mit schwarzem Samt überzogen ist (Messwerte in der Datenfilterung eliminiert).

Fahrt Nummer	Startpunkt	Anzahl Messpositionen	Anzahl Modellpunkte	Gefahrene Strecke	Befahrbarer Bereich
1	Raummitte	19	5287	58.3 m	53.9 m ²
2	Wandmitte	20	4889	60.7 m	50.7 m ²
3	Ecke des Raumes	21	4774	46.7 m	51.7 m ²

Tab. 4.4: Resultierende Testgrößen unter Variation der Schwellwertes für Datenlücken D_{gap}

Bei Explorationsfahrt 1 konnten bereits mit den ersten Messungen relativ viele Bereiche des Raumes erfasst werden. So ist hier ein sprunghafter Anstieg des befahrbaren Bereiches und der gesammelten Modellpunkte zu verzeichnen. Die zunächst sehr hohe Anzahl an Datenlücken wurde in den folgenden Messungen stetig reduziert. Die Strecke ist damit länger als bei den Einmessvorgängen 2 und 3, was daran liegt, dass das System im mittleren Teil der Einmessung oft den Raumbereich gewechselte hat und dabei größere Strecken zurücklegte. Die Fahrten 2 und 3 charakterisieren sich dadurch, dass ein großer Teil der Raumfläche erst sehr spät oder auch gar nicht als befahrbar klassifiziert wurde. So ist in den Verläufen dieser Fahrten deutlich zu erkennen, dass das System die Exploration vor allem in Wandnähe vorantreibt, den mittleren Raumbereich dagegen meidet, da dieser lange Zeit als unbefahrbar klassifiziert wurde.

Es zeigte sich, dass die Wahl der Startposition keinen wesentlichen Einfluss auf den Erfolg der Exploration hatte. Bei zunehmender Raumgröße besteht jedoch die Gefahr, dass gegenüberliegende Wände aus dem Messbereich fallen und die Zwischenflächen als nicht befahrbar klassifiziert werden. Dann wäre eine Anpassung des Sensormessbereichs notwendig.

4.6 Vergleich mit herkömmlichen Messmitteln

Eine wesentliche Kenngröße mit der die Leistungsfähigkeit des Messsystems evaluiert werden kann, ist die Genauigkeit der erstellten Datensätze. Um diese evaluieren zu können, musste ein Referenzrahmen geschaffen werden. Dazu wurde der aus den Abschnitten 4.4 und 4.5 bereits bekannte Raum mit einem Tachymeter eingemessen, um im Anschluss aus den Punktdaten ein linienhaftes Modell abzuleiten.

Architekten und Handwerker benötigen für ihre Arbeit unter anderem Grundrisspläne von Innenraumszenen. Heutzutage lassen sich diese mit Hilfe handgehaltener Laserentfernungsmesser wie z.B. dem Bosch DLE50 (vgl. Anhang A.9) relativ komfortabel erstellen. Gerade bei künstlich geschaffenen Innenraumszenen können einzelne gerade Raumsegmente eingemessen und unter der Annahme rechter Winkel zu einem Modell zusammengefügt werden. Um einen Vergleich zu dieser Art der Innenraumvermessung zu schaffen, wurde die Szene zusätzliche auf beschriebene Weise mit einem DLE50

eingemessen. Für das 2D Messsystem wurde der bei Explorationsfahrt Nr. 3 in Abschnitt 4.5 aufgezeichnete Datensatz zum Vergleich herangezogen.

Während aus den Einmessungen durch das Tachymeter und das DLE Linienmodelle resultieren, liefert das 2D-RDM mobile eine Punktwolke. Folglich müssen die Daten aufbereitet werden, um vergleichbar zu sein. Dazu wurde das DLE50 Linienmodell entsprechend der Punktzahl des vom 2D-RDM mobile gelieferten Datensatzes diskretisiert.

Für den Vergleich wurden die Datensätze durch die manuelle Wahl eines Referenzpunktes und einer Referenzrichtung in einem gemeinsamen Koordinatensystem registriert. Als Kenngröße der Genauigkeitsevaluation dienen die Lotabstände der Messpunkte auf die jeweils nächstgelegenen Liniensegmente des Tachymetermodells (Abbildungen 4.10 und 4.11). Die Standardabweichungen und die maximalen Abweichungen der unterschiedlichen Datensätze finden sich in Tabelle 4.5. Es zeigt sich, dass mit dem 2D Messsystem eine Genauigkeitssteigerung um den Faktor 2 gegenüber der Einmessung mit einem DLE50 erreicht werden kann.

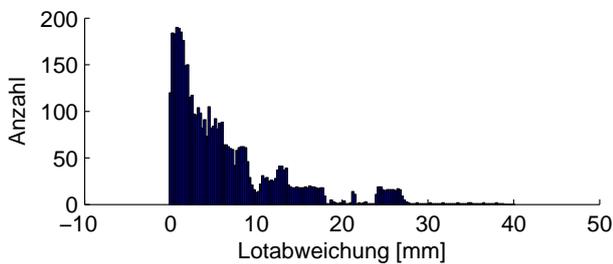


Abb. 4.10: Verteilung der Lotabweichungen: DLE50 Modell \leftrightarrow Tachymetermodell

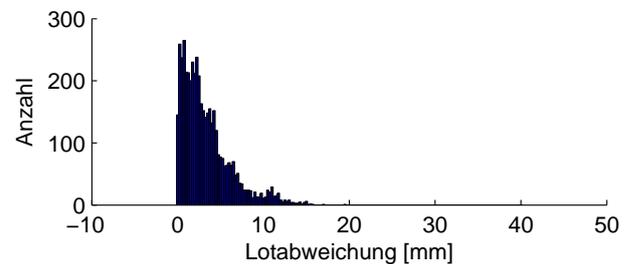


Abb. 4.11: Verteilung der Lotabweichungen: Mobiles Messsystem \leftrightarrow Tachymetermodell

Die Genauigkeit des DLE50 Modells ist abhängig davon, inwiefern die Annahme rechter Winkel mit der Realität übereinstimmt. Zusätzlich verursacht das Aneinanderhängen der gemessenen Distanzen ein Kumulieren der Modellabweichungen. Betrachtet man die geometrische Verteilung der Lotabweichungen im Hinblick auf die Reihenfolge, in der die einzelnen Strecken gemessen wurden, ist ein Zusammenhang erkennbar. Abbildung 4.12 stellt den Messraum, die Abfolge der DLE Messungen sowie die Lotabweichungen gegenüber dem Tachymetermodell dar. Zu erkennen ist ein Anstieg der Abweichungen mit zunehmender Zahl der aneinandergehängten Messungen. Der Schleifenschlussfehler am Ende des Umlaufs betrug hier 28.4 mm.

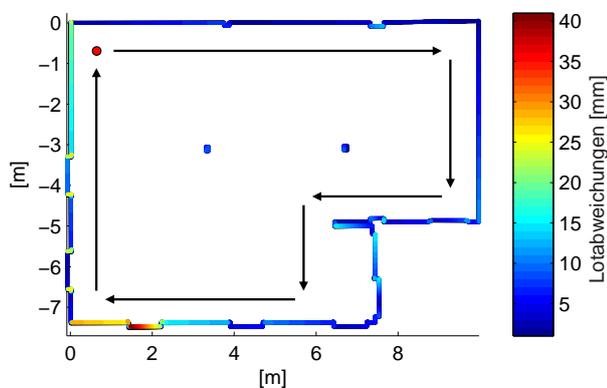


Abb. 4.12: Farblich kodierte Lotabweichungen: DLE50 Modell \leftrightarrow Tachymetermodell

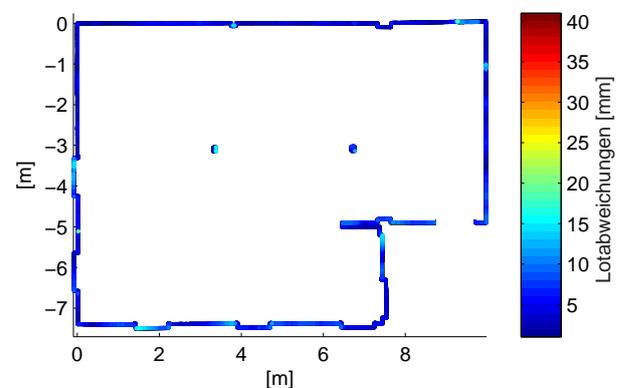


Abb. 4.13: Farblich kodierte Lotabweichungen: Mobiles Messsystem \leftrightarrow Tachymetermodell

Eine weitere wesentliche Kenngröße ist die Vollständigkeit der Datensätze. Im Falle des DLE50 Modells liegt diese bei 100%, falls für sehr kurze Maße ein Maßband hinzugezogen wird.

Die Vollständigkeit der Datensätze des 2D Messsystems hängt im Wesentlichen von der Beschaffenheit der Umgebung ab. Es gibt Datenlücken, die nicht erfasst werden können, weil entweder die entsprechende Umgebungsoberfläche eine ausreichende Reflektion des Messsignals verhindert, oder aber die Geometrie der Umgebung eine weitere Exploration des Messsystems unmöglich macht. Die hierfür aufgezeichneten Datensätze enthalten eine entsprechende Datenlücke im Bereich der mit schwarzem Samt bezogenen Tür (vgl. Abschnitt 4.5).

Die Schwierigkeit bei der Evaluation der Vollständigkeit liegt darin zu unterscheiden, welche Umgebungsbereiche aus den genannten Gründen prinzipiell nicht erfassbar sind und welche Bereiche aufgrund von Mängeln in der Systemalgorithmik fehlen. So ließen sich spiegelnde Oberflächen durch eine Einmessung unter senkrechtem Winkel erfassen, während ein flacher Auftreffwinkel des Messsignals zu einer nicht ausreichenden Reflektion des Signals führen kann. Schlecht reflektierende Oberflächen können eventuell aus nächster Nähe erfasst werden, während eine Einmessung aus großer Entfernung eine zu geringe Signalreflexion mit sich bringt. Beide Effekte werden in der Systemalgorithmik zwar grundsätzlich, aber eventuell nicht immer ausreichend berücksichtigt. Folglich kann es in diesen Fällen zu Fehlern bei der Exploration führen.

Um die Vollständigkeit der Datensätze quantitativ erfassbar zu machen, wird evaluiert, ob alle Umgebungsoberflächen in entsprechender Dichte erfasst werden konnten. Die Messfahrten erfolgten mit der Vorgabe eine Datendichte von $D_{gap} = 2$ cm zu erreichen. So wurde das Tachymetermodell in Abschnitte dieser Größe unterteilt. Für die Messpunkte des mobilen Systems wurden die Lotfußpunkte auf den nächstgelegenen Liniensegmenten des Tachymetermodells ermittelt. Eine die Vollständigkeit des Datensatzes beschreibende Größe ergibt sich nun über das Verhältnis der Tachymetermodellabschnitte, auf denen ein Lotfußpunkt ermittelt wurde, zur Gesamtanzahl der Abschnitte.

Die prozentualen Vollständigkeitswerte der Messfahrten finden sich in Tabelle 4.5. Bei den eingeklammerten Werten wurde der Bereich der Türe nicht berücksichtigt. Da die Türe auch bei fehlerloser Systemalgorithmik alleine aufgrund der Beschränkungen durch die elektrooptische Distanzmessung nicht erfasst werden kann, wird hier dieser zusätzliche Wert angegeben.

Messmittel	Fahrt Nummer	σ	max. Abweichung	Vollständigkeit
DLE50		9.5 mm	38.8 mm	100.0%
2D-RDM mobile	1 (Raummitte)	4.3 mm	18.9 mm	97.82% (99.96%)
2D-RDM mobile	3 (Wandmitte)	4.2 mm	18.8 mm	97.92% (100.0%)
2D-RDM mobile	2 (Ecke des Raumes)	4.4 mm	19.5 mm	97.72% (99.26%)

Tab. 4.5: Vergleich der Messfahrten des 2D Messsystems mit DLE50 Modell referenziert auf Tachymetermodell

4.7 Exploration komplexer Innenraumszenen

Im folgenden Versuch wird das Explorationsvermögen des Systems bei der Einmessung einer größeren und komplexeren Innenraumszene untersucht. Das System soll die gesamte, aus mehreren zusammenhängenden Räumen bestehende, Versuchsumgebung mit einer Gesamtgröße von ca. 150 m² einmessen. Abbildung 4.14 zeigt den vom System aufgezeichneten Datensatz der Szene und die vom System angefahrenen Messpositionen. Das System fuhr 95 Messpositionen an und legte dabei eine Strecke von ca. 160 m zurück.

Im Fokus des Versuchs stand zum Einen die Fähigkeit des Systems, Übergänge in noch unexplorierte Räume zu bewältigen. Diese bilden aufgrund des abrupten Umgebungswechsels eine besondere Heraus-

forderung für die Scan-Matching Algorithmik und müssen in der Explorationsstrategie berücksichtigt werden. Die Algorithmik wurde so erweitert, dass ein systemseitiges Erkennen von Türen möglich ist und dieses darauf entsprechend reagieren kann (vgl. Kapitel 3.4.2). Weitere, hier nicht aufgeführte Versuche ergaben, dass eine zusätzliche Messung in der Nähe des Übergangs zu einem neuen Raum notwendig ist, um die Karte ohne das Auftreten grober Fehler im Matchingprozess und mit gleich bleibender Genauigkeit erweitern zu können. So fuhr das System im dargestellten Versuch die Positionen 13, 42, 65 und 80 an, um die Exploration eines noch nicht erkundeten Raumes einzuleiten, was auf diesem Wege auch gelang.

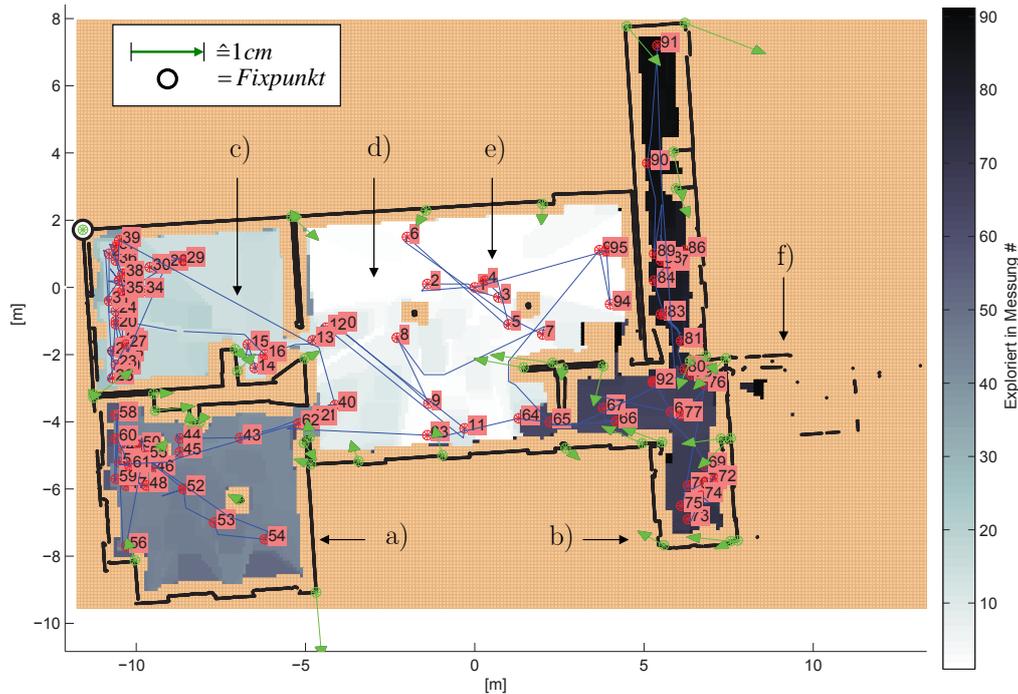


Abb. 4.14: Schematische Darstellung des Messverlauf bei der Exploration der gesamten Versuchsumgebung

- a) Modelldaten
- b) Differenzvektoren zu Tachymetermodell
- c) Gefahrener Pfad
- e) Färbung der Flächen in Abhängigkeit des Zeitpunkts der Einmessung
- d) Abfolge der Messpositionen
- f) Durch Glastüre gemessener Umgebungsbereich

Das wesentliche Ziel des Versuches war eine Evaluation der Genauigkeit, mit der das System eine solche Szene einzumessen vermag. Die mit Fehlern behafteten Messdaten übertragen sich zwangsläufig durch das Scan-Matching auf die erstellte Karte. Zudem summieren sich die Fehler durch das Aneinanderhängen von Aufnahmen bei der Erweiterung der Karte auf. Für die Bestimmung der Fehlergröße bei einer Szene dieser Dimension, wurde durch eine tachymetrische Einmessung ein Referenzmodell geschaffen. Anstatt eines vollständigen Modells, wie in Abschnitt 4.4 verwendet, wurden für diesen Versuch nur 42, über die Szene verteilte Punkte eingemessen. Da die Punkte an geometrisch markante Positionen gelegt wurden, ließen sich diese manuell im Datensatz des 2D Messsystems wiederfinden. Um eine Genauigkeitsaussage treffen zu können, wurden die beiden Punktwolken an einem gewählten Punkt² überlagert und anhand eines weiteren Punktes ausgerichtet. Betrachtet wurden die Differenzvektoren aller weiteren Punkte. In Abbildung 4.14 dargestellt sind die Größe und die Richtung der Koordinatendifferenzen zwischen den Modell- und den Referenzpunkten. Zu erkennen ist ein leichtes

²siehe Abbildung 4.14: Fixpunkt

Ansteigen der Differenzen mit zusätzlicher Entfernung zum Punkt der Überlagerung. Systematische Fehler, z.B. einzelne Räume, die gänzlich versetzt sind, treten nicht auf. In Abbildung 4.15 ist die quantitative Verteilung der Fehlerwerte in einem Histogramm dargestellt. Die auftretenden Differenzen weisen eine Standardabweichung von $s_0 = 5.2$ mm auf. Folglich ist das entwickelte Messsystem in der Lage Umgebungskarten in diesem Maßstabbereich mit einer hohen Gesamtgenauigkeit zu erstellen.

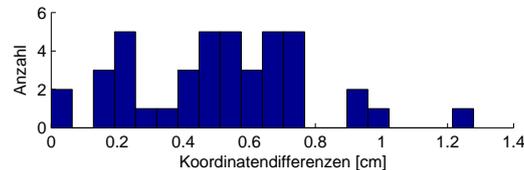


Abb. 4.15: Histogramm der Koordinatendifferenzen

4.8 Vergleich der Raummodelle

Den finalen Schritt im Prozess der vollautomatischen Generierung von Grundrissplänen bildet die Ableitung eines Modells aus den gesammelten Punktdaten. Aus Gründen der Vollständigkeit wird daher in diesem Abschnitt ein einfacher Modellierungsansatz auf die Daten angewandt und diskutiert.

Die Vorgehensweise bei der Modellbildung ist abhängig von der Interpretation der Punktdaten durch den Anwender. Prinzipiell gilt es im Rahmen der Modellbildung aus den Punktdaten mathematische Körper abzuleiten, wozu in der Regel ein Satz geometrischer Primitive verwendet wird. Es stellt sich die Frage, welche Primitive gefunden werden sollen. So lassen sich beispielsweise die auf einem zwei-dimensionalen Kreisbogen gelegenen Punkte durch einen solchen modellieren. Es ist jedoch auch eine Darstellung durch kurze, aneinandergereihte Geradenstücke möglich.

Im Rahmen dieser Arbeit wurde ein einfaches Modellierungsverfahren implementiert, welches auf der Annahme basiert, dass sich alle Umgebungsgeometrien ausschließlich durch Geradenstücke abbilden bzw. modellieren lassen. Vergleichbar mit der Vorgehensweise in Kapitel 3.5.2, werden in den Daten Geradensegmente gesucht und über die Ableitung von Adjazenzen miteinander verknüpft. Eine beispielhafte Modellierung ist in Abbildung 4.17 illustriert, eine detaillierte Beschreibung des Modellierungsverfahrens findet sich in [105].

Die Bildung der Geradenstücke ist schwellwertabhängig. Der Anwender muss daher vorgeben, ob eine gebogenes Umgebungselement durch eine einzelne Gerade zu modellieren ist oder durch mehrere feine Geradensegmente abgebildet werden soll. Im letzteren Fall ließen sich feinere Strukturen modellieren. Andererseits erhöht sich damit die Anfälligkeit der Modellierung zusammenhängende Umgebungselemente aufgrund einzelner Messfehler unnötig zu trennen. So findet sich hier keine global optimale Lösung. Ähnlich verhält es sich mit weiteren Parametern wie auch dem Schwellwert zur Verknüpfung von Geradensegmenten. Dieser Sachverhalt erschwert eine eindeutige Evaluation der Modellierung.

Um an dieser Stelle trotzdem aussagekräftige Ergebnisse zu erhalten, wurde das Modellierungsverfahren auf die Datensätze aus Abschnitt 4.4 mit einer gleichbleibenden Parametrisierung angewandt (vgl. Tabelle 4.6b). Da die Datensätze unterschiedliche Auflösungen aufweisen, kann abgeleitet werden, inwiefern eine Erhöhung der Datendichte zu einer Verbesserung der Modellierung führt. Als Referenz dient das Tachymetermodell aus Abschnitt 4.6.

Die resultierenden Modelle wurden manuell analysiert. Jedes Modellgeradensegment wurde einem Referenzsegment zugeordnet, sofern eine bijektive Zuordnung möglich war. Selbiges erfolgte mit den

Modellecken, also den Verknüpfungen der Modellsegmente. Durch diese Zuordnungen konnten folgende Evaluationsgrößen abgeleitet werden:

- **PAS**: Prozentualer Anteil der zugeordneten Segmente bezüglich der Gesamtanzahl der Segmente des Tachymetermodells [%]
- **s0L**: Standardabweichung der Längenunterschiede dL zugeordneter Segmente [mm]
- **s0P**: Standardabweichung der Abstände dP zwischen den Endpunkten zugeordneter Segmente [mm]
- **PAE**: Prozentualer Anteil der zugeordneten Modellecken bezüglich der Modelleckenanzahl des Tachymetermodells [%]
- **s0W**: Standardabweichung der Winkelunterschiede dW zugeordneter Modellecken [°]

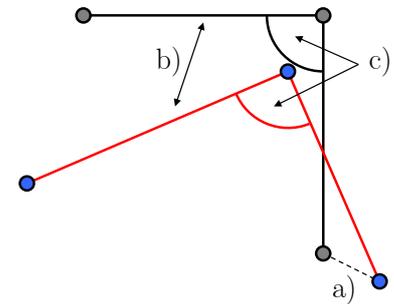


Abb. 4.16: Beispiel
a) dP
b) dL
c) dW

Die Modellierung wurde auf Datensätze unterschiedlicher Dichte angewandt, wobei für den Parameter d_{max} zur Definition von Ausgleichsgeraden die Werte 6 mm und 2 mm angenommen wurden. Folgende Tabelle stellt die aus der Testreihe resultierenden Evaluationsgrößen zusammen:

	a) Max. Lotabstand der Ausgleichsgeraden d_{max}					
	6 mm			2 mm		
Evaluationsgröße	b) Datendichte D_{gap}					
	1 cm	2 cm	4 cm	1 cm	2 cm	4 cm
PAS	79.07%	60.47%	47.67%	62.79%	44.19%	31.40%
s0L	8.53 mm	12.63 mm	24.38 mm	7.42 mm	8.95 mm	12.62 mm
s0P	8.06 mm	9.62 mm	18.87 mm	7.66 mm	7.81 mm	11.26 mm
PAE	93.98%	66.27%	51.81%	65.06%	59.04%	44.58%
s0W	13.07°	8.37°	12.86°	13.10°	7.79°	11.53°

Tab. 4.6: Testergebnisse: Evaluation der Modellierung

Die Ergebnisse spiegeln die vermutete Abhängigkeit von d_{max} wieder. Bei einer strengen Wahl erhöht sich die Genauigkeit der Modellierung bei allen Datendichten, was sich in s0L, s0P und s0W niederschlägt. Andererseits verringert sich gleichzeitig die Anzahl zuordenbarer Segmente bzw. Segmentecken deutlich.

Ein Vergleich zeigt, dass sich durch eine erhöhte Datendichte eine verbesserte Modellierung erzielen lässt. Gerade feinere Umgebungsstrukturen müssen durch eine ausreichende Anzahl an Messpunkten abgebildet werden. Der Einfluss von D_{gap} auf die Modellierung detaillierter Umgebungsbereiche ist in Abbildung 4.17 beispielhaft dargestellt. In den beiden abgebildeten Fällen ist die präzisere Modellierung mit $D_{gap} = 1$ cm erkennbar.

Die Resultate für s0W sind in allen Testvariationen mangelhaft. Dies ist zurückzuführen auf die große Anzahl der im Versuchsraum enthaltenen, detaillierten Umgebungsstrukturen. Die Genauigkeit der Winkelbestimmung ist abhängig von den Längen der beiden Segmente, die eine Modellecke bilden. So konnte hier ein höhere Genauigkeit an den Modellecken festgestellt werden, die die Hauptraumecken der Umgebung repräsentieren. Diese bilden aber nur einen geringen Anteil der Anzahl aller Modellecken.

Vergleicht man die Resultate der punktbezogenen Genauigkeiten s0L mit den Ergebnissen aus Kapitel 4.6, läßt sich eine Verringerung der Genauigkeit durch die Modellierung feststellen. Eine geringere Datendichte erhöht den Grad der Ungenauigkeit zusätzlich, obwohl die Genauigkeit der einzelnen Messpunkte als gleich anzunehmen ist, wie in Kapitel 4.6 nachgewiesen.

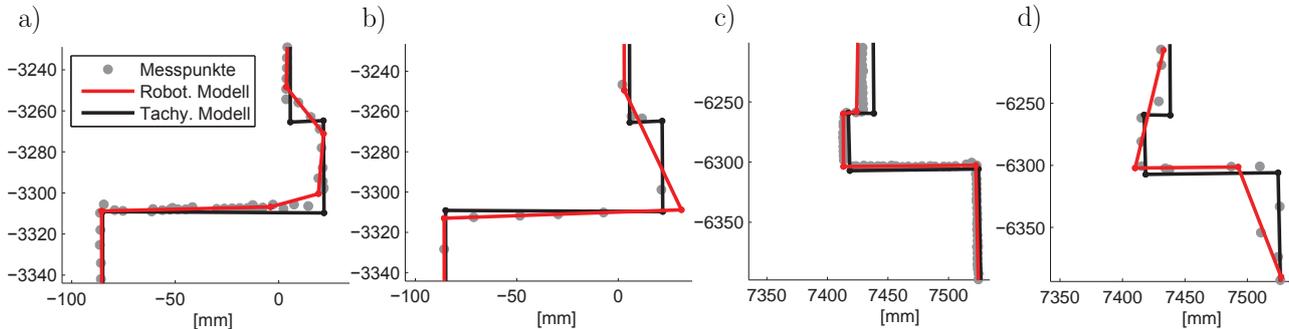


Abb. 4.17: Beispiel eines Modellierungsergebnisses für den realen Standardmessraum

- a) Ausschnitt 1; D_{gap} : 1 cm; d_{max} = 6 mm;
- b) Ausschnitt 1; D_{gap} : 4 cm; d_{max} = 6 mm;
- c) Ausschnitt 2; D_{gap} : 1 cm; d_{max} = 6 mm;
- d) Ausschnitt 2; D_{gap} : 4 cm; d_{max} = 6 mm;

4.9 Diskussion

In Kapitel 3 wurde eine Explorationsstrategie vorgestellt, mit der es möglich ist anhand eines scannden 2D-Messsystems eine präzise und vollständige Punktwolke einer unbekanntem Innenraumumgebung zu erzeugen. Die empirische Evaluierung wurde in Kapitel 4 vorgestellt.

Die iterative Neuberechnung einer Score-Map für alle im Belegtheitsgitter enthaltenen Punkte ist eine kostenintensive Methode zur Bestimmung der nächsten Messpose. Sie verspricht aber die, gemäß des hinterlegten Modells, global optimale Lösung. Der Ansatz wenige, aber durch eine ausführliche Analyse ausgewählte Posen zu nutzen, rechtfertigt sich durch den verwendeten Sensor, der aufgrund seines Messprinzips feste Messpositionen benötigt. Durch die lange Messdauer des Sensors ist jede Messung mit hohen zeitlichen Kosten verbunden (vgl. Abschnitt 3.1).

Der in Kapitel 4.7 vorgestellte Versuch belegt, dass eine vollständige Exploration weitläufiger Umgebungen anhand dieser Strategie möglich ist. Dabei war jedoch auch eine erhöhte Bearbeitungszeit der Algorithmik festzustellen. Um den Aufwand zur Erzeugung der besonders kostenintensiven Score-Map zu verringern, wäre der Einsatz weiterer, übergeordneter Strategien sinnvoll. Denkbar wäre eine Untergliederung der Karte im Verlauf der Exploration (vgl. [103], Abbildung 2.3). Damit ließe sich eine sukzessive Exploration von kleineren Umgebungsbereichen ermöglichen, wobei jeweils nur der aktuelle Kartenausschnitt bearbeitet wird.

Auch bei der Auslegung der Scan-Matching Methode wurden die Hardware-bedingten Restriktionen berücksichtigt. Die Versuche in Kapitel 4 belegen, dass die vorgestellte Methode robust im Umgang mit den Orientierungsdifferenzen sowie den geringen Überlappungsbereichen zwischen den Datensätzen ist, die durch die großen Positionsänderungen des Systems hervorgerufen werden. Eine Analyse, ob ein neu aufgezeichneter Datensatz aufgrund seiner geometrischen Information registrierbar ist, wird hier nicht durchgeführt. Das Einführen von Maßzahlen zur Registrierbarkeit (vgl. [35]) erbrächte dem System eine Kontrollmöglichkeit, durch die sich eine robuste Kartierung auch dann durchführen ließe, wenn die Messumgebung weniger geometrische Informationen zur Registrierung liefern könnte, als dies bei

den genutzten Umgebungen der Fall war. Strukturschwache Bereiche ließen sich durch das Ausführen zusätzlicher Messungen robust explorieren.

Prinzipiell ist der verwendete Scanner aufgrund des 360° Messbereichs im Vorteil gegenüber vielen bestehenden Systemen, die oftmals nur einen Bereich von 180° oder weniger zu scannen vermögen, da omnidirektional gemessene Punktwolken mit größerer Wahrscheinlichkeit Geometrieinformationen enthalten, die für eine erfolgreiche Registrierung nutzbar sind.

Da in den funktionalen Beziehungen des IKQM gemäß Gleichung 2.2 mehrere Beobachtungen und Unbekannte vorkommen, erbringt eine einmalige Ausgleichung anhand des Gauß-Markoff-Modells lediglich eine Näherungslösung. Erst die iterative Anwendung führt zu einer präzisen Parameterschätzung. Basierend auf einer Näherungslösung hätte alternativ eine Ausgleichung nach dem Gauß-Helmert-Modell durchgeführt werden können, durch die eine direkte Parameterschätzung möglich gewesen wäre (vgl. [83]). Da sich jedoch die iterative Neubestimmung der Punktkorrespondenzen im IKQM als vorteilhaft für die Robustheit des Matchings erwies, müsste auch im Fall einer Verwendung des Gauß-Helmert-Modells eine Iteration der Ausgleichung erfolgen. Auf eine zusätzliche Implementierung des Gauß-Helmert-Modells wurde daher an dieser Stelle verzichtet.

Das Messsystem ist nicht mit probabilistischen Lokalisierungsmethoden versehen. Stattdessen erfolgen sowohl die Lokalisierung als auch die Kartierung über das Scan-Matching im selben Prozess. Die ausschließliche Verwendung eines präzisen Scan-Matching Verfahrens begründet sich dadurch, dass nicht die Lokalisierung, sondern die Kartierung das primäre Ziel der vorliegenden Applikation war. Die durch das Scan-Matching gewonnene Lokalisierungsinformation ist ein weiterverwendetes Nebenprodukt. Aufgrund dieser Systemauslegung gehen die Fehler der Sensormessungen in beide Prozesse verbindlich ein. Eine nachträgliche Kontrolle und Korrektur ist somit nicht möglich. Bei einer Ausweitung der Messaufgabe führte die Aufsummierung der Fehler zu Inkonsistenzen im Umgebungsmodell, was fehlerhafte Datenlückendeklarationen zur Folge hätte. Um dem entgegen zu wirken, müssten zusätzliche probabilistische Lokisierungsverfahren implementiert werden, die mit Problemstellungen wie z.B. dem Loop-Closing umzugehen vermögen.

Der Parameter D_{gap} definiert die Minimalgröße einer Datenlücke und somit die angestrebte Dichte der resultierenden Punktwolke. Wie in Kapitel 4.4 gezeigt, ist diese Definition nur bis zu einem Wert von $D_{gap} = 1$ cm mit der Explorationsstrategie vereinbar. Dass dieser Wert erreicht werden kann, ist der Genauigkeit des verwendeten Laserscanners zuzuschreiben. Ein Einsatz der Strategie in Kombination mit einem Sensor geringerer Genauigkeit wäre dagegen weniger sinnvoll.

Die Kombination der Lücken-basierten Explorationsstrategie und der nachgeführten Datenverwaltung ermöglicht es dem System linienförmige Punktgruppen mit konstanter Datendichte zu erzeugen. Damit eignen sich die Datensätze für eine anschließende Modellierung.

Die Strategie erlaubt nur Messpositionen jenseits des Normalenvektors zur lokalen Segmentrichtung (vgl. Abbildung 3.10). Damit soll ein exploratives Systemverhalten gewährleistet werden. Diese Richtlinie kann jedoch zu einer unvollständigen Exploration führen, wenn der zulässige Einmessbereich einer grundsätzlich vermessbaren Datenlücke vollständig außerhalb des befahrbaren Bereichs liegt. Dies kann theoretisch dann vorkommen, wenn im Bereich der Datenlücke keine weiteren Oberflächen auftreten und die Reichweite des Sensors eine Erfassung der Umgebung der Lücke verhindert. Dieses Verhalten wurde bei keinem der durchgeführten Versuche beobachtet. Bei Umgebungen, deren Ausdehnung den Messbereich des Sensors überschreitet, wäre der Effekt jedoch kritischer zu bewerten. In diesem Fall stellt eine Erweiterung des Sensoreindeutigkeitsbereichs eine mögliche Lösung dar.

In die Kostenfunktion geht die euklidische Distanz D_{cp} zur nächsten Messposition ein. Im Fall von

Weghindernissen kann sich dieser Abstand beachtlich vom tatsächlichen Aufwand, also der Wegstrecke, die der Roboter abzufahren hat, um die Zielkonfiguration zu erreichen, unterscheiden. Eine entsprechende Anpassung brächte eine Optimierung der Strategie mit sich.

Das vorgestellte Messsystem beschränkt sich auf die Erzeugung eines Grundrissmodells. Um eine Szene dreidimensional zu erfassen, wird das System im nächsten Kapitel um einen bildgebenden Sensor erweitert.

5 Photogrammetrische Vermessung von Innenraumszenen

Dieses Kapitel beschreibt einen Ansatz zur vollständigen, autonomen und dreidimensionalen Vermessung einer Innenraumszene mittels einer robotischen Plattform, 3D-RDM mobile genannt, unter Verwendung eines elektrooptischen Sensors sowie eines photogrammetrischen Messsystems in Form einer Digitalkamera zuzüglich einer Rekonstruktionssoftware. Zielsetzung ist die Aquisition von Kameraaufnahmen derart, dass sich aus diesen anhand eines Bündelausgleichs eine präzise 3D-Punktwolke rekonstruieren lässt. Der Schwerpunkt des Kapitels liegt auf der Entwicklung einer Strategie zur Wahl der Aufnahmeposes (vgl. Abschnitt 5.2).

Abbildung 5.1 gibt einen Überblick über die allgemeine Vorgehensweise der Messprozedur. Zuerst erzeugt das System eine 2D-Punktwolke der Umgebung mit den Methoden aus Kapitel 3. Diese Daten werden genutzt, um einen Satz an Kameraposen zu ermitteln, von denen aus das System entsprechend Aufnahmen tätigt. Anhand einer Rekonstruktionssoftware werden Merkmalspunkte aus den Bilddaten abgeleitet, deren Korrespondenzen ermittelt und die 3D-Koordinaten zugeordneter Punkte im Rahmen eines Bündelausgleichs geschätzt. Abschnitt 5.1 stellt die verwendeten Hard- und Softwarerekomponenten vor. Eine ausführliche Erläuterung des Verfahrens findet sich in den Abschnitten 5.2 - 5.3. In Kapitel 6 erfolgt eine theoretische und eine empirische Evaluierung des Systems sowie eine abschließende Diskussion.

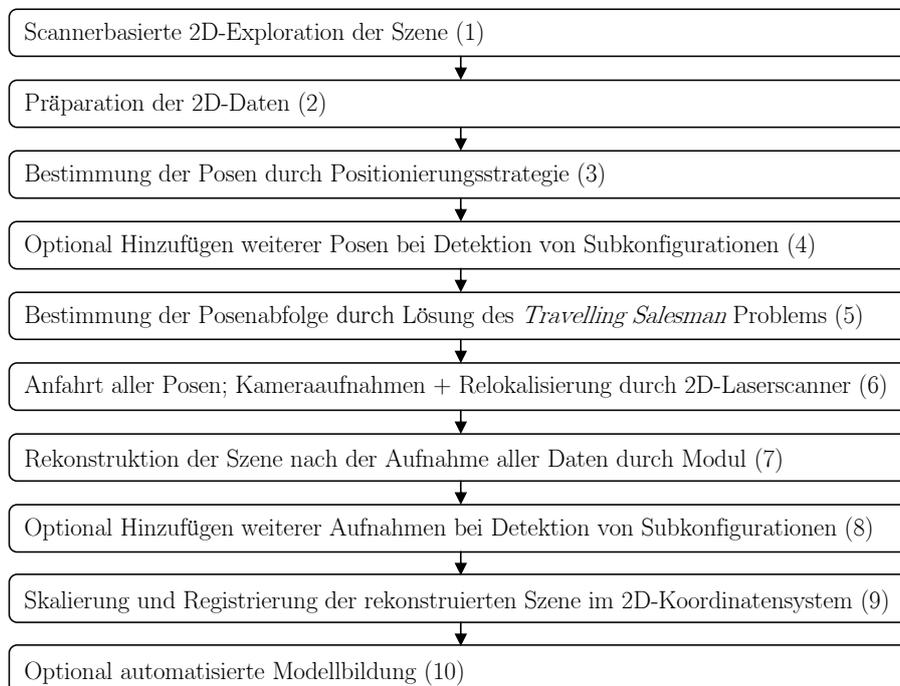


Abb. 5.1: Flussdiagramm zur Illustration des Gesamtablaufs der 3D-Rekonstruktion

(1): vgl. Kapitel 3

(2), (3): vgl. Abschnitt 5.2

(4), (5), (6), (8), (9): vgl. Abschnitt 5.3

(7): vgl. Abschnitt 5.1

(10) vgl. Kapitel 6.2.8

5.1 Systemkomponenten

5.1.1 Hardware 3D-RDM mobile

Die für die photogrammetrische Rekonstruktion von Innenraumszenen verwendete Hardware entspricht im Wesentlichen dem in Kapitel 3 bereits vorgestellten Systemaufbau. Der Aufbau wurde um eine Digitalkamera erweitert, die in einem gesonderten Gehäuse untergebracht ist (Abbildung 5.2). Die Kamera ist unter einem vertikalen Anstellwinkel von $\sim 12^\circ$ angebracht, um die geringe Aufnahmehöhe zu berücksichtigen.

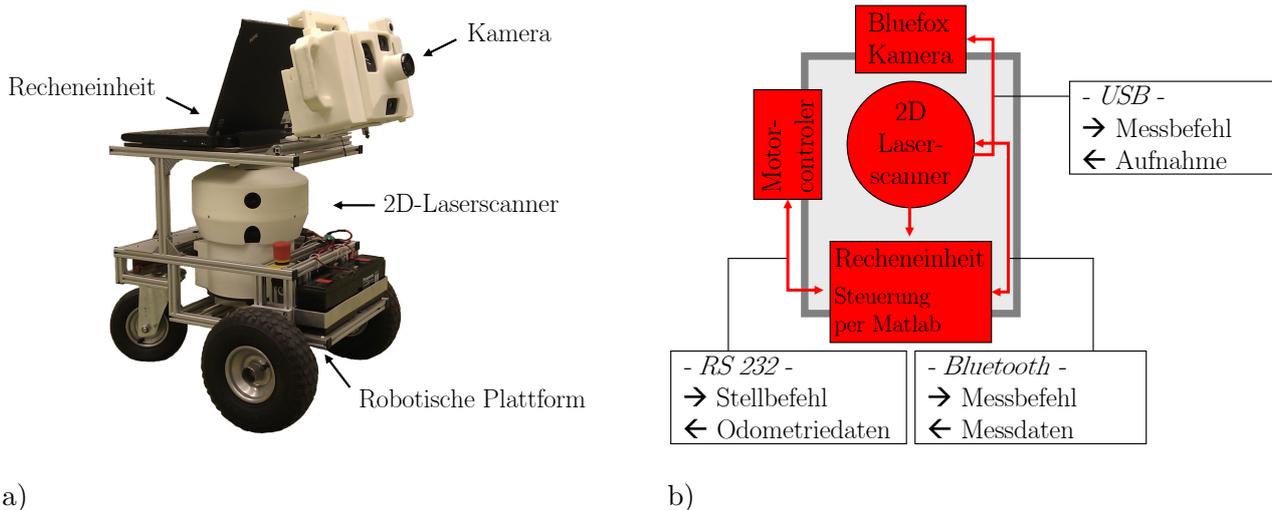


Abb. 5.2: Hardwareaufbau 3D-RDM mobile

- a) Bild des 3D-RDM mobile
b) Vernetzung der Hardwarekomponenten

Spezifikation der Kamera	
Bezeichnung:	mvBLUEFOX-205
Pixelgröße:	2.2 μm
Sensorgöße:	2592 \times 1944
Öffnungswinkel:	hor.: $\sim 80^\circ$ vert.: $\sim 65^\circ$
Sensortyp:	CMOS
Farbe/SW:	Farbe
Objektiv:	Pentax Cosmicar TV Lens 4.2 mm

Kamerakalibrierung

Für eine korrekte photogrammetrische Modellierung gemäß der Kollinearitätsgleichungen müssen die interne Geometrie der Kamera als auch deren Verzeichnungsfehler bekannt sein (vgl. Anhang A.4.2). Die entsprechenden Verzeichnungsparameter dx' und dy' sowie die intrinsischen Kameraparameter m_h , n_h und c werden ihm Rahmen einer Kalibrierung ermittelt. Dafür wurde die *Matlab Calibration Toolbox* verwendet [10]. Da sich die Kameraparameter aufgrund von Umwelteinflüssen zeitlich ändern können, wurde die Kamera vor Beginn der Messungen jeweils neu kalibriert. Einer der verwendeten Parametersätze ist in Anhang A.14 abgebildet.

5.1.2 Rekonstruktionsmodul

Folgender Abschnitt beschreibt das in dieser Arbeit verwendete Modul zur photogrammetrischen 3D-Rekonstruktion einer Szene anhand eines Aufnahmeverbandes. Abbildung 5.3 gibt zunächst einen

Überlick über den Rekonstruktionsablauf.

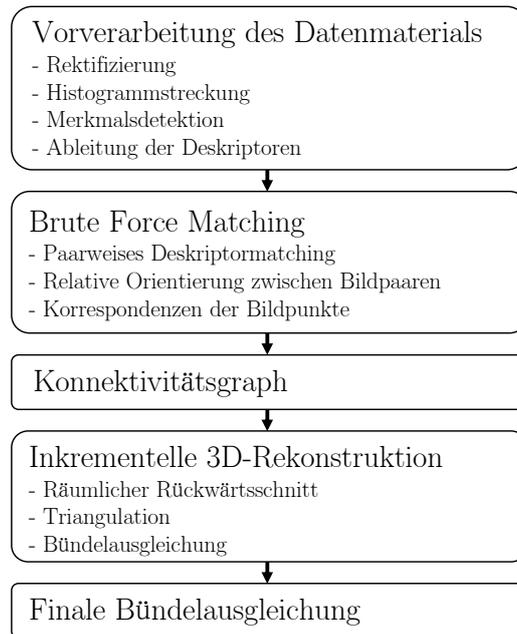


Abb. 5.3: Ablauf der photogrammetrischen Rekonstruktion im Rekonstruktionsmodul

Rektifizierung

Die im Rahmen der Kamerakalibrierung ermittelten Parameter gehen als Eingangsgrößen in das Modul ein. Anhand dieser wird ein „Look up Table“ mit den Korrekturwerten für die einzelnen Pixel erzeugt, durch die wiederum jede Aufnahme mittels bilinearer Interpolation rektifiziert wird (Abbildung 5.4). Zusätzlich erfolgt eine Histogrammstreckung sowie eine Bildaufhellung [46], um die anschließende Merkmalsdetektion zu verbessern.

Detektion von Umgebungsmerkmalen

Um eindeutige Merkmalspunkte in den Aufnahmen zu finden und anhand von Deskriptoren zu beschreiben, wird das SIFT-Verfahren eingesetzt (siehe Anhang A.5). Die paarweise Zurodnung von Merkmalen erfolgt über eine BBF-Suche [4]. Die euklidische Distanz zwischen den Deskriptoren führt zu einem Übereinstimmungsmaß, über das sich die Merkmalspunkte zuordnen lassen.

Relative Kameraorientierungen

Zunächst werden über einen Brute-Force Ansatz Bildpaare gesucht, die dieselben Umgebungspunkte beobachten und folglich über korrespondierende Bildpunkte verfügen. Somit werden bei n Aufnahmen $n(n-1)/2$ potentielle Bildpaare untersucht. Die Berechnung der relativen Orientierungen (R, T) zwischen den Kameraposen $O' \rightarrow O''$ erfolgt anhand der ermittelten Korrespondenzen über den direkten 5-Punkt-Algorithmus nach Nister [85] (Abbildung 5.5).

Um die Orientierungsschätzung robuster gegenüber fehlerhaften Punktzuordnungen zu machen, wurde dem 5-Punkt-Algorithmus ein RANSAC-Verfahren [25] hinzugefügt. Zudem kann anhand der relativen Orientierungen die Epipolarometrie eines Bildpaares ermittelt werden, wodurch sich wiederum Konsistenzprüfungen¹ durchführen lassen. Für jedes geometrisch konsistente Bildpaar wird ein Zuord-

¹Betrachtung der Epipolarlinienabstände zugeordneter Punkte

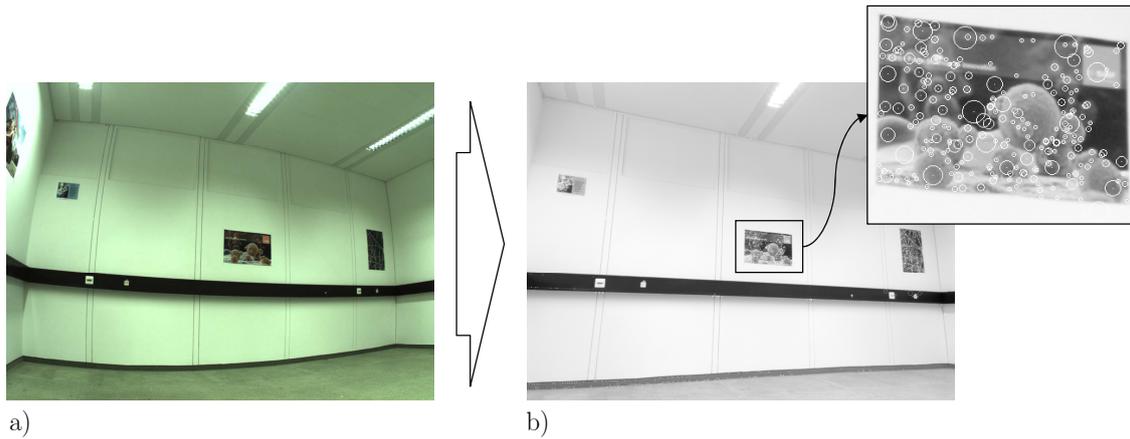


Abb. 5.4: Vorverarbeitung des Datenmaterials

a) Unbearbeitete Farbaufnahme

b) Detektion von Umgebungsmerkmalen (kreisförmig) nach Rektifizierung und Histogrammstreckung

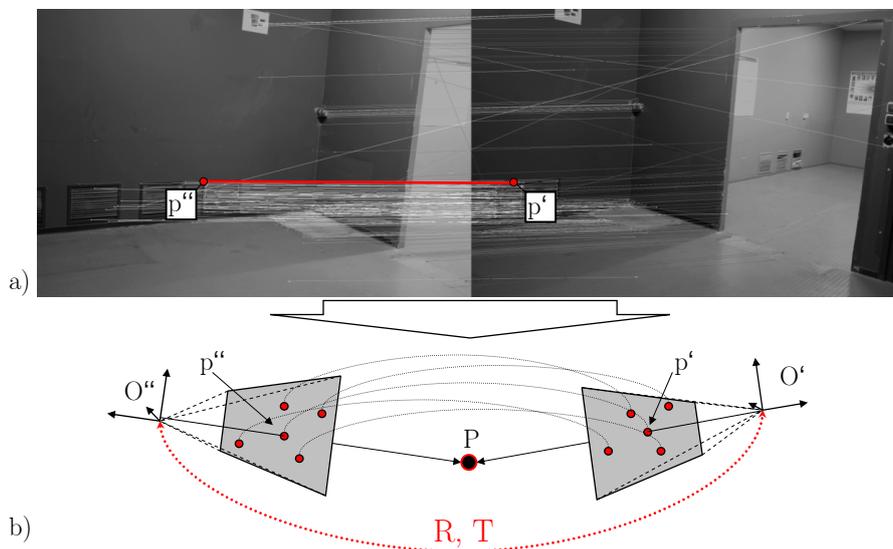


Abb. 5.5: Bestimmung der relativen Orientierungen (R, T) zwischen jeweils zwei Kameraposen anhand von Punktkorrespondenzen $p' \rightarrow p''$

a) Ableitung potentieller Korrespondenzen eines Aufnahmepaares über SIFT-Deskriptoren

b) Bestimmung der relativen Orientierung anhand des Algorithmus nach Nister [85]

nungsqualitätsmaß Z abgeleitet über:

- den globalen Epipolarfehler
- den globalen Reprojektionsfehler²
- die Differenz in der Aufnahmerichtung bzw. die Größe der Aufnahmebasis³

Inkrementelle 3D-Rekonstruktion

Für jedes Bildpaar werden die Qualitätsmaße sowie die Indizes der zugeordneten Punkte in einer Datenstruktur gespeichert. Aus dieser wird ein sogenannter Konnektivitätsgraph abgeleitet, der die Anzahl der Aufnahmen verzeichnet, mit denen jede Aufnahme verknüpft ist, sowie die Anzahl der

²Euklidischer Abstand zwischen der gemessenen 2D-Bildkoordinate und der Projektion des zugehörigen 3D-Objektpunktes in der Bildebene

³engl.: *Apical angle* vgl. [104]

Punktzuordnungen zur entsprechenden Aufnahme (Abbildung 5.6). Durch die Verfolgung zugeordneter Merkmale über mehrere Aufnahmen hinweg, kann zusätzlich über den Graphen ermittelt werden, wieviele weitere Aufnahmen sich im Anschluss an die Verwendung einer bestimmten Aufnahme einbinden ließen. Mittels dieser Größen kann bei jedem Schritt der inkrementellen Erweiterung des Bildverbandes die „vielversprechendste“ Aufnahme ermittelt und verwendet werden. So ergibt sich eine Rekonstruktionsabfolge, wie sie in Abbildung 5.6 beispielhaft dargestellt ist.

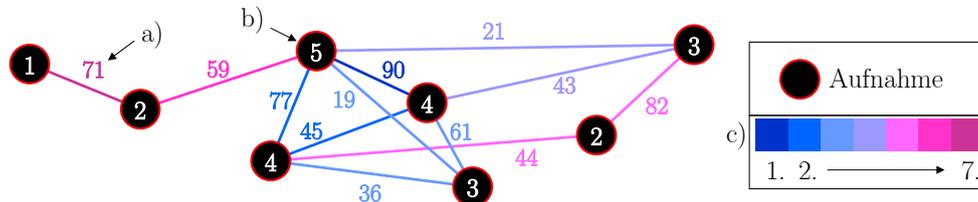


Abb. 5.6: Ableitung der inkrementellen Rekonstruktionsreihenfolge anhand eines Konnektivitätsgraphen

a) Anzahl der Punktkorrespondenzen

b) Anzahl der Aufnahmen zu denen Verbindungen in Form von Punktkorrespondenzen bestehen

c) Reihenfolge der inkrementellen Rekonstruktion

Im Verlauf der Rekonstruktion wird zunächst das Bildpaar mit maximalem Z herangezogen, um mit diesem eine relative 2-Bild-Triangulation [27] zur 3D-Rekonstruktion (unskaliert) der zugeordneten Punkte sowie eine 2-Bild-Bündelausgleichung zur Optimierung zu rechnen. Bei der Einbindung weiterer Aufnahmen wird zuerst deren 3D-Pose über einen räumlichen Rückwärtsschnitt anhand des ePnP-Verfahrens [78] ermittelt. Die Bestimmung der dazugewonnenen Objektpunktkoordinaten erfolgt über eine lineare n -Bild-Triangulation [43] mit anschließender nicht-linearer Optimierung. Dieser Prozess wird iteriert, bis die Anzahl der einbezogenen 3D-Punkte konvergiert. Bei jeder Iteration kann es sein, dass weitere, bereits rekonstruierte 3D-Punkte aufgrund eines ausreichend geringen Reprojektionsfehlers in den räumlichen Rückwärtsschnitt mit einbezogen werden und diesen zusätzlich präzisieren. Für eine weitere Optimierung wird zudem bereits nach der Einbindung jeder Aufnahme eine globale Bündelausgleichung der bis dato rekonstruierten Parameter gerechnet.

Bündelausgleichung und geometrische Ausreißerdetektion

Zur Optimierung der Parameter wird nach der 3D-Triangulation aller Umgebungsmerkmale abschließend eine iterative Ausgleichung unter der Vorgabe gerechnet, den globalen Reprojektionsfehler der Objektpunkte nach L2-Norm zu minimieren. Die Ausgleichung erfolgt in einem Gauß-Markoff-Modell (vgl. Anhang A.4).

Fehlerhafte Punktzuordnungen können sich nachteilig auf den Bündelausgleich auswirken, so dass dieser in einem lokalen Minimum konvergiert bzw. gänzlich divergiert. Dieses Risiko wird mit der Durchführung der folgenden einfachen geometrischen Ausreißertests im Vorfeld der Ausgleichung gemindert:

- Schnittgeometrie: Entfernen von Punkten, die durch schlecht konditionierte Schnittbedingungen (schleifende Schnitte) rekonstruiert wurden
- Reprojektionsfehler: Entfernen von Punkten mit zu großem Reprojektionsfehler
- Ausrichtung der Punkte: Entfernen von Punkten, die hinter der zugehörigen Kamera liegen
- Entfernung zu den Punkten: Entfernen von Punkten, die im Vergleich zu allen anderen Punkten eine sehr große Distanz zur Kamerapose aufweisen

Nach erfolgter Rekonstruktion liegen die geschätzten Parameter der Kameraposen sowie der Objektpunktkoordinaten zuzüglich der geschätzten Genauigkeiten vor.

5.2 Photogrammetrische Positionierungsstrategie

Abschnitt 5.2 befasst sich mit der Planung von Kamerastandpunkten zur photogrammetrischen 3D-Rekonstruktion von Innenräumen. Das Messsystem soll mit der Kamera von einzelnen Standpunkten aus Aufnahmen der zu vermessenden Innenraumszene machen. Damit eine 3D-Rekonstruktion der Umgebung durch einen Bündelausgleich erfolgen kann, werden aus den Aufnahmen Merkmale extrahiert und einander zugeordnet. Um einen Bündelausgleich erfolgreich durchführen zu können, müssen die Aufnahmen, bzw. die dazu gewählten Posen eine Reihe von Restriktionen erfüllen, die in der Planung zu berücksichtigen sind. Bei der Wahl der Posen sollte ein optimaler Kompromiss zwischen der Genauigkeit der resultierenden Punktwolke und der Anzahl der Kameraposen, also der Effizienz des Systems gefunden werden.

Eine Hauptschwierigkeit bei der Entwicklung einer Messstrategie bildet die kombinatorische Vielfalt, die die zunächst beliebige Wahl von Kameraposen zulässt. Reine Brute-Force Methoden zur Wahl der jeweils Besten aus der Menge aller möglichen Posen können aufgrund des viel zu hohen Rechenaufwandes nicht eingesetzt werden. Auch eine analytische Bestimmung ist nicht zielführend, da es keine „beste“ Kamerapose gibt. Auch sehr unterschiedliche Messkonstellationen können zu vergleichbaren Ergebnissen führen.

Aufgabe des Systems ist die Erfassung von Innenräumen, also ebenen Umgebungen, mit vielen geraden Elementen, senkrechten Wänden und oftmals konstanter Raumhöhe. Die Kamera ist auf der Plattform fest installiert. Somit sind deren Roll- und Nickwinkel konstant. Diese Rahmenbedingungen erlauben es das Planungsproblem auf den \mathbb{R}^2 zu reduzieren ohne dabei einen wesentlichen Verlust an planerischen Möglichkeiten hinnehmen zu müssen. Die Anzahl der Freiheitsgrade einer Kamerapose reduziert sich dagegen von 6 $(x, y, z, \omega, \phi, \kappa)$ auf 3 (x, y, ϕ) , womit eine wesentliche Reduktion der kombinatorischen Möglichkeiten verbunden ist.

Dies motivierte zur Entwicklung einer 2D-basierten Planungsstrategie, in der zur Erfassung eines bestimmten Raumbereichs iterativ pseudozufällige Posekandidaten erstellt und evaluiert werden. In Abschnitt 5.2.2 wird erläutert, wie die durch die 2D-Vermessung gegebenen Daten aufbereitet werden, um als Planungsgrundlage genutzt werden zu können. Sowohl die Erzeugung als auch die Evaluation der Posekandidaten erfolgt unter Berücksichtigung der in Abschnitt 5.2.1 definierten Restriktionen sowie einer theoretischen Betrachtung der Genauigkeit, erläutert in Abschnitt 5.2.3, mit der sich der entsprechende Raumbereich erfassen ließe. Für eine a priori Abschätzung der erreichbaren Genauigkeiten sowie einer optimalen Auslegung der Strategieparameter wurden anhand synthetischer Daten diverse Versuche durchgeführt, die wiederum in Kapitel 6 erläutert werden.

5.2.1 Restriktionen

In Kapitel 2.4.1 wurden bereits allgemeine Restriktionen zur Platzierung von Sensoren in der Nahbereichsphotogrammetrie erörtert. Diese sollen nun entsprechend der vorliegenden Applikation angepasst und um weitere Restriktionen ergänzt werden:

- *Kamera:*

Die Öffnungswinkel beschränken die Wahl möglicher Aufnahmestandorte. Da die Kamera fest

auf der Plattform angebracht ist, muss ein Mindestabstand gewahrt werden, um eine vollständige Erfassung der Umgebungsoberflächen in vertikaler Richtung zu ermöglichen. Auch der horizontale Öffnungswinkel muss bei der Wahl der Posen berücksichtigt werden. Über diesen lassen sich die horizontalen Überlappungen der Aufnahmen a priori ermitteln.

Der Schärfentiefebereich der Kamera führt zu Einschränkungen bezüglich des Aufnahmeabstands. Merkmalspunkte außerhalb dieses Bereichs lassen sich nicht korrekt extrahieren.

- *Bündelausgleich:*

Die 3D-Koordinaten der Merkmalspunkte werden in einem Bündelausgleich gemeinsam bestimmt. Da im Bündelausgleich nur mehrfach erfasste Merkmalspunkte rekonstruiert werden können, bildet deren redundante Erfassung eine Anforderung an die Bewegungsstrategie. Um alle Punkte in einem gemeinsamen Koordinatensystem registrieren zu können, darf der Bildverband keine Subkonfigurationen aufweisen. Entsprechend muss gewährleistet sein, dass sich alle Aufnahmen ausreichend überlappen und somit direkt oder indirekte Aufnahme- bzw. Punktverknüpfungen über den gesamten Bildverband möglich sind. Auch das Auftreten geringer Überlappungsbereiche erhöht die Wahrscheinlichkeit, dass ein einzelner globaler Bündelausgleich fehlschlägt.

- *Schnittwinkel von Bildstrahlen:*

Die Güte der photogrammetrischen Punktreakonstruktion durch den Schnitt von Bildstrahlen im Objektpunkt ist abhängig von der Geometrie der Triangulation. Die Länge der Strahlen sowie deren Schnittwinkel beeinflussen die Genauigkeit mit der der entsprechende Objektpunkt bestimmt werden kann. So ermöglichen z.B. Strahlschnittwinkel von 90° bzw. 60° bei zwei bzw. drei Strahlen die theoretisch höchste Genauigkeit.

- *Merkmalserkennung:*

Für die Detektion von Merkmalspunkten wird der SIFT-Operator verwendet, da dieser eine weitgehend rotationsinvariante Wiedererkennung von Punkten verspricht. Die Wahrscheinlichkeit korrekter Punktzuordnungen sinkt jedoch auch hier mit zunehmender Veränderung des Betrachtungswinkels. Abhängig von Form und Texturierung der abgebildeten Umgebung können bereits Variationen des Aufnahmewinkels von weniger als 10° zu einer wesentlichen Verminderung korrekter Punktzuordnungen führen (vgl. Anhang A.5).

Diese Restriktion steht im Gegensatz zu den photogrammetrischen Schnittbedingungen, die eine große Basis zwischen den Aufnahmen erwarten. Wie in Abbildung 5.7 illustriert, ist es prinzipiell möglich Aufnahmekonfigurationen zu generieren, die große Schnittwinkel im Objekt aufweisen, obwohl der Betrachtungswinkel also die Aufnahmerichtung weitestgehend konstant bleibt. Eine solche Konstellation läßt sich jedoch nicht für alle Umgebungsbereiche bewerkstelligen. Entsprechend muss bei der Wahl der Kameraposen ein Kompromiss getroffen werden.

Auch die Variation der Aufnahmeentfernung hat einen, wenn auch geringeren Einfluss auf die Wiedererkennungsrate von Merkmalspunkten.

- *Flache Winkel:*

Flache Aufnahmewinkel gegenüber der Objektoberflächennormalen sollten vermieden werden. Da sich dadurch das Intervall der Objekte bezüglich der Kamera erhöht, wird die skaleninvariante Wiedererkennung erschwert. Zudem können flache Aufnahmewinkel zu größeren

Variationen des Betrachtungswinkels führen und somit die rotationsinvariante Wiedererkennung erschweren.

5.2.2 Präparation gegebener Daten

Die im Zuge der 2D-Vermessung erstellte Punktwolke sowie das zugehörige Belegtheitsgitter werden in der Planungsstrategie als bekannt vorausgesetzt. Im Vorfeld erfolgt eine Aufbereitung dieser Daten. Wenn nicht bereits durch die 2D-Exploration gegeben, werden aus der Punktwolke Liniensegmente abgeleitet und in n Stücke gleicher Länge unterteilt. Dazu werden die Abstände aufeinanderfolgender Messpunkte aufsummiert, bis eine gegebene Länge L_{disk} erreicht ist. Diese Punktgruppen werden im Folgenden als Umgebungselemente E_n bezeichnet.

Im Verlauf der 2D-Exploration wurden die Positionen, von denen jeder Messpunkt aus erfasst wurde, gespeichert. Diese Information wird nun genutzt, um für alle E den projektiven Normalenvektor \vec{N}_n bezüglich einer Regressionsgeraden zu bestimmen (Abbildung 5.8). Dieser gibt die Richtung an, aus der sich ein Umgebungselement orthonormal erfassen lässt.

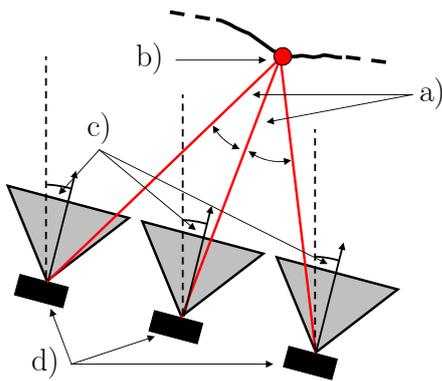


Abb. 5.7: Optimale Erfassung eines Objektpunktes mit hohem Schnittwinkel α bei konstanter Kameraorientierung ϕ

- a) Schnittwinkel α
- b) Objektpunkt
- c) Kameraorientierungen ϕ
- d) Kameraposen

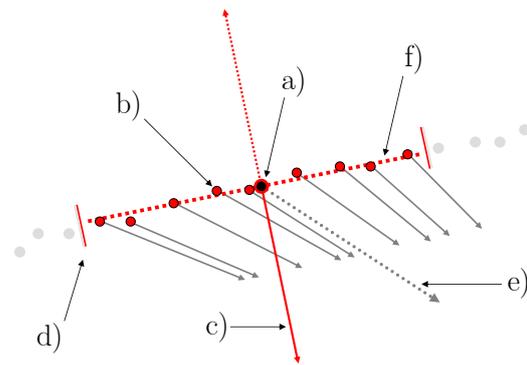


Abb. 5.8: Definition des projektiven Normalenvektors \vec{N}_n eines Umgebungselementes E_n

- a) Elementschwerpunkt
- b) Messpunkt
- c) Projektiver Normalenvektor \vec{N}
- d) Elementgrenze
- e) Mittlere Erfassungsrichtung
- f) Ausgleichsgerade

Der nächste Schritt besteht darin, für jedes E_n die Menge $CE_n = \{C_{i,j}\}$ der Zellen im Belegtheitsgitter zu ermitteln, von denen aus E_n erfasst werden kann. Die Auswahl der Gitterzellen basiert auf den Restriktionen aus Abschnitt 5.2.1. Ein Element E_n kann dann von einer Gitterzelle aus erfasst werden, wenn diese innerhalb eines minimalen und maximalen Aufnahmeabstandes liegt, einen bestimmten Winkel gegenüber \vec{N}_n aufweist, im Belegtheitsgitter als befahrbar klassifiziert ist und zudem eine ungehinderte Sichtverbindung zwischen dem Elementschwerpunkt und der Gitterzelle besteht. Abbildung 5.9 zeigt in einer synthetisch erzeugten Beispielumgebung die Menge der Zellen CE_n für ein zufällig gewähltes Element E_n . Die Anzahl CA_n der Zellen sowie deren Winkelverteilung Φ_n erlauben eine Einschätzung über die generelle Sichtbarkeit eines Elements. Beide Werte sind bei der Wahl der Kameraposen relevant, da zwischen diesen für eine genaue Rekonstruktion eine ausreichend große Basis geschaffen werden muss. Um die *Erfassbarkeit* EB_n jedes Elementes E_n zu beschreiben,

ergibt sich so ein einzelner und aussagekräftiger Wert über:

$$EB_n = \frac{\Phi_n}{\sum \Phi} + \frac{CA_n}{\sum CA} \quad (5.1)$$

Elemente, die in einer Raumecke liegen, weisen einen relativ geringen EB Wert auf. Die geringere Menge an Wahlmöglichkeiten erschwert hier die Suche nach passenden Kameraposen. Abbildung 5.10 zeigt die ermittelten Winkelintervalle aller Elemente der Beispielumgebung. Zu erkennen ist die Aussagekraft des Winkelintervalls hinsichtlich darauf, für welche Umgebungsbereiche es einfach ist passende Kameraposen zu ermitteln und für welche Bereiche dies nicht der Fall ist.

Die Menge CE_n ist für jedes E_n ableitbar. Daraus läßt sich umgekehrt für jede Gitterzelle die Menge EC_n der von dort aus erfassbaren Elemente ermitteln. Beide Informationen bilden die Grundlage für die folgende Positionierungsstrategie.

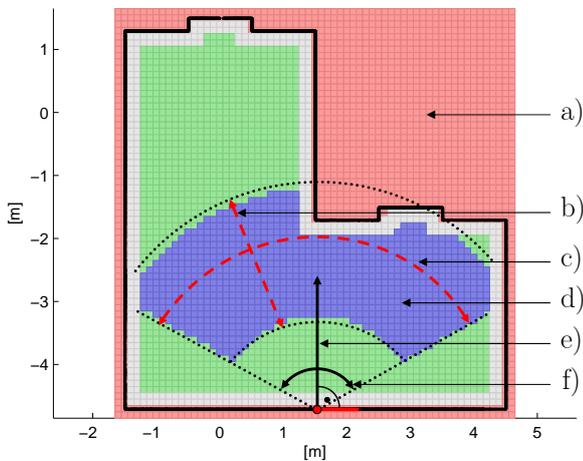


Abb. 5.9: Auswahl von Gitterzellen zur Erfassung eines Umgebungselementes E
a) Belegtheitsgitter
b) $[AA_{min}; AA_{max}]$: Begrenzung des Aufnahmeabstands
c) Winkelverteilung Φ der sichtbaren Zellen
d) CE
e) \vec{N}
f) AW : Begrenzung des Aufnahmewinkels bzgl. \vec{N}

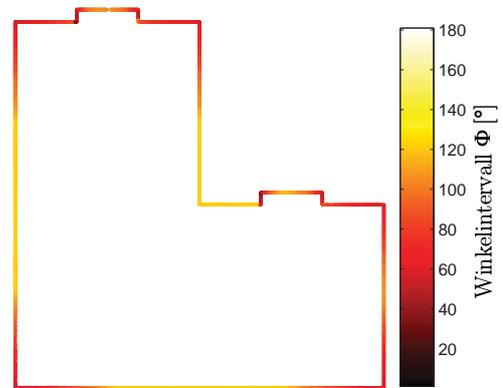


Abb. 5.10: Abhängig von der Größe des Winkelintervalls Φ farblich kodierte Darstellung der Umgebung

5.2.3 A priori Genauigkeitsbetrachtung

Der wichtigste Aspekt bei der Planung der Kameraposen ist die resultierende Genauigkeit der Objektpunkte. Daher sollte versucht werden die Genauigkeit, die durch die Wahl einer bestimmten Messkonstellation erzielt wird, a priori zu schätzen und in die Planung mit einfließen zu lassen.

Im realen Messvorgang resultiert die Genauigkeit der Objektpunkte sowie der Kameraposen aus der Bündelausgleichung. Folglich muss für eine a priori Genauigkeitsbetrachtung in der Positionierungsstrategie das funktionale Modell des Bündelausgleichs auf den 2D-Fall reduziert werden. Dies ist im Rahmen der Ausgleichsrechnung möglich, indem der Bündelausgleich im \mathbb{R}^2 als Richtungsnetz dargestellt wird. Die dazu notwendigen Schritte werden im Folgenden erläutert. Abbildung 5.11 stellt zunächst die Zusammenhänge des funktionalen Modells im 2D-Fall dar.

Unbekannte Parameter

Im Bündelausgleich werden Kameraposen und Objektpunktkoordinaten gemeinsam geschätzt. Dies

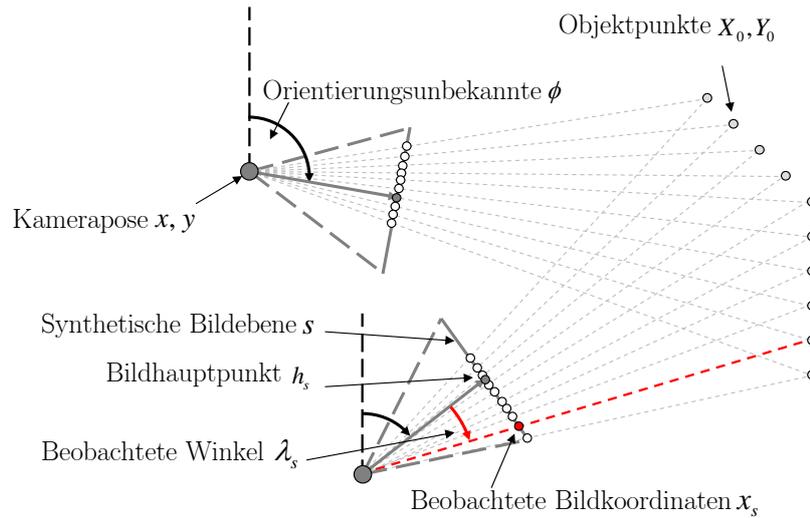


Abb. 5.11: Modellierung der Aufnahmekonfiguration als Richtungswinkelnetz

soll auch hier der Fall sein. So werden die 2D-Koordinaten der Elementschwerpunkte dem Vektor der zu schätzenden Unbekannten beigelegt. Damit entspricht jeweils ein Elementschwerpunkt in der theoretischen Betrachtung einem Merkmalspunkt der realen Umgebung. Die drei Parameter x , y und ϕ einer Kamerapose im \mathbb{R}^2 sind zu schätzende Parameter.

Beobachtungen

Den gemessenen Bildkoordinaten x_{3D} , y_{3D} im 3D-Fall steht im \mathbb{R}^2 jeweils nur eine einzelne Bildkoordinate x_s gegenüber. Die Koordinaten x_s entstehen durch den Schnitt der Verbindungsstrahlen zwischen den Kameraposen und den Objektpunkten mit der synthetischen Bildebene s , welche wiederum orthogonal zur Kamerahaupttrichtung ausgerichtet ist (Abbildung 5.11). Im Zuge der Ausgleichung werden diese nicht verwendet. Als Beobachtungen fungieren die Winkel λ_s der Bildstrahlen relativ zur Richtung des Hauptstrahls, also der Ausrichtung ϕ der Kamera.

Genauigkeit der Beobachtungen

Auch das a priori bekannte Wissen bezüglich der Genauigkeit der Beobachtungen muss auf das 2D-Modell übertragen werden. Ausgangswert im 3D ist die Pixelgenauigkeit σ_{x_s} , mit der ein Merkmalspunkt in den Bilddaten bestimmt werden kann. Dieser muss auf die Winkelmessung übertragen werden. Der Zusammenhang zwischen Winkel- und Bildmessung ist:

$$\tan(\lambda_s) = \frac{x_s}{c} \rightarrow \lambda_s = \operatorname{atan}\left(\frac{x_s}{c}\right) \quad (5.2)$$

wobei mit c die Kammerkonstante der Kamera gemeint ist.

Nach den Regeln der Fehlerfortpflanzung (vgl. [48]) ergibt sich für die Ableitung der Winkelgenauigkeit σ_λ folgende Formel, die entsprechend aufzulösen ist:

$$\left(\frac{\sigma_\lambda}{\rho}\right)^2 = \left(\frac{\delta f}{\delta c}\right)^2 \cdot \sigma_c^2 + \left(\frac{\delta f}{\delta x_s}\right)^2 \cdot \sigma_{x_s}^2 \quad (5.3)$$

mit $\rho = \frac{\pi}{180}$ und:

$$\begin{aligned}\frac{\delta f}{\delta c} &= \frac{1}{1 + \left(\frac{x_s}{c}\right)^2} \frac{x_s}{-c^2} = \frac{-x_s}{c^2 + x_s^2} \\ \frac{\delta f}{\delta x_s} &= \frac{1}{1 + \left(\frac{x_s}{c}\right)^2} \frac{1}{c} = \frac{c}{c^2 + x_s^2}\end{aligned}\quad (5.4)$$

Für die Genauigkeit der SIFT-Merkmalbestimmung wurde hier ein Wert von $\sigma_{x_s} = 1$ Pixel angenommen (vgl. Abbildung 6.8). Größe und Genauigkeit der Kammerkonstante ergeben sich aus dem Kalibriervorgang (siehe Abschnitt 5.1.1). Für die verwendete Kamera ergab sich eine Größe von $c = 1984.5911$ Pixeln, bestimmt mit einer Genauigkeit von $\sigma_c = 1.701$ Pixeln. Mit der Kenntnis der Pixelgröße des Kamerachips⁴ lassen sich die Werte in ein metrisches Maß umrechnen. Die dabei entstehende Fehlerfunktion zeigt Abbildung 5.12.

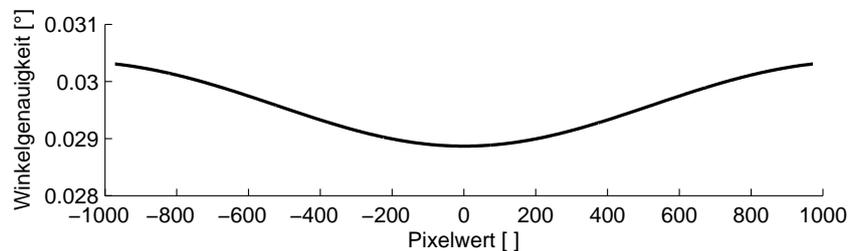


Abb. 5.12: Winkelmessgenauigkeit in Abhängigkeit von der Pixelposition im Fall der kalibrierten Kamera. Genauigkeitsreduktion von der Bildmitte zu den Bildrändern.

Die Genauigkeit der Winkelbeobachtungen ist somit abhängig vom Pixelwert, also dem Abschnitt des Strahlschnittpunktes vom Hauptstrahl. Die Genauigkeit jedes Messwertes muss also an der Fehlerfunktion abgegriffen und in der Ausgleichung individuell berücksichtigt werden.

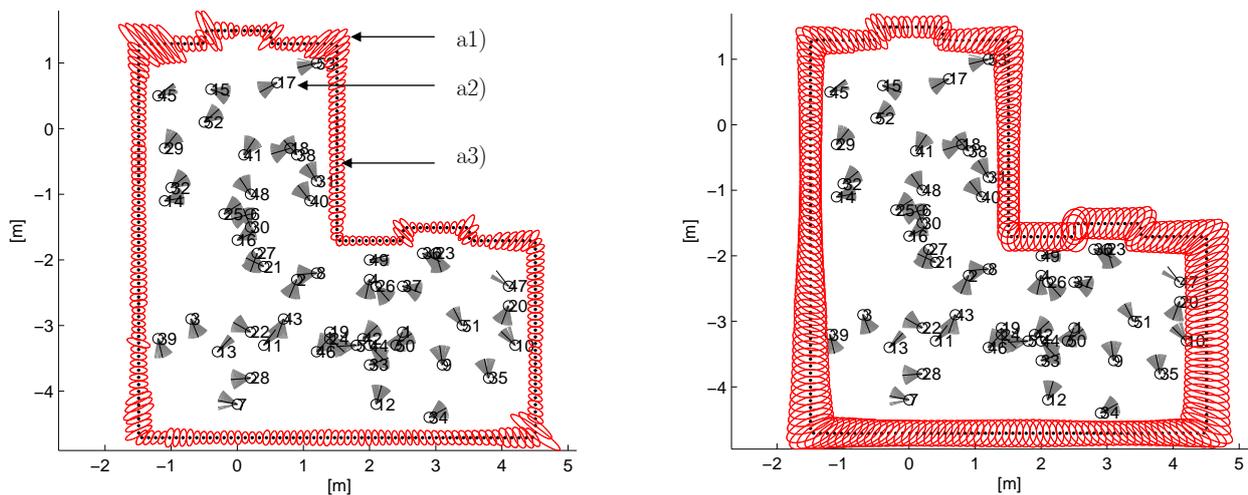
Datumsdefekt und Fehlerellipsen

Werden die Kameraposen als auch die Objektpunkte als unbekannte Parameter betrachtet, besitzt das auszugleichende Netz einen Datumsdefekt (vgl. [83]). Das aufgestellte Gleichungssystem weist einen entsprechenden Rangdefekt auf. Im Fall des 2D-Richtungsnetzes verbleiben 4 Freiheitsgrade (2 Translationen, 1 Rotation, 1 Maßstab). Eine Behebung des Datumsdefektes kann auf unterschiedlichen Wegen erfolgen. Im Hinblick auf die Beurteilung der Genauigkeiten ist zu beachten, dass die Form der resultierenden Fehlerellipsen „extrem von der Datumsverfügung im Netz abhängt“ [83]. Eine Fehler- bzw. Genauigkeitsanalyse kann also nur unter Berücksichtigung der Datumsverfügung vollzogen werden. Eine Möglichkeit ist es eine den Freiheitsgraden entsprechende Anzahl unbekannter Parameter festzuhalten. Diese minimale Datumsverfügung führt zu einer Akkumulation der Fehler mit zunehmender Distanz zu den datumsgebenden Parametern. Schwachstellen im Netz sind durch ein starkes Anwachsen der Fehlerellipsen in den entsprechenden Bereichen erkennbar. Auch in der Bündelausgleichung wird diese minimale Datumsverfügung durchgeführt. Festgehalten werden dabei 6 Parameter einer Pose sowie eine Koordinate einer weiteren Pose.

Demgegenüber besteht die Möglichkeit alle Kameraparameter festzuhalten und allein die Koordinaten der Objektpunkte zu schätzen. Eine Betrachtung der Fehlerfortpflanzung ist durch diese Variante

⁴hier: $5 \cdot 10^{-6}$ m

nicht möglich. Was sich mit dieser Ausgleichungsvariante überprüfen läßt, ist die Form einzelner Fehlerellipsen. Es kann festgestellt werden, inwieweit z.B. eine Erhöhung der Redundanz, und damit in der Regel eine Verbesserung der Schnittbedingungen, eine verbesserte Verteilung der Fehler bewirkt. Eine weitere Möglichkeit bildet die sogenannte Teil- bzw. Gesamtpurminimierung (vgl. Anhang A.4.3). Dabei wird das Netz frei und gleichmäßig auf einem Teil oder auf allen unbekanntem Parametern gelagert. Die entstehenden Fehler verteilen sich ebenso gleichmäßig. Statt des Festhaltens von Parametern wird hier der Datumsdefekt behoben, indem zusätzliche Bedingungen in die Ausgleichung eingebracht werden. Diese werden als Gleichungen formuliert und zusätzlich zu den Beobachtungsgleichungen in die Designmatrix A der Ausgleichung eingefügt (siehe Anhang A.6). Diese Vorgehensweise hat den Vorteil, dass die „Genauigkeit und Zuverlässigkeit des neu bestimmten Netzteils jetzt unabhängig von eventuell vorhandenen Netzspannungen beurteilt und überprüft werden kann“ [83]. Ein Vergleich zwischen den Ausprägungen der Fehlerellipsen bei den beiden genutzten Ausgleichungsansätzen findet sich in den Abbildungen 5.13a und 5.13b. Bei einem Festhalten aller Kameraposen können Form und Größe benachbarter Fehlerellipsen stark variieren, da deren Betrachtung ausschließlich lokal erfolgt. Durch die Gesamtpurminimierung ergibt sich dagegen eine homogenere Ausprägung der Fehlerellipsen, so dass sich Änderungen vorzugsweise auf ganze Umgebungsbereiche beziehen.



a) Fehlerellipsen bei Datumsfestelegung:
Alle Kameraposen

b) Fehlerellipsen bei Datumsfestelegung:
Gesamtpurminimierung

Abb. 5.13: Darstellung der Testumgebung samt der aus den in der Evaluierung verwendeten Ausgleichungsansätze resultierenden Fehlerellipsen. Die Fehlerellipsen sind aus Anschauungsgründen in Übergröße abgebildet.

- a1) Fehlerellipsen
- a2) Kamerapose und Sichtverbindungen zu Objektpunkten
- a3) Objektpunkte

Zur fehlertheoretischen Beurteilung der Planungsstrategie wurde zum Einen die Gesamtpurminimierung eingesetzt. Zusätzlich erfolgte eine lokale Netzbetrachtung bei der alle Kameraposen als bekannt angenommen und allein die Objektpunktkoordinaten geschätzt wurden. Ein Vergleich beider Ansätze wird in Kapitel 6.2.7 angestellt.

5.2.4 Strategie zur Wahl von Kameraposen

Dieser Abschnitt stellt eine Strategie zur Bestimmung eines Satzes von Kameraposen vor, durch die sich eine Innenraumszene so erfassen läßt, dass deren Rekonstruktion anhand eines Bündelausgleichs

möglich ist. Das primäre Ziel ist es mit der Wahl der Kameraposen alle zuvor definierten Umgebungselemente E redundant⁵ zu erfassen. Der generelle Ablauf sieht vor, ein noch nicht redundant erfasstes E aus der Menge aller Elemente zu wählen und für dieses einen Satz an Kameraposen zu bestimmen. Die Wahl der Posen erfolgt mit der Vorgabe das entsprechende Element unter Berücksichtigung der gegebenen Restriktionen redundant und hinsichtlich der resultierenden Genauigkeit möglichst optimal zu erfassen. Dieser Prozess wird iteriert, bis alle Elemente redundant erfasst worden sind. Abbildung 5.14 gibt einen Überblick über den Gesamtprozess der Algorithmik.

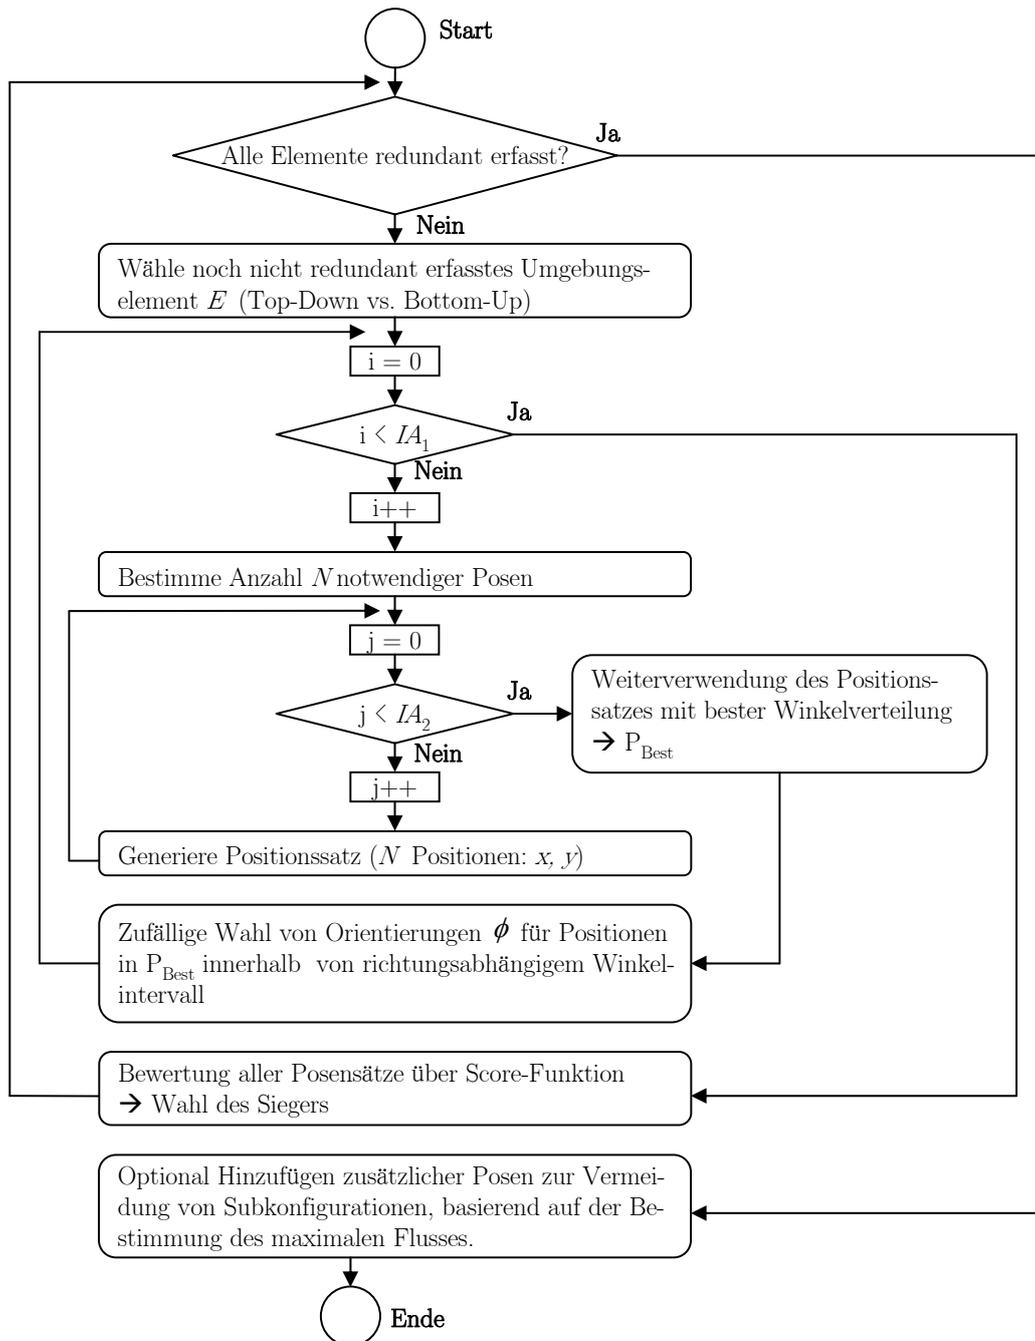


Abb. 5.14: Illustration des Ablaufs der Positionierungsstrategie

⁵Die Redundanz Red gibt die Anzahl der Aufnahmen vor, mit der jedes Element zu erfassen ist

Bottom-Up und Top-Down Ansatz

Für die Reihenfolge, in der die Elemente zu bearbeiten sind, wurden zwei Ansätze definiert und evaluiert. Der erste Ansatz wird als *Bottom-Up* Ansatz bezeichnet. Dieser gibt vor, aus der Menge der noch nicht redundant erfassten Elemente, das Element E_n mit der geringsten Erfassbarkeit EB_n zu wählen. Die Intention ist hier zunächst Kameraposen für die schwer zu erfassenden Oberflächenbereiche zu finden, um im Anschluss für die leichter einsehbaren Bereiche nur noch Ergänzungsaufnahmen suchen zu müssen.

Im Gegensatz dazu wird beim *Top-Down* Ansatz immer das Element mit dem größten EB_n gewählt. Dadurch ist zu erwarten, dass mit der Wahl der ersten Kameraposen bereits relativ große Oberflächenbereiche abgedeckt werden können. Die Schließung der Lücken am Ende, also der problematischeren Bereiche, könnte dagegen einen entsprechenden Mehraufwand bedeuten.

Wie in Kapitel 5.2.3 beschrieben, konnte dem *Top-Down* Ansatz anhand einer theoretischen Evaluierung ein höheres Leistungsvermögen bescheinigt werden. So wurde dieser Ansatz für die realen Messreihen verwendet.

Wahl der Kameraposen

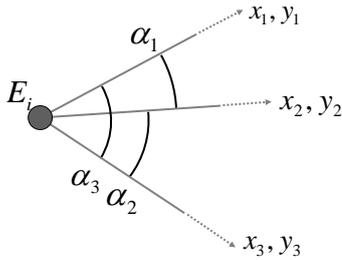
Ist ein Element gemäß eines der beschriebenen Ansätze gewählt, wird ein Satz an Kameraposen bestimmt, mit dem eine redundante Erfassung des Elements durchgeführt werden kann. Zunächst wird geprüft, ob das Element bereits durch andere Aufnahmen erfasst wurde. Die Anzahl der nun zu bestimmenden Posen entspricht der Differenz zwischen der Anzahl der für eine Redundanz nötigen und den bereits vorhandenen Kameraposen. Auch die bereits vorhandenen Posen werden in der neuen Bewertung berücksichtigt. Ist z.B. ein Element bei einer geforderten Redundanz von 4 bereits durch 2 Posen beobachtet, werden in jeder Iteration 2 weitere Posen pseudozufällig generiert, während in die Bewertung alle 4 Posen eingehen.

Für jedes Element wird eine feste Anzahl (IA_1 in Abbildung 5.14) potentieller Posensätze generiert. Diese werden anhand einer Kostenfunktion bewertet und verglichen, wobei der am besten bewertete Posensatz weiter verwendet wird:

Die Wahl der Posen erfolgt in mehreren Stufen, wobei die Position x, y vor der Orientierung ϕ gewählt wird.

1) Positionen x, y

Die Wahl der Positionen eines Elements E_n beschränkt sich auf die Mittelpunkte der CE_n . Zu Beginn jeder Iteration werden die Positionen des potentiellen Posensatzes festgelegt, indem eine feste Anzahl (IA_2 in Abbildung 5.14) an Zellmittelpunkten zufällig aus CE_n gewählt werden. Aus dieser Menge wird die Kombination weiter verwendet, welche die beste Winkelaufteilung in Bezug auf E_n aufweist. Bei einer guten Verteilung entstehen keine kleinen Schnittwinkel und damit schleifenden Schnitte der Sichtstrahlen im Elementschwerpunkt. Ein vergleichbarer Wert VT für die Güte der Verteilung lässt sich über Gleichung 5.5 berechnen.



$$VT = \sum_{i=1}^n \alpha_i \cdot 2^{(n-i+1)} \quad (5.5)$$

Abb. 5.15: Berechnung eines Vergleichswertes für die Winkelverteilung

2) Kameraorientierungen ϕ

Nach Festlegung der Position des potentiellen Posensatzes wird dieser um die Orientierungen ϕ ergänzt. Die Erzeugung der Orientierungen erfolgt zufällig, beschränkt sich jedoch auf einen definierten Winkelbereich. Dieser ist abhängig von der Position und dem horizontalen Kameraöffnungswinkel. Die Richtung des Hauptstrahls ϕ darf nicht mehr als den halben horizontalen Öffnungswinkel von der Richtung des Elementschwerpunkts bezüglich der zugehörigen Position x, y abweichen, da der Elementschwerpunkt ansonsten nicht mehr im Blickfeld der Kamera liegen würde.

Kostenfunktion

Sind alle Posensätze (entspr. IA_1) generiert, erfolgt eine vergleichende Bewertung anhand einer Kostenfunktion. Zur Menge der in der Planungsstrategie verwendeten Posen wird der Satz bzw. die neuen Posen des Satzes hinzugefügt, der die höchste Bewertung BW erhielt. Der Vergleichswert BW setzt sich aus mehreren Termen zusammen:

$$BW = f_1 \cdot V_{Sch} + f_2 \cdot V_{Anz} + f_3 \cdot V_{Red} + f_4 \cdot V_{Dis} + f_5 \cdot V_{Dif} \quad (5.6)$$

Erläuterung der Parameter:

V_{Sch} : Schnittbedingungen am aktuellen Element

Um die Erfassungsbedingungen am aktuellen Element, also den Schnitt der Sichtstrahlen im Elementschwerpunkt, zu evaluieren, wird die durch die Messkonstellation resultierende Helmertsche Fehlerellipse (vgl. Anhang A.15.3) bestimmt und deren Fläche berechnet. Es folgt eine Normierung der Fläche bezüglich der größten aller bestimmten Flächen. Die Berechnung der Fehlerellipse basiert auf der Durchführung einer Art Minimalausgleichung, bei der die Koordinaten des Elementpunktes die einzigen unbekannt Parameter bilden. Als Beobachtungen fungieren die Richtungswinkel der gewählten Kameraposen. Die Koordinaten der Posen selbst werden als bekannt vorausgesetzt.

V_{Anz} : Anzahl der durch die Posekandidaten insgesamt erfassten Elemente

Um die generelle Effizienz der Strategie zu steigern und ein Voranschreiten der Erfassung zu fördern, wird die Anzahl der weiteren Elemente, die durch die Posekandidaten erfasst werden, bewertet. Damit soll verhindert werden, dass in den Aufnahmen trotz der unterschiedlichen Positionen immer dieselbe Umgebungsoberfläche betrachtet wird. Denn dies würde die Wahrscheinlichkeit von Subkonfigurationen erhöhen (vgl. Abschnitt 5.2.1). Zudem soll verhindert werden, dass mit den Posekandidaten nur das aktuelle Element, aber keine weiteren Elemente erfasst werden. Auch hier erfolgt eine Normierung anhand der größten bestimmten Elementsumme.

V_{Red} : Reduktion der Ellipsenflächen

Durch den neuen Posensatz sollen außer dem aktuellen auch alle weiteren erfassbaren Elemente möglichst genau eingemessen werden, was durch den Term V_{Red} berücksichtigt werden soll. Ähnlich wie bei V_{Sch} wird die Flächenreduktion der Fehlerellipsen aller beteiligten Elemente betrachtet. Sofern für ein betroffenes Element bereits eine Fehlerellipse existiert, das Element also bereits durch mindestens 2 Aufnahmen erfasst wird, kann die Differenz der Ellipsenflächen vor und nach der Einbringung des potentiellen Posensatzes bestimmt werden (Abbildung 5.16). V_{Red} ergibt sich aus der Summe dieser Differenzen.



Abb. 5.16: Veränderung der Fehlerellipse durch zusätzliche Beobachtung von Pose P_3 ($P_1, P_2 \rightarrow P_1, P_2, P_3$)

V_{Dis} : Entfernungsunterschiede der Kameraposen zum aktuellen Element

Ein erhöhter Distanzunterschied der Kameraposen, durch die ein Merkmalspunkt erfasst wurde, hat einen negativen Einfluss auf dessen Wiedererkennbarkeit. Dementsprechend werden hier zunächst die Distanzen $DP_{i,j}$ aller n Positionen des potentiellen Posensatzes zum aktuellen Elementschwerpunkt bestimmt und in ein Verhältnis zueinander gesetzt. Der Mittelwert MV der Verhältnisse wird bestimmt über:

$$MV = \frac{\sum_{i=1}^{n^2} \frac{D_i}{D_j}}{n^2} \quad (5.7)$$

bei Vertauschung von D_i und D_j , wenn $D_j > D_i$. Der normierte Kehrwert von MV geht über den Term V_{Dis} in die Bewertung mit ein.

V_{Dif} : Winkeldifferenz der Kamerahaupttrichtung

Die Wiedererkennungsrates eines Merkmalspunktes sinkt bei steigender Betrachtungswinkeldifferenz. Zur Berücksichtigung dieses Effektes bewertet der Term V_{Dif} die Differenzen der Kameraorientierungen ϕ . Auch hier geht der Durchschnitt der Differenzen als normierter Kehrwert in die Bewertung ein.

Faktorisierung f_1 - f_5

Durch die Faktoren erfolgt eine Gewichtung der Teilterme und regelt somit deren Einfluss auf die Strategie. Ein Vergleich variierender Faktorisierungen in einem gesonderten Test (siehe Kapitel 6.1.2) ermöglichte deren Optimierung. Basierend auf der Optimierung wurde folgende Faktorisierung gewählt:

$$f_1 = 1.8 \quad f_2 = 2.7 \quad f_3 = 2.6 \quad f_4 = 1.0 \quad f_5 = 2.0 \quad (5.8)$$

5.3 Gesamtablauf der photogrammetrischen Rekonstruktion

Die für eine photogrammetrische Rekonstruktion notwendigen Komponenten sind in diesem Kapitel bereits vorgestellt worden. Um eine automatisierte 3D-Rekonstruktion der Szene zu ermöglichen, wer-

den diese mit weiteren notwendigen Arbeitsschritten zu einem gemeinsamen Prozess zusammengesetzt (Abbildung 5.1). Die einzelnen Schritte werden im Folgenden erläutert.

Zunächst soll an dieser Stelle in Abbildung 5.17 anhand eines Beispiels ein Eindruck gegeben werden, wie sich ein, durch die Strategie generierter Posenverband darstellt.

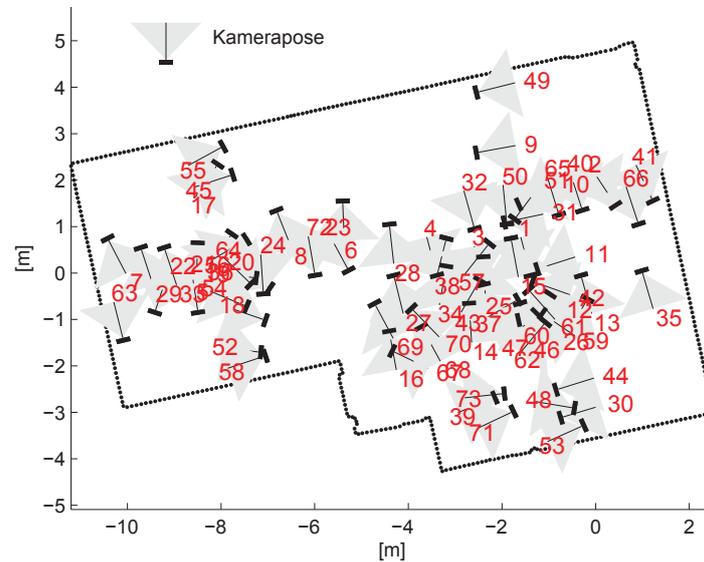
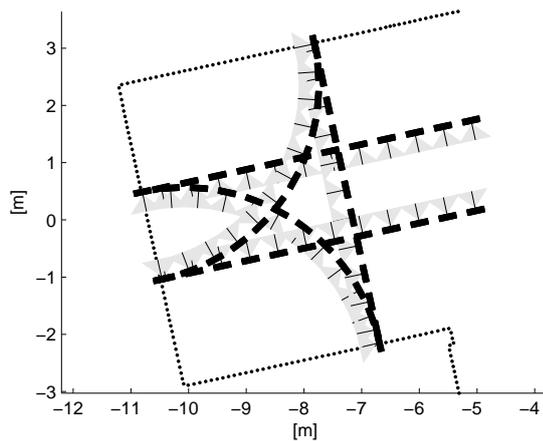
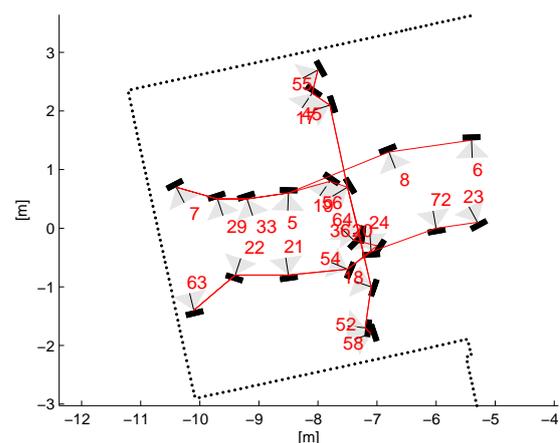


Abb. 5.17: 73 durch die Bewegungsstrategie ermittelte Kameraposen für eine reale Versuchsumgebung bei einer geforderten Redundanz $Red = 4$ (vgl. Kapitel 6.2.2)

In Abschnitt 5.2.1 wurde erläutert in welcher Form Posenanordnungen zu erstellen sind, um die gegebenen Rekonstruktionsrestriktionen harmonisierend zu verbinden (Abbildung 5.7). Projiziert man diese Vorgaben auf die Beispielumgebung, ergibt sich z.B. für den linken Teil des Raumes ein theoretischer Suchbereich für Kameraposen, wie er in Abbildung 5.18a zu sehen ist. Vergleicht man diesen mit der durch die Strategie gewählten Posen (Abbildung 5.18b), ist eine weitgehende Übereinstimmung festzustellen.



a)



b)

Abb. 5.18: Vergleich zwischen theoretischem Suchbereich und der in der Praxis gewählten Kameraposen
a) Darstellung der Bereiche, in denen bei konstantem Kameraabstand die theoretisch optimalen Posen zu finden sind
b) Durch die Bewegungsstrategie ermittelten Kameraposen

5.3.1 A priori Behandlung von Subkonfigurationen

Detektion von Subkonfigurationen

Für eine gemeinsame Registrierung müssen alle Aufnahmen direkt oder indirekt miteinander verknüpft sein (vgl. Abschnitt 5.2.1). Die Positionierungsstrategie berücksichtigt die Anzahl der Aufnahmen, durch die jedes Element E beobachtet wird, wodurch zumindest zwischen diesen Aufnahmen eine minimale Konnektivität gewährleistet werden kann. Eine Detektion von Subkonfigurationen ist so jedoch nicht möglich.

Zur Lösung dieses Problems wurde ein Ansatz gewählt, der auf dem sogenannten Max-Flow-Min-Cut-Theorem (vgl. Anhang A.16) beruht. Dazu müssen die ermittelten Kameraposen samt der von den Posen aus sichtbaren Umgebungselemente in einen gewichteten Graphen überführt werden. Die Kameraposen CP bilden die Knoten O des Graphen (Abbildung 5.20). Es werden Kanten A zwischen den Posen erstellt, die gemeinsame Objektpunkte bzw. Umgebungselemente erfassen. Die Gewichtung a der Kanten ist dabei abhängig von der Anzahl der gemeinsam erfassten Elemente E . Der Min-Cut, also die schwächste Verbindungsstelle im gesamten Posenverbund, läßt sich detektieren, indem der maximale Fluss F_{max} von einem beliebig gewählten Knoten zu allen anderen Knoten bestimmt wird.

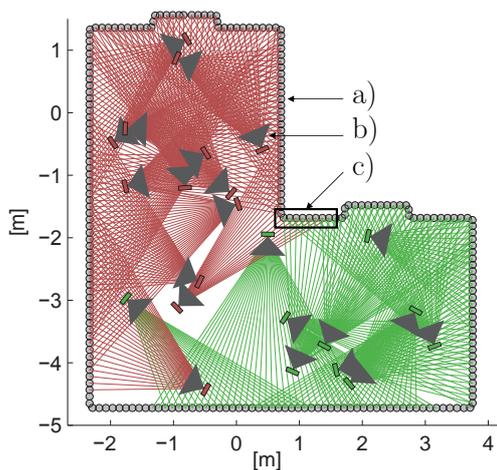


Abb. 5.19: Detektion von Subkonfigurationen (rot/grün) im Posenverband durch die Bestimmung des maximalen Flusses

- a) Umgebungselemente E des virtuellen Versuchsraumes
- b) Durch Positionierungsstrategie bestimmte Kameraposen
- c) Schwächste Verbindungsstelle im Gesamtverband

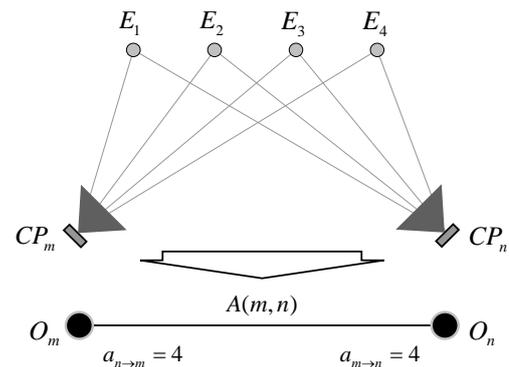


Abb. 5.20: Ableitung eines gewichteten Graphen mit den Kanten A und den Knoten O aus den Kameraposen CP und den Umgebungselementen E

Abbildung 5.19 stellt beispielhaft den ermittelten Min-Cut eines, für einen synthetischen Messraum ermittelten, Posenverbandes dar. Zu sehen sind in rot und grün die beiden Teilmengen bzw. möglichen Subkonfigurationen zwischen denen die geringste Verknüpfung besteht. Schwachstellen im späteren realen Bildverband entstehen nicht nur durch die räumliche Anordnung der Kameraposen, sondern auch durch schwach texturierte Umgebungsbereiche mit wenigen Merkmalspunkten. Da die Verteilung der Merkmale im Vorfeld nicht bekannt ist, bildet die Verwendung der äquidistanten Umgebungselemente hier die bestmögliche Abschätzung.

Behebung von Subkonfigurationen

Über einen Schwellwert S_{cut} kann nun bestimmt werden, ob der maximale Fluss also die Konnektivität eines Bildverbandes als ausreichend betrachtet werden kann. Ist dies nicht der Fall, müssen zusätzliche Kameraposen zur Behebung der Schwachstellen definiert werden. Dabei werden iterativ zusätzliche

Posen bestimmt, bis F_{max} den geforderten Schwellwert erreicht hat. Die Posen werden so gewählt, dass durch diese möglichst alle, dem Min-Cut zugehörigen, Umgebungselemente erfasst werden. Zudem werden alle bereits existierenden Posen berücksichtigt, so dass es zu keiner mehrfachen Wahl derselben Posen kommt.

Dient eine einzelne Kamerapose CP_i dazu, nur sehr wenige und hinsichtlich der Sichtbarkeit schwer zugängliche Umgebungselemente zu erfassen, weist diese eine sehr geringe Konnektivität auf. Der Min-Cut erzeugt dann eine Knotenteilmenge mit nur dieser einen Pose. Da die Definition weiterer Posen hier keinen wesentlichen Vorteil erbringt, werden die von CP_i ausgehenden Kanten $A_{i,1...n}$ künstlich erhöht, um in der nächsten Iteration andere Bereiche geringer Konnektivität finden zu können.

5.3.2 Abfolge angefahrener Posen

Ein geringer Gesamtaufwand für den Besuch aller Messposen ist erstrebenswert. Die Bestimmung der kürzesten Route führt zum *Problem des Handlungsreisenden* (engl.: *travelling salesman problem* oder kurz *TSP*). Algorithmen für eine schnelle, approximative Lösung dieses Problems sind bekannt (z.B. [23]). Als Eingangsgrößen müssen die Kantengewichte eines Graphen definiert werden. Diese entsprechen den Kosten K , die das Messsystem aufwenden müsste, um sich zwischen den durch die Positionierungsstrategie definierten Posen zu bewegen. $K_{m,n}$ ergibt sich gemäß des Bewegungsmodells (vgl. Kapitel 3.3) aus der Summe der j Geradeausfahrten zu den Zwischenpunkten p_i und den dort auszuführenden Richtungsänderungen $\Delta_{\alpha i}$, die notwendig sind, um den Pfad zwischen zwei Messpunkten P_m und P_n abzufahren. Während im Fall der Geradeausfahrten die euklidische Distanz der Zwischenpunkte $p_{i-1} \rightarrow p_i$ eingeht, ergibt sich der Aufwand einer Drehbewegung aus der Länge des für die Räder abzufahrenden Kreisbogens, also abhängig vom Radabstand D_{Rad} (vgl. Anhang A.1):

$$K_{m,n} = \sum_{i=2}^j (|p_i - p_{i-1}| + \pi \frac{\Delta_{\alpha i}}{360^\circ} D_{Rad}) \quad (5.9)$$

Da die Anzahl der zu berechnenden Pfade quadratisch zur Anzahl der Kameraposen steigt, ist diese Methode mit einem hohen Rechenaufwand verbunden. Um diesen zu reduzieren, werden zunächst nur die direkten Verbindungslinien V zwischen allen Posen betrachtet. Besteht die Menge aller Gitterzellen $c_{m,n}$ (vgl. Kapitel 2.1.2), die von einer Verbindungslinie $V_{m,n}$ überstrichen wird, ausschließlich aus befahrbaren Zellen, geht direkt die Länge der Verbindungslinie $|V_{m,n}|$ in die Berechnung von K ein und die Bestimmung des Pfades entfällt.

Abbildung 5.21 stellt eine solche Pfadabfolge beispielhaft dar. Die Pose des Messsystems vor dem eigentlichen Messprozess geht in die Berechnungen als zusätzlicher Knotenpunkt mit ein. Eine entsprechende Lokalisierungsinformation bezieht das Messsystem durch eine zusätzliche Scannermessung.

5.3.3 Aufnahme und Rekonstruktion

Wie in Kapitel 3 lokalisiert sich auch das 3D Messsystem während der Fahrt nur anhand der Odometriedaten. Aufgrund der Versuchsergebnisse aus Kapitel 4.3 erfolgt der Einsatz des Laserscanners für eine präzise Relokalisierung nur an den Aufnahmestandorten zu deren Folgeposen das System eine Distanz $K > 10$ m (vgl. Gleichung 5.9) im Hinblick auf die letzte Relokalisierung zurücklegen müsste. Dieser Ansatz führt zwar zu weniger Beobachtungen bezüglich des Registrierungsvorgangs (vgl. Abschnitt 5.3.5), erbringt aber wegen der langen Scandauer eine erhebliche Zeitersparnis.

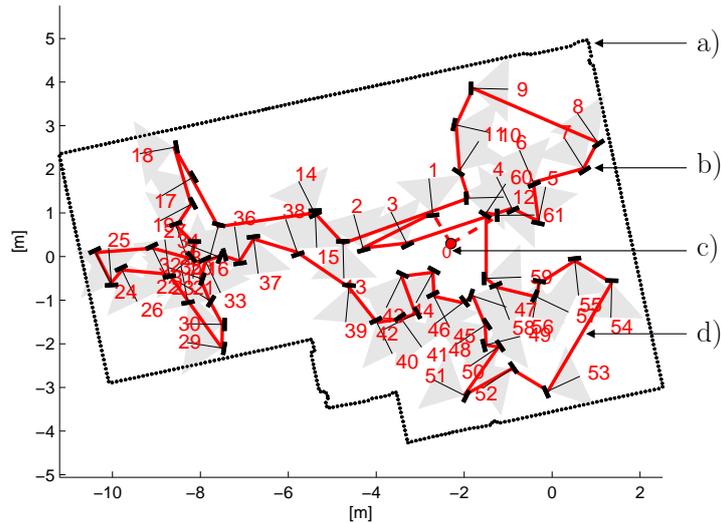


Abb. 5.21: Beispiel für eine durch die Lösung des TSP definierte Pfadabfolge. Die Kameraposen resultieren aus der Anwendung der Positionierungsstrategie auf die reale Versuchsumgebung bei einer geforderten Redundanz $Red = 3$

- a) Umgebungselemente E
- b) Durch Positionierungsstrategie definierte Kameraposen CP
- c) Initiale Pose
- d) Durch Lösung des TSP ermittelte Pfadabfolge

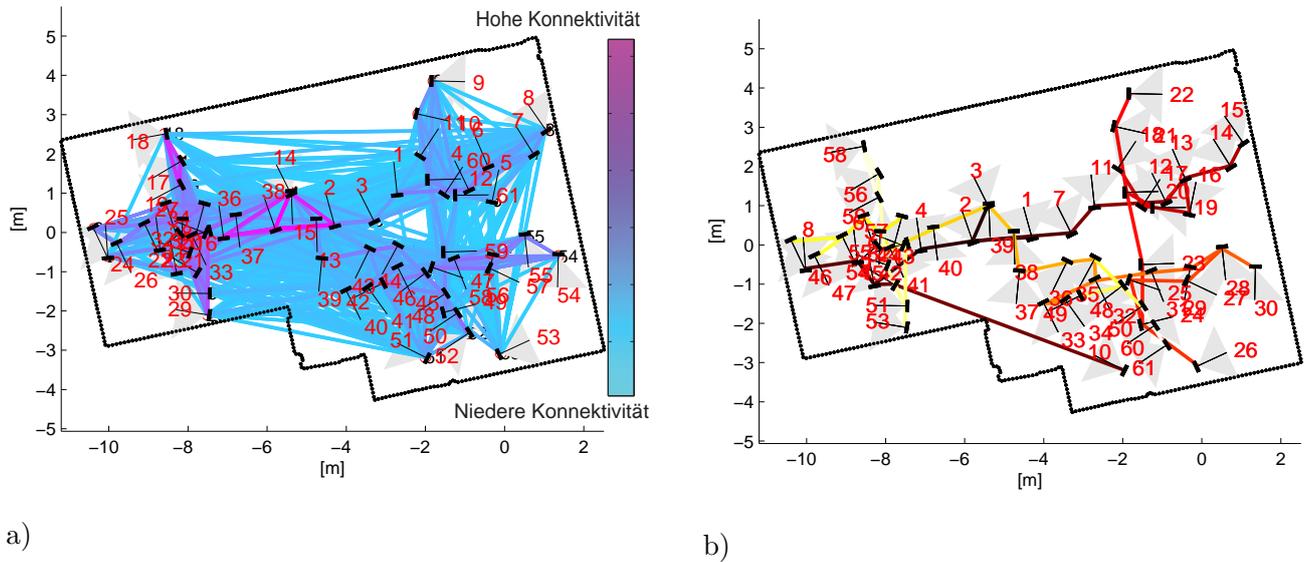


Abb. 5.22: Rekonstruktionsreihenfolge in iterativer Bündelausgleichung

- a) Konnektivität zwischen Kameraposen
- b) Resultierende Rekonstruktionsreihenfolge

Nach Durchführung aller Aufnahmen wird der Rekonstruktionsprozess gestartet. Die Reihenfolge, in der die einzelnen Aufnahmen in die iterative Berechnung des Bündelausgleichs eingehen, entspricht nicht der Aufnahmereihenfolge. Die Rekonstruktionsreihenfolge der Aufnahmen ergibt sich aus der Konnektivität zwischen den Aufnahmen (vgl. Abschnitt 5.1.2). Abbildung 5.22a stellt die Konnektivität zwischen den Aufnahmen des Bildverbands aus Abbildung 5.21 dar, wodurch die in Abbildung 5.22b dargestellte Rekonstruktionsreihenfolge resultiert.

5.3.4 A posteriori Behandlung von Subkonfigurationen

Trotz der gesonderten Suche nach Subkonfigurationen in Abschnitt 5.3.1 kann es vorkommen, dass sich der Aufnahmeverband nicht in einem gemeinsamen Bündelausgleichprozessieren lässt. Das Rekonstruktionsmodul erzeugt dann nur eine Subkonfiguration der Szene während das verbleibende Aufnahmematerial zunächst außer Acht gelassen wird. Das kann insbesondere dann vorkommen, wenn die Umgebungsoberflächen nur schwach texturiert sind und die einzelnen Aufnahmen nur geringe Verknüpfungen aufweisen. Dieser Umstand lässt sich aufgrund mangelnder Kenntnis über die Oberflächentextur bei der Aufnahmeplanung nicht berücksichtigen.

Ist keine gemeinsame Prozessierung möglich, werden mit dem verbleibenden Aufnahmematerial iterativ weitere Rekonstruktionsversuche durchgeführt, bis sich keine weiteren Subkonfigurationen mehr erzeugen lassen. Anschließend liegt dem System die Szene in Form mehrerer, sich überlappender Subkonfigurationen vor (Abbildung 5.23b). Hier soll durch das Hinzufügen weiterer Kameraposen ein erneuter Versuch der gemeinsamen Rekonstruktion durchgeführt werden. Zur Ableitung geeigneter Posen wird der Überlappungsbereich bzw. der n durch die Subkonfigurationen gemeinsam beobachteten Umgebungselemente E_n betrachtet. Anhand dessen wird zunächst ein gemeinsamer Sichtbereich CE_{ges} in Form einer Vereinigung aller Sichtbereiche CE_n mit $CE_{ges} = CE_{E1} \cup CE_{E2} \cup \dots \cup CE_{En}$ definiert. Die Definition einer weiteren Kamerapose CP_{neu} erfolgt durch eine Evaluation aller m Zellen aus CE_{ges} über:

$$V_{CE}(m) = d_N^r(m) + d_S^r(m) + d_{CP}^r(m) \quad (5.10)$$

Hierfür müssen der Schwerpunkt S der E_n sowie ein gemittelter Normalenvektor N_S aller n Normalenvektoren der E_n gebildet werden. Die Evaluationsgröße V_{CE} ergibt als Summe von d_N : dem Kehrwert des Lotabstands zwischen einer zu evaluierenden Zelle $C_{i,j}$ und N_S , d_S : dem Abstand von $C_{i,j}$ zu N_S und d_{CP} : dem Abstand von $C_{i,j}$ zur nächstgelegenen, bereits definierten Kamerapose CP_S (Abbildung 5.23a). Die Ausrichtung von CP_{neu} entspricht hierbei der Richtung zu N_S . Für eine gleichgewichtete Berücksichtigung werden d_N , d_S und d_{CP} auf den Wertebereich von 0 bis 10 skaliert $\rightarrow d_N^r$, d_S^r und d_{CP}^r :

$$d_{N/S/CP}^r(m) = \frac{(d_{N/S/CP}(m) - d_{N/S/CP \min}) \cdot 10}{d_{N/S/CP \max} - d_{N/S/CP \min}} \quad (5.11)$$

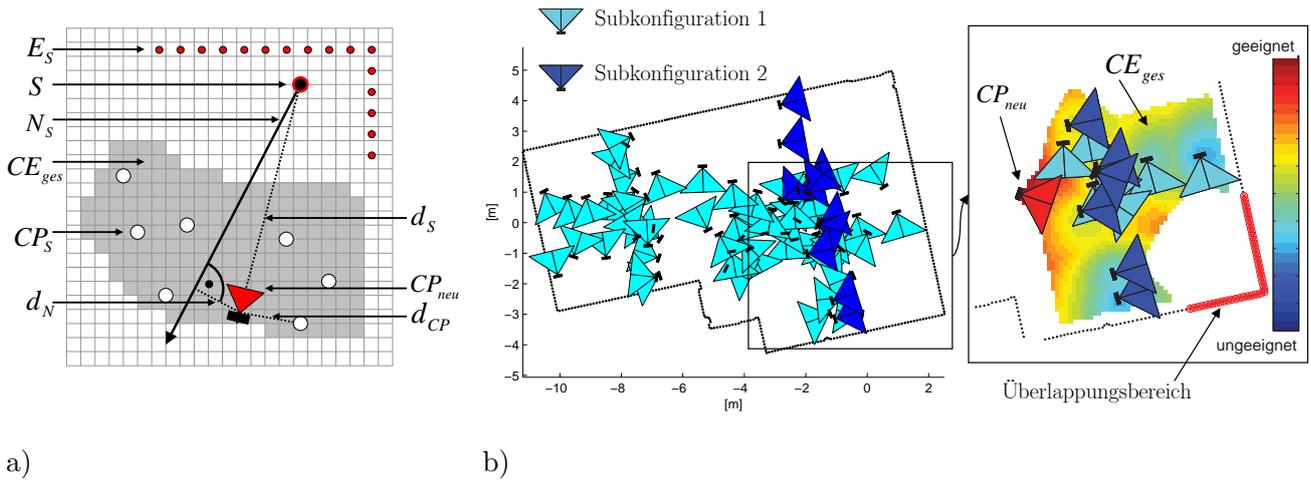
Abbildung 5.23b zeigt die Wahl einer zusätzlichen Kamerapose am Beispiel eines realen Datensatzes ($Red = 3$, siehe Kapitel 6.2.3).

5.3.5 Skalierung und Registrierung

Im Falle einer weiteren Nutzung der rekonstruierten Punktwolke durch das Messsystem müssen die rekonstruierten Umgebungspunkte in dessen Koordinatensystem überführt werden. Eine Veranschaulichung des gesamten Prozesses der Datenregistrierung zeigt Abbildung 5.24.

Skalierung

Ein grundlegendes Problem der Photogrammetrie ist das Fehlen einer Maßstabsinformation. Diese muss durch zusätzliche Aufwendungen eingeführt werden. Da sich der Maßstab hier nicht direkt aus den Bilddaten ableiten lässt (z.B. durch ein wiedererkennbares Referenzobjekt), wird auf die Lokalisierungsinformation des Laserscanners zurückgegriffen. Durch die an den Kameraaufnahmestandorten zusätzlich durchgeführten Scannermessungen sind die entsprechenden Roboterposen bereits bekannt. Der Skalierungsfaktor sk wird durch einen Abstandsvergleich der vom System besuchten Messpo-



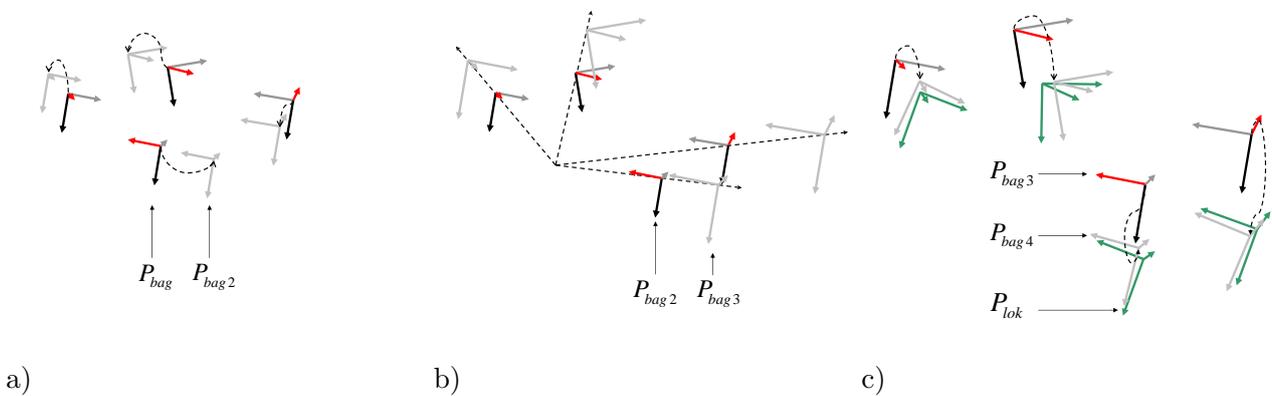
a)

b)

Abb. 5.23: Wahl weiterer Kameraposen zur Verknüpfung der Subkonfigurationen

a) Ableitung von V_{CE}

b) Anwendungsbeispiel



a)

b)

c)

Abb. 5.24: Registrierung der rekonstruierten Kameraposen P_{bag} im Koordinatensystem der Scannermessungen K_{lok} .

a) Transformation aller P_{bag} entsprechend der in situ geschätzten relativen Orientierung $O_{cam \rightarrow scan} \rightarrow P_{bag2}$

b) Skalierung der P_{bag2} anhand des geschätzten Skalierungsfaktors $sk \rightarrow P_{bag3}$

c) Transformation der P_{bag3} auf P_{lok} nach iterativer Schätzung der Transformationsparameter anhand einer SVD zur Minimierung der Restklaffungen $\rightarrow P_{bag4}$

sen abgeleitet. Verglichen werden die im Koordinatensystem des Bündelausgleichs gegebenen Posen $P_{bag}(x, y, z)$ mit den Posen der 2D-Lokalisierung $P_{lok}(x, y, 0)$. sk ergibt sich durch die Bildung des Mittelwerts aller möglichen Einzelskalierungen:

$$sk = \frac{1}{\sum_{m=1}^{k-1} m} \sum_{i=1}^k \sum_{j=i+1}^k \frac{|P_{lok}^i - P_{lok}^j|}{|P_{bag}^i - P_{bag}^j|} \quad (5.12)$$

mit k = Anzahl der Messposen

Ein direkter Vergleich zwischen den P_{bag} und P_{lok} ist nicht möglich, da sich die P_{bag} auf die Kameraprojektionszentren beziehen, während die P_{lok} auf den Sensorursprung des Laserscanners referenziert sind. Die für eine Umrechnung nach P_{bag} notwendige relative Orientierung O_{cs} zwischen der Kamera und dem Scanner ist zunächst nicht bekannt. Aufgrund des sich durch die Nivelliereinheit bewegenden Sensorkopfes, aber auch weil die Kamera zwischen den Versuchen mehrmals demontiert werden musste, unterliegt O_{cs} einer zeitlichen Variation, worauf auf eine Bestimmung von O_{cs} im Rahmen

einer gesonderten Kalibrierung verzichtet wurde.

Stattdessen wird versucht O_{cs} bei jeder neuen Messreihe durch eine in situ Kalibrierung abzuleiten, die im Zuge der Bestimmung von sk durchgeführt wird. Ermittelt werden lediglich die Parameter der Translation $O(x, y, z)$, da die rotatorischen Parameter zur Ableitung des Maßstabs vernachlässigt werden können. Da $O(x, y, z)$ bezüglich des Koordinatensystems jeder Kamerapose bestimmt wird, läßt sich ein gemeinsamer Transformationsparametersatz ableiten (Abbildung 5.24a). Die Problemstellung läßt sich als Optimierungsaufgabe definieren, in der die Standardabweichung σ_{sk} der Einzelskalierungen (vgl. Gleichung 5.12) zu minimieren ist. Die Optimierung der Parameter erfolgt unter Verwendung eines evolutionären Algorithmus (vgl. [110]), bei dem iterativ zufällige Werte für $O(x, y, z)$ ermittelt und bezüglich σ_{sk} evaluiert werden. Dabei wird eine Ausgangsbelegung, die auf Erfahrungswerten basiert, mit Zufallswerten einer definierten Streubreite variiert. Nach einer festen Anzahl an Iterationen wird die Wertebelegung mit minimalem σ_{sk} als neue Ausgangsbelegung genutzt und die Streubreite verringert. Dieser Vorgang wird mehrfach iteriert. In Abbildung 5.25 ist die optimierte Bestimmung von sk und O anhand eines Beispiels dargestellt.

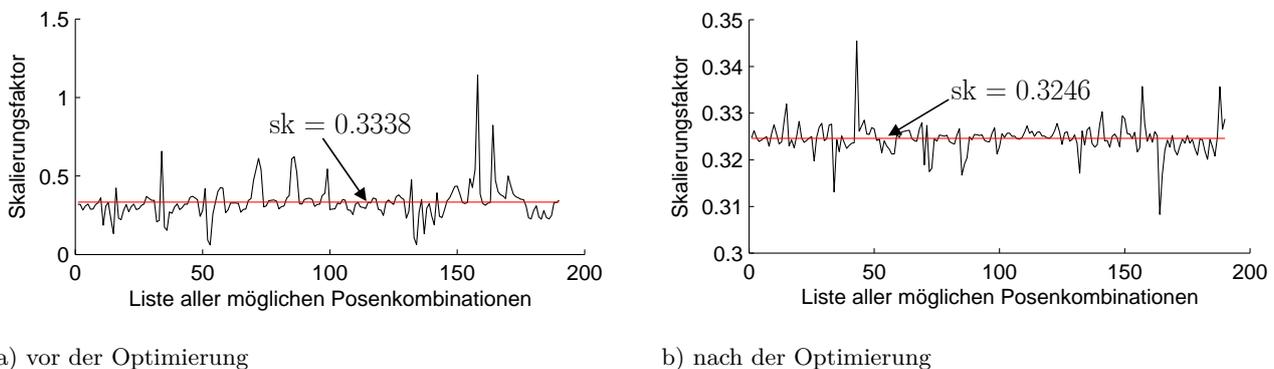


Abb. 5.25: Simultane Bestimmung bzw. Optimierung des Scanner-Kamera Versatzes $O(x, y, z)$ und des Skalierungsfaktors sk . Betrachtung der Abstandsverhältnisse aller besuchten Messposen $P_{lok} \rightarrow P_{bag}$ und Ableitung des Skalierungsfaktors sk durch Mittelwertbildung (rot)

Registrierung

Zur Registrierung müssen die skalierten Kameraposen P_{bag3} (Abbildung 5.24b) auf die Scannermessungen P_{lok} transformiert werden. Um im \mathbb{R}^3 zwei Punktmengen ineinander zu überführen, ist die Bestimmung von 7 Parametern notwendig (3 Rotationen $R(x, y, z)$, 3 Translationen $T(x, y, z)$, 1 Maßstab a). Prinzipiell wäre die Verwendung von 3 linear unabhängigen Punkten zur Ableitung der Transformationsparameter ausreichend. Da jedoch viel mehr Punkte also Beobachtungen zur Verfügung stehen, werden diese in die Bestimmung von R , T und a im Rahmen einer Singulärwertzerlegung mit einbezogen (siehe Anhang A.17). Da der Maßstab bereits zuvor bestimmt wurde, wird in Gleichung A.56 anstatt der Verwendung des ermittelten Wertes $a = 1$ gesetzt.

Nach Durchführung der Transformation ist zu erwarten, dass zwischen den korrespondierenden Punkten Restklaffungen verbleiben. Die Rekonstruktion einzelner Kameraposen kann aufgrund einer zu geringen Konnektivität ungenau sein. Um die Transformation robust gegenüber diesen Ausreißern zu machen, wurde die beschriebene Vorgehensweise iterativ angewandt, wobei in jeder Iteration nur die 50% aller Punkte mit den geringsten Restklaffungen in der Parameterbestimmung berücksichtigt wurden.

Eine bisher vernachlässigte Größe ist die Höhe H_L , in der der Laserscanner auf der Plattform an-

gebracht ist⁶. So muss die Punktwolke in einem letzten Transformationsschritt um H_L in vertikaler Richtung verschoben werden, um schließlich im Koordinatensystem des Belegheitsgitters vorzuliegen. Abbildung 5.26 zeigt eine, für die in der Versuchsumgebung getätigten Messungen charakteristische, registrierte Punktwolke.

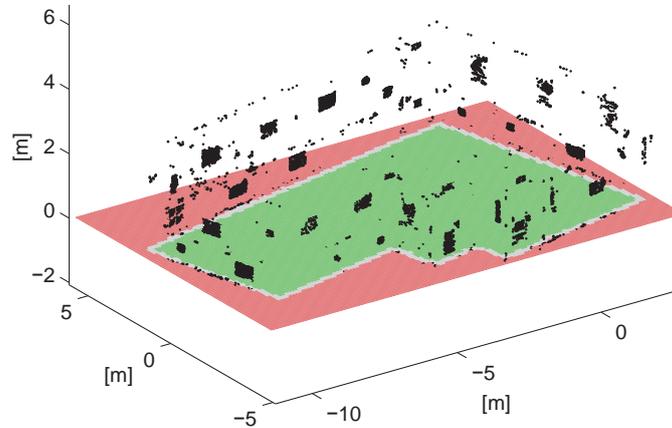


Abb. 5.26: Aus der 3D-Rekonstruktion resultierende und im Koordinatensystem des Belegheitsgitters registrierte Punktwolke

Parametrisierung

In Tabelle 5.1 findet sich eine Zusammenfassung der in der Positionierungsstrategie bzw. dem Bündelausgleich benötigten Systemparameter, sowie einer typischen, in den Versuchen aus Kapitel 6 verwendeten Wertebelegung.

Parameter	Wert	Beschreibung
Allgemein		
IA_1	2 cm	Feste Anzahl an Posensätzen, die für jedes Umgebungselement E generiert und evaluiert werden
IA_2	2 cm	Feste Anzahl an Zellmittelpunktsätzen zur Positionsbestimmung eines Posensatzes
L_{disk}	5 cm	Diskretisierungsdichte bei der Bildung der Umgebungselemente E
AA_{min}	1.5 mm	Minimal zulässiger Aufnahmeabstand bei der Erfassung eines Umgebungselements E
AA_{max}	3.5 mm	Maximal zulässiger Aufnahmeabstand bei der Erfassung eines Umgebungselements E
AW	$\pm 60^\circ$	Begrenzung des Aufnahmewinkels bei der Erfassung eines Umgebungselements E
Red	4	Mindestanzahl mit der jedes Umgebungselement E beobachtet werden soll
S_{cut}	40	Schwellwert des maximalen Flusses zur Überprüfung des Posenverbandes auf Schwachstellen
Bündelausgleich (vgl. Abschnitt 6.2.1)		
ORE	4.0 px	Maximal zulässiger Reprojektionsfehler
BMV	3	Ausschließliche Verwendung von Punkten mit BMV -facher Zuordnung

Tab. 5.1: Parametrisierung

⁶Die Größe H_L lässt sich messen, indem der Lotabstand des Laserstrahls auf der Wand zur Bodenebene gemessen wird

6 Evaluierung des 3D-Messsystems



Abb. 6.1: Reale Versuchsumgebung

Zur Evaluierung des in Kapitel 5 beschriebenen Messsystems wurden verschiedene Testreihen durchgeführt. In Abschnitt 6.1 erfolgt zunächst eine Evaluierung mittels synthetischer Daten. Zur Durchführung der Versuchsreihen wurde eine synthetische Innenraumumgebung erzeugt (vgl. Abbildung 5.13), die mit geraden Elementen und den Einbuchtungen von Türen eine charakteristische Innenraumumgebung repräsentieren soll. In Abschnitt 6.2 erfolgt eine Betrachtung von empirischer Seite. Um dies zu ermöglichen, wurde das System in einer realen Innenraumumgebung eingesetzt. Als Testumgebung wurde ein leerer Raum von rund 80 m^2 genutzt (Abbildung 6.1). Um Genauigkeitsaussagen bezüglich der durch das Messsystem erzeugten Punktwolken bzw. Modelle treffen zu können, wurde im Vorfeld anhand eines Tachymeters (vgl. Kapitel 4) ein 3D-Referenzmodell der Szene erstellt (Abbildung 6.2).

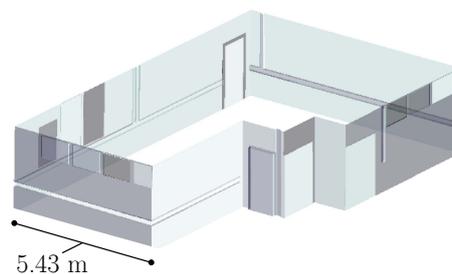


Abb. 6.2: 3D-Tachymetermodell

6.1 Evaluierung mittels synthetischer Daten

Durch die Untersuchungen anhand synthetischer Daten soll festgestellt werden, welche Genauigkeiten für die später in der Praxis erstellten Modelle erwartet werden können. Zudem soll der Einfluss verschiedener Parameter auf die Messstrategie evaluiert werden. Der Vergleich unterschiedlicher Strategievarianten soll es in der späteren praktischen Anwendung ermöglichen auf eine möglichst effiziente, robuste und genaue Strategie zurückgreifen zu können.

L_{disk} definiert die Größe der Umgebungselemente E , in die die gegebenen 2D-Daten äquidistant unterteilt werden (vgl. Kapitel 5.2.2). Für die folgenden Versuche wurde die Testumgebung mit variierendem L_{disk} diskretisiert und die resultierenden Elemente E als Merkmalspunkte betrachtet.

Erläuterung der Testparameter

Für eine möglichst vollständige Evaluation werden in den Versuchsreihen Kenngrößen beobachtet, die

die Genauigkeit und die Robustheit der genutzten Positionierungsstrategie als auch deren Effizienz wiedergeben sollen. Tabelle 6.1 stellt zunächst alle verwendeten Kenngrößen zusammen.

Die Kenngrößen lassen sich in drei Gruppen einteilen. In den Spalten 1-3 der Tabelle 6.1 finden sich allgemeine Kenngrößen bezüglich der für eine Innenraumszene ermittelten Messkonfiguration. Die Größen in den Spalten 4-11 sollen ein Maß dafür sein, inwiefern die ermittelte Konfiguration den Restriktionen der Merkmalerkennung folgt. Für die Wiedererkennung der Merkmalspunkte in den Bildern relevant ist die Verteilung der Kameraposen bezüglich des Aufnahmewinkels und des Aufnahmeabstands. Für beide wurden hier 4 Intervalle gewählt, die mit den Beurteilungen „sehr gut“, „gut“, „ausreichend“ und „mangelhaft“ interpretiert werden können. Die Spalten 12-21 verweisen auf die Genauigkeitswerte, die im Zuge der Ausgleichsrechnungen ermittelt wurden (vgl. Kapitel 5.2.3). In den Spalten 12-16 sind die Ergebnisse der Ausgleichungen aufgelistet, bei der alle Kameraposen festgehalten wurden. Die Spalten 17-21 zeigen die Ergebnisse der Gesamtpurminimierung.

Allgemein			Merkmalerkennung				Genauigkeit													
							Datum:													
			Abstandverh.: V_A ¹		Winkeldiff.: V_M ²		Alle Kameraposen ³					Spurminimierung ⁴								
Freiheitsgrade ⁵	Anzahl der Posen ⁶	Effizienz ⁷	< 1.5 [%]	< 2.0 [%]	< 2.5 [%]	> 2.5 [%]	< 15° [%]	< 30° [%]	< 45° [%]	> 45° [%]	Mit. Koordinatengen. ⁸ [cm]	Ø große Halbachse A ⁹ [cm]	Ø kleine Halbachse B ⁹ [cm]	Isotropie ¹⁰ [m]	Spur-Var. Kriterium ¹⁰ [m]	Mit. Koordinatengen. ⁸ [cm]	Ø große Halbachse A ⁹ [cm]	Ø kleine Halbachse B ⁹ [cm]	Isotropie ¹⁰ [m]	Spur-Var. Kriterium ¹⁰ [m]

¹ Verhältnis der Abstände der Kameraposen bezüglich des erfassten Elementes

² Maximale Winkeldifferenz der Kamerahaupttrichtungen aller Kameraposen, die ein Element erfassen

³ Die Festlegung des Datums erfolgt über das Festhalten aller Kameraposen

⁴ Die Festlegung des Datums erfolgt indirekt über das Einführen zusätzlicher Bedingungsgleichungen (Gesamtpurminimierung)

⁵ Differenz zwischen Anzahl der Beobachtungen und der Anzahl der geschätzten Parameter

⁶ Anzahl der insgesamt verwendeten Kameraposen

⁷ Anzahl aller Beobachtungen geteilt durch die Anzahl der mindestens notwendigen Beobachtungen

⁸ Durchschnitt der Standardabweichungen der Objektpunktkoordinaten (siehe Anhang A.15.3)

⁹ Halbachse der Konfidenzellipse bei einem Quantil von $1 - \alpha = 95\%$ (siehe Anhang A.15.3)

¹⁰ Globales Genauigkeitskriterium (siehe Anhang A.15.3)

Tab. 6.1: Erläuterung der in den Testreihen evaluierten Kenngrößen

Bestimmung der Konfidenzellipsen

Wenn möglich, erfolgt eine Bestimmung der Konfidenzellipsen anhand des Schätzwertes s_0^2 , der das Genauigkeitsniveau a posteriori beschreibt. Die in dieser theoretischen Evaluierung verwendeten Messungen sind synthetisch erzeugt worden und somit fehlerlos. Da die Verbesserungen v_i (vgl. Gleichung A.12) und damit auch s_0^2 zu Null werden würden, findet der Schätzwert an dieser Stelle keine Verwendung. So muss auf den theoretischen Varianzfaktor σ_0^2 zurückgegriffen werden. Die Achsen D_{K_i} der Fehlerellipsen ergeben sich somit nach Gleichung A.48. Die Bestimmung des Quantils basiert dann auf

der χ^2 -Verteilung. Im 2D-Fall ergibt sich für $1 - \alpha = 0.95$ ein Quantil von $\chi^2_{2,0.95} = 5.99$.

6.1.1 Vergleich der Strategien

In einem ersten Test sollte geklärt werden, mit welcher der beiden in Kapitel 5.2.4 bereits beschriebenen Messstrategien eine effizientere und genauere Rekonstruktion möglich ist. Für den Test wurden mit den beiden Strategien für Redundanzwerte Red von 2 bis 7 jeweils 11 Messkonfigurationen für einen synthetischen Messraum ermittelt. L_{disk} betrug 5 cm. Die Ergebnisse des Tests sind in den Tabellen 6.2 und 6.3 dargestellt. Die Bewertungsformel der Kameraposen erhielt eine auf Erfahrungswerten basierende Gewichtung.

Redundanz	Allgemein		Abstandverhältnis				Winkeldifferenzen				Alle Kameraposen					Gesamtspurminimierung				
	Anzahl der Posen	Effizienz	< 1.5 [%]	< 2.0 [%]	< 2.5 [%]	> 2.5 [%]	< 15° [%]	< 30° [%]	< 45° [%]	> 45° [%]	Mit. Koordinatengen. [cm]	∅ große Halbachse A [cm]	∅ kleine Halbachse B [cm]	Isotropie [m]	Spur- Var. Kriterium [m]	Mit. Koordinatengen. [cm]	∅ große Halbachse [cm]	∅ kleine Halbachse B [cm]	Isotropie [m]	Spur- Var. Kriterium [m]
2	31.6	1.89	91.0	9.0	0.0	0.0	37.0	11.2	17.4	34.3	0.29	0.70	0.18	1.7e3	4.1e-4	1.99	5.88	2.57	1.2e7	1.9e-1
3	44.2	1.70	92.2	7.6	0.2	0.0	15.8	28.2	25.8	30.2	0.13	0.36	0.15	5.2e2	9.6e-4	0.73	2.21	0.95	6.8e5	2.9e-3
4	56.2	1.59	93.0	6.9	0.1	0.0	13.5	44.0	24.0	18.6	0.11	0.32	0.13	3.1e2	6.0e-4	0.41	1.22	0.65	1.4e5	8.3e-3
5	72.6	1.68	96.6	3.4	0.0	0.0	25.3	48.3	14.5	11.9	0.09	0.29	0.11	2.0e2	5.3e-3	0.35	1.08	0.52	1.7e5	6.2e-3
6	83.4	1.59	96.3	3.7	0.0	0.0	28.8	46.8	13.5	11.0	0.09	0.26	0.11	3.2e2	4.8e-4	0.39	1.20	0.52	1.8e5	7.4e-3
7	98.8	1.61	98.4	1.6	0.0	0.0	29.7	50.4	10.5	9.4	0.08	0.25	0.10	2.2e2	3.5e-4	0.36	1.13	0.45	1.6e5	6.3e-3

Tab. 6.2: Testergebnisse: Top-Down Strategie

Redundanz	Allgemein		Abstandverhältnis				Winkeldifferenzen				Alle Kameraposen					Gesamtspurminimierung				
	Anzahl der Posen	Effizienz	< 1.5 [%]	< 2.0 [%]	< 2.5 [%]	> 2.5 [%]	< 15° [%]	< 30° [%]	< 45° [%]	> 45° [%]	Mit. Koordinatengen. [cm]	∅ große Halbachse A [cm]	∅ kleine Halbachse B [cm]	Isotropie [m]	Spur- Var. Kriterium [m]	Mit. Koordinatengen. [cm]	∅ große Halbachse [cm]	∅ kleine Halbachse B [cm]	Isotropie [m]	Spur- Var. Kriterium [m]
2	27.0	1.66	87.0	12.5	0.5	0.0	26.0	4.5	17.4	52.0	0.41	0.92	0.19	3.6e3	8.1e-3	2.81	12.8	3.26	2.1e17	1.0e17
3	40.6	1.56	89.9	10.1	0.0	0.0	24.9	18.8	19.5	36.9	0.17	0.45	0.16	3.7e2	1.3e-3	0.89	2.75	1.16	6.8e5	4.1e-2
4	53.0	1.54	91.6	8.2	0.2	0.0	35.1	17.3	16.0	31.7	0.13	0.37	0.14	3.7e2	9.4e-4	0.65	2.06	0.71	9.3e5	2.8e-2
5	65.8	1.54	91.2	8.84	0.0	0.0	34.5	21.8	16.5	27.1	0.11	0.31	0.12	2.7e2	6.2e-4	0.45	1.39	0.60	2.1e5	1.0e-2
6	74.0	1.46	92.0	8.0	0.0	0.0	32.5	29.1	15.4	23.1	0.11	0.31	0.11	2.6e2	6.5e-4	0.41	1.26	0.57	2.8e6	8.3e-3
7	86.6	1.47	96.5	3.47	0.0	0.0	39.9	26.8	13.2	20.1	0.10	0.29	0.15	3.3e2	5.7e-4	0.42	1.33	0.52	2.1e5	8.7e-3

Tab. 6.3: Testergebnisse: Bottom-Up Strategie

Bei einer vergleichenden Betrachtung der Tabellen fällt zunächst auf, dass die Anzahl der benötigten Kameraposen bei der Bottom-Up Strategie stets geringer und die Effizienz somit höher ist. Es werden also weniger Aufnahmen benötigt, bis alle Elemente E redundant erfasst sind.

Die Betrachtung der weiteren Kenngrößen sollte unter Berücksichtigung der Anzahl der benötigten Kameraposen erfolgen, da diese voneinander abhängig sind (vgl. Abschnitt 6.1.3). So lassen sich z.B. die Ergebnisse der Top-Down Strategie bei $Red = 5$ und durchschnittlich 73 Kameraposen mit den Ergebnissen der Bottom-Up Strategie bei $Red = 6$ und 74 Posen vergleichen.

Die Kenngrößen V_A und V_W zeigen, dass hier die Top-Down Strategie im Vorteil ist. Bei vergleichbarer Posenzahl weist diese ein besseres Abstandsverhältnis und bessere Winkeldifferenzen auf. So fällt der Prozentsatz der V_W bei der Bottom-Up Strategie selbst bei $Red = 7$ und durchschnittlich 87 Kameraposen nicht unter 20%. Auch bezüglich der Mittleren Koordinatengenauigkeit sowie der Isotropie ist

die Top-Down Strategie im Vergleich im Vorteil.

Es läßt sich sagen, dass beide Strategien ihre Vorteile haben. Während mit der Bottom-Up Strategie eine vollständige Erfassung der Umgebung mit höherer Effizienz vollzogen werden kann, spricht für die Top-Down Strategie die höhere Genauigkeit. Da der Genauigkeitsaspekt für die Vermessung wesentlich ist, wurde nur die Top-Down Strategie für die zusätzlichen Untersuchungen und den Einsatz in der Praxis weiter verfolgt.

Standardabweichungen der Kenngrößen

Da es sich bei angeführten Kenngrößen um Durchschnittswerte handelt, müssen der Vollständigkeit halber zusätzlich deren Standardabweichungen s_0^2 angegeben werden (Tabelle 6.4). Aus Platzgründen werden diese jedoch nicht bei allen Testergebnissen angeführt, sondern ausschließlich für die ermittelten Größen der Top-Down Strategie angegeben. Es zeigt sich, dass die Standardabweichungen in deutlich geringeren Größenordnungen liegen als die entsprechenden Kenngrößen, was die Aussagekraft der Kenngrößen unterstreicht. Lediglich bei den V_W war eine Streuung der Kenngrößen erkennbar.

Redundanz	Allgemein		Abstandverhältnis				Winkeldifferenzen				Alle Kameraposen					Gesamtspurminimierung				
	Anzahl der Posen	Effizienz	< 1.5 [%]	< 2.0 [%]	< 2.5 [%]	> 2.5 [%]	< 15° [%]	< 30° [%]	< 45° [%]	> 45° [%]	Mit. Koordinatengen. [cm]	Ø große Halbachse A [cm]	Ø kleine Halbachse B [cm]	Isotropie [m]	Spur- Var. Kriterium [m]	Mit. Koordinatengen. [cm]	Ø große Halbachse [cm]	Ø kleine Halbachse B [cm]	Isotropie [m]	Spur- Var. Kriterium [m]
2	0.6	5.0e-3	11.8	11.8	0.0	0.0	89.4	45.3	94.2	29.9	1.5e-3	2.3e-3	5.0e-6	5.8e4	1.2e-6	6.6e-2	2.6e-1	2.5e-2	1.6e12	2.6e-3
3	3.0	6.0e-3	8.1	6.5	0.1	0.0	27.1	93.7	91.0	99.8	5.1e-4	1.9e-4	8.6e-6	7.5e4	1.0e-8	5.2e-2	4.9e-1	9.2e-3	1.0e10	3.5e-4
4	1.4	2.0e-3	38.7	38.3	0.0	0.0	28.5	56.1	73.4	18.6	4.3e-5	1.0e-4	4.6e-6	3.3e3	4.1e-9	3.0e-3	3.7e-2	1.8e-3	3.3e8	5.0e-6
5	4.2	1.2e-3	2.3	2.3	0.0	0.0	46.3	80.4	35.3	16.2	7.4e-5	3.2e-4	2.0e-6	5.2e2	6.2e-9	1.9e-3	2.2e-2	1.1e-3	1.1e9	2.4e-6
6	8.0	9.7e-3	7.3	7.3	0.0	0.0	91.0	57.9	42.5	14.2	2.1e5	1.4e-4	1.2e-5	8.5e2	2.1e-9	1.3e-3	1.4e-2	6.1e-4	6.8e9	2.0e-6
7	9.6	8.4e-4	1.1	1.1	0.0	0.0	86.6	29.0	37.3	4.3	2.5e-5	1.8e-4	5.5e-6	2.9e2	2.7e-9	9.4e-4	1.1e-2	7.5e-4	1.1e8	1.1e-6

Tab. 6.4: Standardabweichungen s_0^2 der ermittelten Kenngrößen bei Top-Down Strategie

6.1.2 Gewichtungsoptimierung der Kostenfunktion

Die Kostenfunktion der Positionierungsstrategie ist mit Gewichtungen f_1 - f_5 versehen (vgl. Kapitel 5.2.4). Entsprechend der Vorgehensweise in Kapitel 4.1 wurde eine Parameteroptimierung der Gewichtungen durchgeführt. Die Algorithmen der Bewegungsstrategie wurden wiederholt und unter variierenden f_i auf den virtuellen Innenraum angewandt. Die synthetischen Merkmalspunkte wurden gleichmäßig mit $L_{disk} = 5$ cm generiert (vgl. Abschnitt 6.1.4) und ein Redundanzwert von 3 gefordert (vgl. Abschnitt 6.1.3). Da die Algorithmen nicht deterministisch sind, sondern auf der Bewertung pseudozufälliger Kameraposen beruhen, wurde für jede Gewichtungsvariation eine eigene Messreihe mit jeweils 11 Durchläufen durchgeführt und deren Ergebnisse gemittelt.

Startlösung der Optimierung war eine erfahrungsbasierte Gewichtungswahl (siehe Tabelle 6.5), die im Rahmen des Tests variiert wurde. In einer ersten Testiteration wurden 20 Gewichtungsvariationen $F_{20}(f_1-f_5)$ untersucht, wobei die Faktoren f_i der Startlösung durch Zufallswerte mit den Standardabweichungen $\sigma_i = 0.5 \cdot f_i$ variiert wurden. Die am besten bewerteten Faktoren wurden in einer weiteren Testiteration erneut 20 mal variiert.

Die Bildung der zu minimierenden Zielfunktion $z(T_1 - T_7)$ erfolgte in Anbetracht der in Tabelle 6.6 aufgelisteten Größen¹ und entsprechend ihrer Gewichtungen. Für jede Testgröße T_i wurde eine

¹vgl. mit Erläuterung der Kenngrößen in der Einleitung des Kapitels

Faktoren	f_1	f_2	f_3	f_4	f_5
Startlösung	1.5	2.0	4.0	1.0	2.0
Gewichtungen nach 1. Testiteration	1.6	2.6	2.9	1.1	2.0
Gewichtungen nach 2. Testiteration	1.8	2.7	2.6	1.0	2.0

Tab. 6.5: Gewichtung f_1 - f_5 der 5 Einflussgrößen vor und nach den Optimierungsschritten

Testgröße T_i	Gewichtung G_i
T_1 : Anzahl der Kameraposen	1
T_2 : Effizienz	1
T_3 : Abstandsverhältnis	1
T_4 : Winkeldifferenzen	3
T_5 : Mittlere Koordinatengenauigkeit	3
T_6 : Isotropie	1
T_7 : Spur und Varianz	1

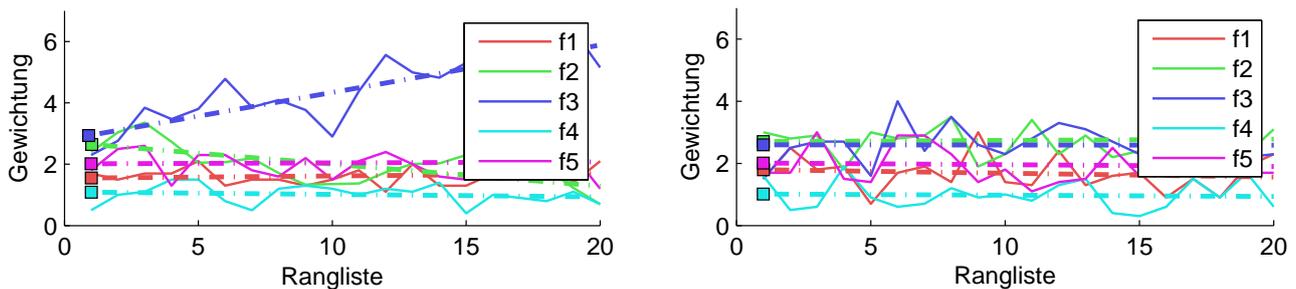
Tab. 6.6: Evaluierte Testgrößen und deren Gewichtungen in der Zielfunktion (resultierend aus Gesamtpurminimierung)

Rangliste mit Platzierungen P_j^i von 1 bis 20 aufgestellt. Die finale Zielfunktion setzt sich aus der mit den G_i gewichteten Summe dieser Einzelplatzierungen zusammen:

$$z_j = \sum_{i=1}^7 P_j^{T_i} \tag{6.1}$$

Ein höheres Gewicht erhielt die Mittlere Koordinatengenauigkeit, da diese direkt auf die Qualität der Rekonstruktion verweist. Zudem wurden die Winkeldifferenzen der Kamerahaupttrichtungen höher gewichtet, da deren Minimierung erfahrungsgemäß als kritischer Faktor für das Gelingen der Rekonstruktion anzusehen ist.

Zur Erkennung von Parametertendenzen sind die Ranglisten der z_j in den Abbildungen 6.3a und 6.3b gegen die Gewichtungen der Faktoren f_1 - f_5 aufgetragen. Testiteration 1 weist auf eine Minimierung von z bei einer Erhöhung von f_2 sowie einer Gewichtsreduzierung von f_3 hin. Die Endwerte der Regressionsgeraden aus Testiteration 1 bildeten die Startlösung für die zweite Testiteration. Die geringen Steigungen der Regressionsgeraden weisen hier auf das Erreichen eines lokalen Minimums hin, worauf die Optimierung an dieser Stelle abgebrochen wurde. Die aus der zweiten Testiteration resultierenden Gewichtungen wurden in den folgenden Untersuchungen weiter verwendet.



a)

b)

Abb. 6.3: Ranglisten der Gewichtungsvariationen F_{20}

- a) F_{20} Testiteration 1
- b) F_{20} Testiteration 2

6.1.3 Variation der Redundanz

In diesem Test sollte untersucht werden, wie sich die Messkonfiguration unter der Variation der Redundanz Red verhält, also der Mindestanzahl der Messungen mit denen jedes Umgebungselement E erfasst werden soll. Der Test umfasste die Untersuchung von Redundanzwerten zwischen 2 und 7. L_{disk} blieb

während der Testreihe konstant bei 5 cm. Für jeden Redundanzwert wurden 7 Kamerakonfigurationen bestimmt und deren Ergebnisse gemittelt. Die Ergebnisse sind in Tabelle 6.7 dargestellt.

Redundanz	Allgemein		Abstandverhältnis				Winkeldifferenzen				Alle Kameraposen					Gesamtspurminimierung				
	Anzahl der Posen	Effizienz	< 1.5 [%]	< 2.0 [%]	< 2.5 [%]	> 2.5 [%]	< 15° [%]	< 30° [%]	< 45° [%]	> 45° [%]	Mit. Koordinatengen. [cm]	ø große Halbachse A [cm]	ø kleine Halbachse B [cm]	Isotropie [m]	Spur- Var. Kriterium [m]	Mit. Koordinatengen. [cm]	ø große Halbachse [cm]	ø kleine Halbachse B [cm]	Isotropie [m]	Spur- Var. Kriterium [m]
2	30.6	1.83	86.8	13.0	0.1	0.0	21.1	37.3	19.4	22.1	0.44	0.71	0.18	1.6e4	7.4e-3	2.46	7.55	2.42	4.2e7	3.6e-1
3	42.2	1.55	85.4	13.7	1.0	0.0	19.5	27.4	28.4	24.8	0.13	0.35	0.15	4.6e2	7.9e-4	0.60	1.78	0.90	3.9e5	1.7e-2
4	56.6	1.54	92.0	7.8	0.0	0.0	12.4	54.5	17.6	15.4	0.10	0.29	0.13	1.1e2	4.7e-7	0.39	1.14	0.63	1.6e5	7.5e-3
5	70.4	1.53	96.6	3.4	0.0	0.0	22.5	53.0	15.7	8.7	0.09	0.26	0.14	9.2e1	3.7e-4	0.37	1.11	0.56	1.3e5	6.7e-3
6	87.0	1.57	96.9	3.1	0.0	0.0	26.2	54.1	14.1	5.8	0.08	0.25	0.11	6.4e1	3.0e-4	0.29	0.87	0.47	5.8e4	4.1e-3
7	100.0	1.50	99.2	0.8	0.0	0.0	33.6	55.2	6.3	4.9	0.07	0.22	0.10	4.5e1	2.5e-4	0.29	0.96	0.46	5.8e4	4.7e-3

Tab. 6.7: Testergebnisse: Variation der Redundanz

Wie zu erwarten, stieg die Anzahl der ermittelten Kameraposen bei einer Steigerung von Red . Das Verhältnis zwischen der Anzahl der ermittelten Posen und Red blieb annähernd konstant². In Folge dessen blieb auch die Effizienz invariant gegenüber Änderungen des Redundanzwertes.

Die V_A Werte verbessern sich bei einer Erhöhung von Red . Da diese selbst bei einer Redundanz von 2 durchweg „gut“ bis „sehr gut“ sind, bedürfen sie keiner besonderen Beachtung. Auch die V_W Werte zeigen eine Verbesserung bei einer Erhöhung der Redundanz. Hier verbleibt jedoch selbst bei $Red = 7$ ein Anteil von knapp 5% über den mindestens geforderten 45°. Auch eine Verbesserung der Fehlerverteilung ist am Verhältnis der Ellipsenachsen erkennbar. Während das Verhältnis der Ellipsenachsen 3.94 bei $Red = 2$ beträgt, fällt dieses bei der Erhöhung von Red auf 3 bereits auf 2.33. Durch zusätzliche Redundanz erhöhungen sinkt das Verhältnis weiter. Die Veränderung ist dann jedoch nur noch gering. Auch an der Veränderung der Isotropiewerte läßt sich eine Formverbesserung der Fehlerellipsen feststellen. Hier sinken die Werte stetig von 16000 bei $Red = 2$ auf 45 bei $Red = 7$. Beim Ausgleichungsmodell der Gesamtspurminimierung sind dieselben Trends erkennbar. Auch hier zeigt sich eine deutliche Verbesserung der Genauigkeit bei Erhöhung der Redundanz von 2 auf 3 von 2.5 cm auf 0.6 cm. Weitere Redundanz erhöhungen verbessern die Genauigkeit stetig weiter, aber in geringerem Maße. Bei $Red = 7$ wird der Bestwert von 0.3 cm erreicht. Die zugehörigen Achsen der Konfidenzellipsen haben Durchschnittswerte von 1 cm und 0.5 cm.

6.1.4 Variation der Diskretisierungsdichte

Bei vorangegangenen Versuchen betrug $L_{disk} = 5$ cm. Folgender Test sollte die Algorithmen der Messstrategie hinsichtlich einer Variation von L_{disk} überprüfen. Im Test wurden Wertebelegungen zwischen 1.25 cm und 20 cm betrachtet. Es wurde jeweils eine Messreihe mit 11 Konfigurationen ermittelt und deren Werte gemittelt. Die geforderte Redundanz betrug 3. Die Ergebnisse des Tests sind in Tabelle 6.8 aufgelistet.

In der zweiten Spalte von Tabelle 6.8 sind die Freiheitsgrade bei entsprechendem L_{disk} ablesbar. Die Freiheitsgrade werden bei $L_{disk} = 20$ cm minimal. Somit läßt sich sagen, dass im 2D-Fall Szenarien mit einem noch geringeren L_{disk} bei $Red = 3$ zwangsweise zu einem Scheitern der Ausgleichungsrechnung und somit der Rekonstruktion führen. Durch eine Erhöhung der Redundanz läßt sich dieser Wert steigern. So würde z.B. gemäß Abschnitt 6.1.3 eine Erhöhung auf $Red = 4$ eine Anzahl von 14 weiteren

²[15.3 → 14.1 → 14.2 → 14.1 → 14.5 → 14.3]

L_{disk} [cm]	Allgemein			Abstandverhältnis				Winkeldifferenzen				Alle Kameraposen				Gesamtspurminimierung					
	Freiheitsgrade	Anzahl der Posen	Effizienz	< 1.5 [%]	< 2.0 [%]	< 2.5 [%]	> 2.5 [%]	< 15° [%]	< 30° [%]	< 45° [%]	> 45° [%]	Mit. Koordinatengen. [cm]	∅ große Halbachse A [cm]	∅ kleine Halbachse B [cm]	Isotropie [m]	Spur- Var. Kriterium [m]	Mit. Koordinatengen. [cm]	∅ große Halbachse A [cm]	∅ kleine Halbachse B [cm]	Isotropie [m]	Spur- Var. Kriterium [m]
1.25	1.4e3	38.1	1.29	87.0	13.0	0.0	0.0	19.9	19.9	31.1	29.1	0.12	0.38	0.17	7.8e1	2.5e-3	0.29	0.87	0.51	1.3e7	1.5e-2
2.5	8.1e2	43.2	1.36	92.7	7.3	0.0	0.0	16.9	37.4	27.4	18.3	0.11	0.34	0.16	3.3e1	1.1e-3	0.38	1.11	0.61	2.9e6	2.9e-3
5	4.5e2	45.3	1.51	87.0	13.0	0.0	0.0	24.3	25.5	29.5	20.7	0.10	0.31	0.16	6.1e1	4.8e-4	0.39	1.15	0.69	6.7e5	7.0e-3
7.5	2.4e2	43.6	1.44	89.3	10.7	0.0	0.0	19.1	30.0	24.5	26.5	0.11	0.33	0.15	5.3e1	3.7e-4	0.48	1.37	0.85	3.1e5	6.8e-3
10	1.3e2	42.0	1.34	77.9	22.1	0.0	0.0	20.3	35.0	26.9	17.8	0.11	0.33	0.16	2.9e1	2.6e-4	0.95	2.86	1.54	2.7e5	2.0e-2
12.5	77.5	38.3	1.28	82.4	17.6	0.0	0.0	22.6	15.2	38.3	24.0	0.16	0.37	0.17	6.9e1	2.9e-4	0.62	1.85	1.03	2.4e5	7.1e-3
15	66.7	41.8	1.39	89.5	10.5	0.0	0.0	15.6	38.8	28.5	17.1	0.12	0.35	0.16	6.0e1	2.1e-4	1.50	4.69	1.76	9.8e5	3.4e-2
17.5	37.1	43.3	1.40	78.5	21.5	0.0	0.0	21.9	31.7	20.7	25.7	0.12	0.35	0.16	4.1e1	1.7e-4	2.75	8.18	3.02	1.0e6	9.8e-2
20	9.1	36.7	1.15	82.5	17.5	0.0	0.0	25.9	12.1	33.7	28.3	0.13	0.40	15.7	6.1e1	2.0e-4	31.0	97.8	15.7	1.1e8	1.1e1

Tab. 6.8: Testergebnisse: Variation der Diskretisierungsdichte

Aufnahmen zur Folge haben. Bei durchschnittlich 7.2 Beobachtungen pro Aufnahme würden also ca. 100 zusätzliche Beobachtungen gemacht werden, während sich die Zahl der Unbekannten nur um die Parameter der zusätzlichen Kameraposen ($3 \cdot 14 = 52$) erhöhte. Die Anzahl der Objektpunkte bliebe dagegen gleich.

Vorangehende Betrachtung kann auch auf den 3D-Fall übertragen werden. Hier bringt jede Kamerapose 6 und jeder Objektpunkt 3 unbekannte Parameter mit sich. Der für L_{disk} mindestens notwendige Wert verringert sich somit. Bei $Red = 3$ wäre eine Dichte von 5 cm notwendig. Bei einer Dichte von 7.5 cm würden 649 Beobachtungen 660 Unbekannte³ gegenüberstehen. Das Gleichungssystem wäre damit unterbestimmt.

Bezüglich der Anzahl der Kameraposen und auch der Effizienz ist bei einer Variation von L_{disk} kein Trend erkennbar. Selbiges gilt für die V_A und die V_W Werte. Es war zu erwarten, dass sich die Bedingungen, mit denen ein einzelnes Element erfasst wird, nicht ändern. Dies bestätigt sich durch die über alle L_{disk} konstanten Werte der Ausgleichungen bei denen durch das Festhalten aller Kameraposen über das Datum verfügt wurde. Die Ergebnisse der Gesamtspurminimierung weisen dagegen einen deutlichen Trend in Abhängigkeit von L_{disk} und damit der Anzahl der Freiheitsgrade auf. Während bei $L_{disk} = 1.25$ cm eine Mittlere Koordinatengenauigkeit von 0.29 cm erreicht wird, steigt diese bei einem Abnehmen der Zahl der Freiheitsgrade an. Das Verhältnis der Ellipsenachsen bleibt bei einer hohen Anzahl an Freiheitsgraden konstant. Beide Kenngrößen verschlechtern sich erheblich, wenn die Anzahl der Freiheitsgrade gegen Null geht.

6.1.5 Variation der Merkmalsverteilung

Bisherige Untersuchungen gingen davon aus, dass die detektierbaren Merkmalspunkte im Objekt gleichabständig verteilt sind. In Innenräumen ist sowohl mit stark variabel texturierten Oberflächen (z.B. Bildern) als auch Oberflächen mit sehr geringer Textur (z.B. unifarbene Wände) zu rechnen. Entsprechend werden die detektierbaren Merkmale in der Realität ungleich verteilt sein.

Folgender Test sollte zeigen, wie sich der Grad der Ungleichverteilung auf die Messalgorithmen bzw. die Rekonstruktion selbst auswirkt. Als Maß für die Verteilung der Merkmalspunkte wurden die Abstände zu ihren benachbarten Vorgänger- bzw. Folgepunkten betrachtet. Da die Abstände zwischen allen Umgebungselementen E definitionsgemäß gleich sind, wurden für den Test aus diesen nur Teilmengen mit

³ $6 \cdot 35$ Kameraposen + $3 \cdot 150$ Elementkoordinaten

konstanter Anzahl zufällig gewählt (\rightarrow Merkmalspunkte). Als Verteilungsmaß wurde die Standardabweichung σ_E der Abstände nach Gleichung A.38 genutzt. Beispiele für unterschiedliche Verteilungsgrade finden sich in den Abbildungen 6.4a und 6.4b.

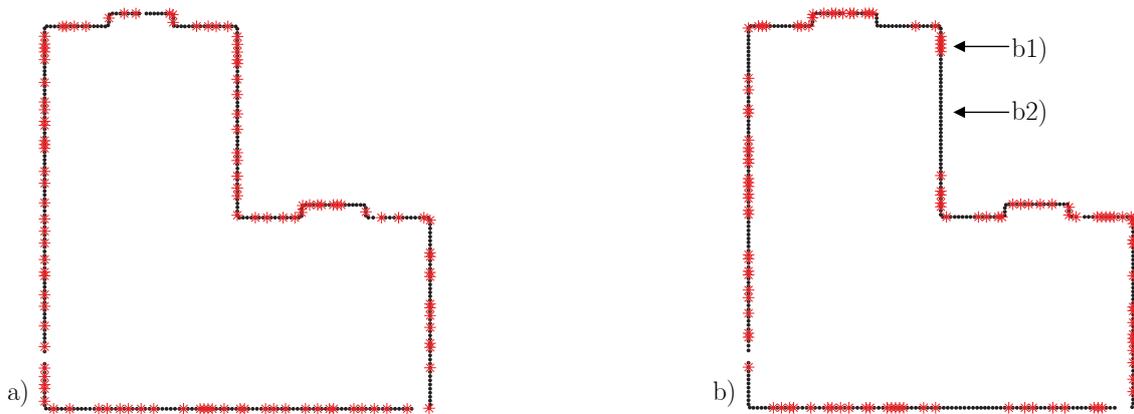


Abb. 6.4: Wahl von Merkmalspunkten mit unterschiedlichen Verteilungsgraden

a) Gleichmäßige Verteilung: $\sigma_E = 0.12$ [m]

b) Ungleichmäßige Verteilung: $\sigma_E = 0.24$ [m]

b1) Für Untersuchung gewählte Umgebungselemente \rightarrow Merkmalspunkte

b2) Äquidistante Umgebungselemente E mit hoher Diskretisierungsdichte L_{disk}

Auf diesem Weg wurde zunächst eine Vielzahl⁴ an zufällig verteilten Merkmalspunktmengen generiert. Aus dieser Menge konnten nun Konstellationen mit unterschiedlichen Verteilungsgraden gewählt werden. Die große Anzahl der generierten Mengen war nötig, da die σ_E aufgrund der Zufallswahl gleichverteilt sind und somit sehr gleich- bzw. ungleichverteilte Konstellationen selten generiert werden. Die Verteilung der Standardabweichungen ist in Abbildung 6.5 dargestellt.

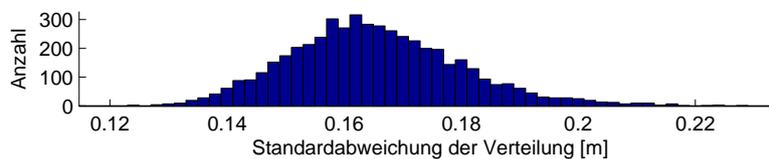


Abb. 6.5: Verteilung der Verteilungsgrade bzw. σ_E

Zur Untersuchung wurden für 5 unterschiedliche σ_E jeweils 11 Verteilungskonstellationen generiert und evaluiert. Auf jede der Konstellationen wurden die Algorithmen der Messstrategie angewandt und die Ergebnisse der 11 Konstellationen gemittelt. Zunächst wurde eine Redundanz von 3 gefordert. Die Ergebnisse dieser Testreihe finden sich in Tabelle 6.9.

Die Testreihe zeigte, dass die Variation der Verteilung keinen Einfluss auf die allgemeinen Parameter als auch die Parameter der Merkmalerkennung hat (Spalten 1-11). Anders verhält es sich mit der Genauigkeit mit der die Objektpunkte rekonstruiert werden können. Die Mittlere Koordinatengenauigkeit steigt z.B. mit Erhöhung des Verteilungsfaktors von 1.15 cm auf 2.2e5 cm stark an. Mit den Achsgrößen der Konfidenzellipsen verhält es sich entsprechend. Dies hängt damit zusammen, dass eine erhöhte Ungleichverteilung dazu führt, dass Teilbereiche der Umgebung zwar redundant erfasst werden, jedoch nur eine geringe Überlappung zum restlichen Aufnahmeverband besteht. Ist dies der Fall, entstehen in diesen Bereichen durch die Fehlerfortpflanzung im Zuge der Ausgleichung sehr hohe Fehlerwerte. Dies schlägt sich in den Durchschnittswerten in Tabelle 6.9 nieder.

Der Test motivierte dazu eine weitere Testreihe mit einer erhöhten Redundanzforderung durchzuführen,

⁴5000

Verteilung	Allgemein		Abstandverhältnis				Winkeldifferenzen				Alle Kameraposen					Gesamtspurminimierung				
	Anzahl der Posen	Effizienz	< 1.5 [%]	< 2.0 [%]	< 2.5 [%]	> 2.5 [%]	< 15°	< 30°	< 45°	> 45°	Mit. Koordinatengen. [cm]	∅ große Halbachse [cm]	∅ kleine Halbachse B [cm]	Isotropie [m]	Spur- Var. Kriterium [m]	Mit. Koordinatengen. [cm]	∅ große Halbachse A [cm]	∅ kleine Halbachse B [cm]	Isotropie [m]	Spur- Var. Kriterium [m]
0.12	39.2	1.55	86.8	18.5	2.0	0.6	12.5	40.2	18.3	29.0	0.14	0.37	0.16	1.8e2	3.9e-4	1.15	3.44	1.71	3.2e5	3.2e-2
0.15	38.6	1.47	86.7	13.2	0.2	0.0	14.0	23.1	28.5	13.7	0.13	0.36	0.15	1.4e2	3.6e-4	1.88	5.74	2.14	1.2e6	1.2e-1
0.18	40.2	1.58	84.5	14.9	0.7	0.0	13.7	31.3	30.1	25.0	0.12	0.35	0.15	1.7e1	3.2e-4	3.16	9.84	2.22	7.3e6	4.9e-1
0.21	39.6	1.58	83.8	16.1	0.3	0.0	12.7	34.0	30.4	22.9	0.14	0.36	0.15	1.1e2	3.5e-4	1.8e5	5.6e5	1.5e6	1.1e16	2.1e9
0.24	38.8	1.58	81.4	18.5	0.2	0.0	18.1	33.8	18.6	29.4	0.13	0.35	0.15	14.4	3.5e-4	2.2e5	5.8e5	1.7e5	1.7e16	3.1e9

Tab. 6.9: Testergebnisse: Variation von σ_E mit $Red = 3$

deren Ergebnisse in Tabelle 6.10 dargestellt sind. Es zeigt sich, dass der beschriebene Effekt durch die Erhöhung der Redundanz auf 4 stark reduziert werden konnte. Es ist immernoch ein leichter Anstieg der Mittleren Koordinatengenauigkeit zu erkennen. Dieser ist mit einem Maximalwert von 2.68 cm bei einem Verteilungsfaktor von 0.24 vergleichsweise klein.

Da in Innenräumen durchaus mit einer erhöhten Ungleichverteilung zu rechnen ist, zeigt dieser Test, dass eine ausreichend redundante Erfassung der Szene unabdingbar ist.

Verteilung	Allgemein		Abstandverhältnis				Winkeldifferenzen				Alle Kameraposen					Gesamtspurminimierung				
	Anzahl der Posen	Effizienz	< 1.5 [%]	< 2.0 [%]	< 2.5 [%]	> 2.5 [%]	< 15°	< 30°	< 45°	> 45°	Mit. Koordinatengen. [cm]	∅ große Halbachse A [cm]	∅ kleine Halbachse B [cm]	Isotropie [m]	Spur- Var. Kriterium [m]	Mit. Koordinatengen. [cm]	∅ große Halbachse A [cm]	∅ kleine Halbachse B [cm]	Isotropie [m]	Spur- Var. Kriterium [m]
0.12	53.0	1.53	90.8	9.2	0.0	0.0	17.1	50.2	20.3	12.3	0.10	0.29	0.13	69.9	4.2e-3	1.44	4.42	1.18	5.7e5	6.7e-2
0.15	53.6	1.51	92.1	7.5	0.3	0.0	17.9	42.2	21.1	18.9	0.10	0.29	0.14	1.0e1	2.3e-4	0.72	2.15	1.12	7.3e4	2.9e-2
0.18	51.4	1.47	93.2	6.8	0.0	0.0	15.5	43.8	21.9	18.9	0.10	0.30	0.13	9.8e1	2.5e-4	1.13	3.54	1.36	2.0e5	3.2e-2
0.21	50.2	1.49	89.6	10.4	0.0	0.0	13.2	42.8	22.4	21.6	0.11	0.31	0.14	1.4e2	2.7e-4	2.19	8.00	2.38	1.9e6	0.18
0.24	51.6	1.55	87.2	12.6	0.0	0.0	22.0	38.5	21.5	18.0	0.10	0.30	0.13	8.6e1	2.4e-4	2.68	10.15	1.83	3.2e6	0.54

Tab. 6.10: Testergebnisse: Variation der Verteilung mit $Red = 4$

6.1.6 Variation der Iterationen

Der Algorithmus zur Bestimmung der Messkonfiguration beruht auf einer iterativen pseudozufälligen Wahl und Bewertung von Posekandidaten. Die Wahrscheinlichkeit die Posekandidaten mit bestmöglicher Bewertung zu finden, hängt damit von der Anzahl der Iterationen IA_1 ab, die der Algorithmus durchläuft. In diesem Test soll geklärt werden, welche Wahl von IA_1 hinsichtlich einer robusten Auffindung sinnvoller Kameraposen notwendig ist. In der Testreihe wurden für verschiedene Iterationszahlen bei geforderter Redundanz $Red = 4$ jeweils 11 Messkonfigurationen bestimmt und deren Ergebnisse verglichen (siehe Tabelle 6.11).

Bei Betrachtung der Ergebnisse ist zu erkennen, dass alle Testgrößen bis auf die Anzahl der benötigten Kameraposen sowie die Effizienz unter Variation von IA_1 konstante Werte aufzeigen. Das Testergebnis läßt sich dahingehend interpretieren, dass bei einer Erhöhung von IA_1 mit weniger Aufwand bzw. weniger benötigten Kameraposen eine Rekonstruktion der Umgebung mit gleicher Güte bzw. Genauigkeit möglich ist.

Iterationszahl IA_1	Allgemein		Abstandverhältnis				Winkeldifferenzen				Alle Kameraposen					Gesamtspurminimierung				
	Anzahl der Posen	Effizienz	< 1.5 [%]	< 2.0 [%]	< 2.5 [%]	> 2.5 [%]	< 15°	< 30°	< 45°	> 45°	Mit. Koordinatengen. [cm]	∅ große Halbachse A [cm]	∅ kleine Halbachse B [cm]	Isotropie [m]	Spur- Var. Kriterium [m]	Mit. Koordinatengen. [cm]	∅ große Halbachse A [cm]	∅ kleine Halbachse B [cm]	Isotropie [m]	Spur- Var. Kriterium [m]
1	73.4	1.64	89.7	10.2	0.1	0.0	16.1	38.4	23.8	21.7	0.13	0.37	0.12	3.2e2	6.7e-4	0.52	1.54	0.82	7.3e4	1.4e-2
5	62.2	1.59	95.1	4.9	0.0	0.0	22.0	37.2	17.9	23.0	0.11	0.38	0.14	3.1e2	6.7e-4	0.46	1.38	0.71	1.8e5	1.1e-2
10	59.4	1.53	95.0	5.0	0.0	0.0	17.6	39.2	26.6	16.6	0.12	0.34	0.11	3.3e2	6.4e-4	0.43	1.27	0.70	2.2e56	9.2e-3
30	58.0	1.53	94.0	6.5	0.0	0.0	22.0	44.8	18.1	15.1	0.19	0.29	0.13	3.2e2	6.1e-4	0.42	1.24	0.68	1.4e5	8.8e-3
60	57.0	1.55	91.4	8.5	0.1	0.0	26.8	36.5	21.7	15.0	0.11	0.29	0.12	2.9e2	5.8e-4	0.42	1.24	0.63	2.7e5	8.6e-3
90	56.4	1.53	93.1	6.8	0.2	0.0	18.6	42.7	21.0	17.7	0.09	0.32	0.13	2.9e2	6.4e-4	0.39	1.16	0.62	2.1e5	7.4e-3
120	58.4	1.57	92.8	7.0	0.2	0.0	20.2	44.7	20.1	15.0	0.11	0.30	0.12	3.1e2	6.0e-4	0.43	1.29	0.67	2.4e5	9.1e-3
150	56.0	1.51	97.2	2.8	0.0	0.0	20.1	35.0	28.2	16.7	0.10	0.30	0.12	2.8e2	5.6e-4	0.46	1.36	0.70	2.9e5	1.1e-2
300	54.8	1.50	93.1	6.9	0.0	0.0	22.5	40.4	22.4	14.7	0.10	0.30	0.12	3.0e2	5.9e-4	0.41	1.21	0.66	1.9e5	8.1e-3

Tab. 6.11: Testergebnisse: Variation der Iterationsanzahl IA_1

Die Anzahl der Kameraposen nimmt bis zu einer Iterationszahl von 60 ab und bleibt von da an nahezu konstant. Die Effizienz erreicht bereits ab $IA_1 = 10$ einen konstanten Wert. Die Effizienz gibt das Verhältnis zwischen der Summe der durchgeführten und den tatsächlich notwendigen Beobachtungen wieder. Somit zeigt sich hier, dass bei einer Erhöhung der Iterationszahl mit weniger Kameraposen die selbe Anzahl an Beobachtungen durchgeführt werden konnte, die Anzahl der Beobachtungen pro Pose also gestiegen ist. Aufgrund des Testergebnisses wurde für den weiteren Einsatz der Messstrategie eine Iterationszahl von $IA_1 = 60$ gewählt.

6.1.7 Auswirkung von Fehlmessungen auf die Parameterschätzung

Im realen Anwendungsfall erfolgt die Punktzuordnung über die SIFT Deskriptoren. Auftretende Fehlzuordnungen werden durch Konsistenzprüfungen wie dem Vergleich von Epipolarlinien oder der Bestimmung der Reprojektionsfehler zu eliminieren versucht (vgl. Kapitel 5.1.2). Alle verbleibenden Fehlzuordnungen wirken sich fehlerhaft auf die Parameterbestimmung im Bündelausgleich aus. Deren Einfluss sollte in einem Test untersucht werden.

Der Einfluss von Fehlzuordnungen läßt sich in der theoretischen Betrachtung simulieren, indem die Beobachtungen l_i mit einem Zufallsrauschen versehen werden. In einer Testreihe wurde der Zusammenhang zwischen der Qualität der Eingangsdaten, also der Genauigkeit der Bildbeobachtungen $\sigma(l_i)$, mit den Genauigkeiten der resultierenden Parameter \hat{X} verglichen.

Evaluiert wurden die resultierenden Parameterabweichungen unter Variation der Verrauschungsintensität sowie der Diskretisierungsdichte. Für jede Diskretisierungsdichte wurden 11 Posensätze ermittelt. Alle Posensätze wurden unter Einfluss von 13 verschiedenen Verrauschungsintensitäten ausgeglichen. Da in der theoretischen Betrachtung die Sollkoordinaten der Objektpunkte als auch der Kameraposen bekannt sind, läßt sich eine Genauigkeitsaussage durch einen Vergleich mit den resultierenden Istwerten treffen. Die Tabellen 6.12 und 6.13 stellen die Standardabweichungen der euklidischen Abstände zwischen Soll- und Istwerten der Objektpunkte bzw. der Kameraposen dar.

Eine angenommene Bildmessgenauigkeit von 1 [px] im Rahmen der SIFT Merkmalerkennung (vgl. Kapitel 5.2.3) ergibt im Richtungsnetz eine maximale Winkelmessgenauigkeit von 0.029° . In der Versuchsreihe wurde dieser Wert mit dem Faktor 2 variiert.

Die Testergebnisse zeigen einerseits deutlich den Zusammenhang zwischen dem Ansteigen der Objektpunktabweichungen bei zunehmender Rauschintensität. Zudem läßt sich eine Abhängigkeit des

	Standardabweichung [cm]			der Verrauschung [°]										
	$0.029 \cdot 2^{-3}$	$0.029 \cdot 2^{-2}$	$0.029 \cdot 2^{-1}$	$0.029 \cdot 2^0$	$0.029 \cdot 2^1$	$0.029 \cdot 2^2$	$0.029 \cdot 2^3$	$0.029 \cdot 2^4$	$0.029 \cdot 2^5$	$0.029 \cdot 2^6$	$0.029 \cdot 2^7$	$0.029 \cdot 2^8$	$0.029 \cdot 2^9$	
D.dichte [cm]	1.25	1.85e-2	3.94e-2	1.06e-1	7.09e-2	2.74e-1	3.66e-1	1.29e+0	2.70e+0	6.44e+0	1.02e+1	1.85e+3	2.17e+5	1.95e+8
	2.50	3.75e-2	1.04e-1	2.00e-1	1.61e-1	4.32e-1	6.30e-1	3.11e+0	5.27e+0	1.23e+1	2.68e+1	7.69e+3	1.84e+5	7.86e+8
	5.00	5.44e-2	8.33e-2	3.30e-1	1.84e-1	9.68e-1	1.22e+0	3.13e+0	8.18e+0	2.00e+1	2.15e+1	1.05e+2	9.81e+5	4.32e+7
	10.00	1.33e-1	4.29e-1	6.76e-1	6.19e-1	1.23e+0	1.96e+0	1.23e+1	1.82e+1	4.16e+1	1.11e+2	3.73e+4	1.06e+4	3.78e+9
	20.00	1.15e-1	1.97e-1	3.17e-1	6.51e-1	1.36e+0	3.83e+0	4.01e+0	9.82e+0	3.35e+1	7.62e+1	5.81e+1	3.49e+4	8.07e+6
	40.00	4.56e-1	1.71e+0	2.08e+0	1.39e+0	7.22e+0	2.78e+1	2.34e+1	5.22e+1	8.57e+10	1.99e+9	1.61e+13	2.03e+11	1.30e+10

Tab. 6.12: Standardabweichungen der Objektpunktposen bei Rauschvariation der Bilddaten

	Standardabweichung [cm]			der Verrauschung [°]										
	$0.029 \cdot 2^{-3}$	$0.029 \cdot 2^{-2}$	$0.029 \cdot 2^{-1}$	$0.029 \cdot 2^0$	$0.029 \cdot 2^1$	$0.029 \cdot 2^2$	$0.029 \cdot 2^3$	$0.029 \cdot 2^4$	$0.029 \cdot 2^5$	$0.029 \cdot 2^6$	$0.029 \cdot 2^7$	$0.029 \cdot 2^8$	$0.029 \cdot 2^9$	
D.dichte [cm]	1.25	1.49e-2	3.66e-2	1.13e-1	7.74e-2	2.39e-1	3.78e-1	1.24e+0	2.28e+0	5.26e+0	1.47e+1	3.50e+3	9.84e+4	2.36e+9
	2.50	3.11e-2	8.65e-2	2.67e-1	1.99e-1	3.86e-1	7.77e-1	2.76e+0	4.37e+0	1.05e+1	4.20e+1	1.41e+4	1.16e+5	9.55e+9
	5.00	4.22e-2	8.90e-2	2.73e-1	1.64e-1	8.36e-1	1.09e+0	3.23e+0	7.02e+0	1.55e+1	2.51e+1	7.55e+1	4.07e+5	2.50e+6
	10.00	1.16e-1	3.55e-1	1.10e+0	8.65e-1	1.09e+0	2.87e+0	1.09e+1	1.51e+1	3.79e+1	1.93e+2	7.44e+4	1.53e+5	5.03e+10
	20.00	9.54e-2	1.84e-1	2.93e-1	6.93e-1	1.52e+0	3.26e+0	3.89e+0	1.22e+1	2.91e+1	6.32e+1	7.61e+1	4.01e+4	1.95e+6
	40.00	3.56e-1	1.34e+0	1.66e+0	1.39e+0	6.75e+0	1.98e+1	2.26e+1	4.84e+1	1.23e+11	1.82e+9	1.34e+13	1.59e+11	1.24e+10

Tab. 6.13: Standardabweichungen der Kameraposen bei Rauschvariation der Bilddaten

resultierenden Genauigkeitsniveaus von der Merkmalsanzahl bzw. der Diskretisierungsdichte nachweisen. Da die künstlich angebrachten Fehler zufallsverteilt sind, erbringt eine Steigerung der Redundanz hier eine Genauigkeitssteigerung. Die Abweichungen der Objektpunkte und der Kameraposen weisen ein ähnliches Genauigkeitsniveau auf. Auf eine zusätzliche Variation der Merkmalsverteilung wurde an dieser Stelle verzichtet. Zu erwarten wäre auch hier, dass sich eine zunehmende Ungleichverteilung der Merkmale im Objektraum negativ auf die Parameterschätzung auswirkt (vgl. Abschnitt 6.1.5).

6.2 Empirische Evaluierung

In diesem Abschnitt wird das 3D Messsystem anhand von Versuchen in einer realen Innenraumumgebung untersucht.

Das verwendete Rekonstruktionsmodul arbeitet nicht deterministisch. Das bedeutet, dass die Rekonstruktionsergebnisse variieren, auch wenn alle eingehenden Größen und Parameter bei wiederholter Ausführung festgehalten werden. Bei jedem der aufgeführten Versuche wurde die Rekonstruktion daher mehrfach wiederholt. Die dargestellten Ergebnisse stellen jedoch nicht den Mittelwert dieser Versuchsreihen dar, sondern repräsentieren vielmehr die für einen Versuch charakteristischen Resultate. Eine ausführlichere Durchführung separater Messreihen für jeden der Versuche hätte für diese Arbeit einen zu großen Zeitaufwand bedeutet, die Ergebnisse dafür aber mit statistischen Kenngrößen hinterlegt. Wie in Kapitel 5.1.2 beschrieben, ist das Rekonstruktionsergebnis abhängig von der Wahl einer Vielzahl von Parametern bzw. Schwellwerten. Aus Gründen der Vergleichbarkeit, aber auch aufgrund des erheblichen Mehraufwands, wurde mit Ausnahme von Abschnitt 6.2.1 auf eine Parametervariation verzichtet. Der in den Versuchen verwendete Parametersatz ist in Anhang A.14 abgebildet.

Erläuterung der Testparameter

Für eine empirische Evaluation wurden unterschiedliche Testgrößengruppen betrachtet, die in Tabelle 6.14 näher erläutert werden.

Allgemein		Beobachtungen			Genauigkeiten						
				MViO ⁷	Theoretisch			Praktisch			
Anzahl der Posen ¹ []											
Anzahl der Aufnahmen ² []											
zurückgelegte Strecke ³ [m]											
Anzahl rekonstruierter Punkte ⁴ []											
∅ Anzahl der Merkmale ⁵ []											
∅ Merkmalsverteilung im Bild ⁶ [%]											
∅ Punkte pro Volumenelement: 0 [%]											
∅ Punkte pro Volumenelement: < 10 [%]											
∅ Punkte pro Volumenelement: 10 – 50 [%]											
∅ Punkte pro Volumenelement: > 50 [%]											
Mit. Koordinatengen. ⁸ [cm]											
∅ Halbachse A ⁹ [cm]											
∅ Halbachse B ⁹ [cm]											
∅ Halbachse C ⁹ [cm]											
Isotropie ⁸ [m]											
Spur- Var. Kriterium ⁸ [m]											
∅ Lotabstände ¹⁰ [cm]											
Ausreißer ¹¹ [%]											
∅ Posedifferenzen ¹² [cm]											
∅ Posedifferenzen ¹² [°]											

¹ Anzahl der getätigten Aufnahmen

² Anzahl der im Bündelausgleich verwendeten bzw. zur Rekonstruktion genutzten Aufnahmen

³ Gesamtstrecke die vom System zum Besuch aller Posen zurückgelegt wurde. Die Wege vor der ersten und nach der letzten Pose sind nicht mit eingerechnet.

⁴ Anzahl der Umgebungspunkte, die rekonstruiert wurden

⁵ Durchschnittliche Anzahl der in einer Aufnahme verwendeten Merkmale

⁶ Durchschnittliche Fläche der konvexen Hülle um alle in einer Aufnahme gefundenen und im Bündel verwendeten Merkmale in Relation zur gesamten Bildgröße (vgl. Abbildung 6.6)

⁷ Merkmalsverteilung im Objekt: Prozentualer Anteile der Objektpunktzahlen in den Volumenelementen (vgl. Abbildung 6.7)

⁸ Globales Genauigkeitskriterium (siehe Anhang A.15.3)

⁹ Halbachse der Konfidenzellipse bei einem Quantil von $1 - \alpha = 95\%$

¹⁰ Durchschnitt der Lotabstände der rekonstruierten Umgebungspunkte zum Referenzmodell

¹¹ Prozentualer Anteil der als Ausreißer klassifizierten Umgebungspunkte

¹² Durchschnittliche Differenz zwischen den Roboterposen gemäß der Bündelausgleichung und der 2D-Lokalisierung. Die Ergebnisse der in situ Kalibrierung wurden dabei invers auf die Resultate der Bündelausgleichung angewendet. Untersucht wurden die Differenzen der 2D Posen x, y sowie der Richtungswinkel ϕ .

Tab. 6.14: Erläuterung der in den Testreihen evaluierten Kenngrößen

Die Kenngrößen lassen sich in zwei Gruppen einteilen. In den Spalten 1-3 in Tabelle 6.14 finden sich allgemeine Kenngrößen bezüglich der für eine Innenraumszene ermittelten Messkonfiguration. Die Größen der Spalten 4-10 geben Auskunft über das Beobachtungsmaterial. Ermittelt wird die Anzahl der rekonstruierten Punkte, sowie deren Verteilung im Objektraum. Hierbei wurde die Szene in Voxel gleicher Größe (40 cm Kantenlänge) unterteilt (Abbildung 6.7) und die Objektpunktzahl innerhalb jedes Voxels ermittelt. Die vier gewählten Intervalle können mit den Beurteilungen "sehr gut", "gut", "ausreichend" und "mangelhaft" interpretiert werden. Die Voxelgröße wurde so gewählt, dass von der Kamera bei einer Senkrechtaufnahme einer Ebene aus 2.5 m Abstand in horizontaler Richtung 10 Voxel erfasst werden. Eine Evaluationsgröße für die Verteilung der Merkmalspunkte im Bild ergibt sich dagegen über die Fläche der konvexen Hülle um die Merkmalspunkte (Abbildung 6.6). Eine ungünstige Verteilung kann sich negativ auf die Rekonstruktionsgüte auswirken.

Die Größen der Spalten 11-16 resultieren aus der theoretischen Analyse der Genauigkeiten im Rahmen

der Ausgleichung (vgl. Anhang A.4) vergleichbar mit den ermittelten Genauigkeiten in Abschnitt 6.1. Die praktischen Genauigkeiten in den Spalten 17-20 ergeben sich dagegen aus einem empirischen Vergleich mit einem Referenzmodell bzw. Referenzlokalisierungen. Aufgrund einer fehlerhaften Rekonstruktion weisen einzelne Objektpunkte einen sehr großen Lotabstand zum Referenzmodell auf. Da diese Ausreißer einen wesentlichen Einfluss auf die durchschnittliche Abweichung hätten, werden Punkte mit einem Lotabstand > 30 cm nicht in die Berechnung mit einbezogen. Stattdessen erfolgt eine prozentuale Angabe des Ausreißeranteils.

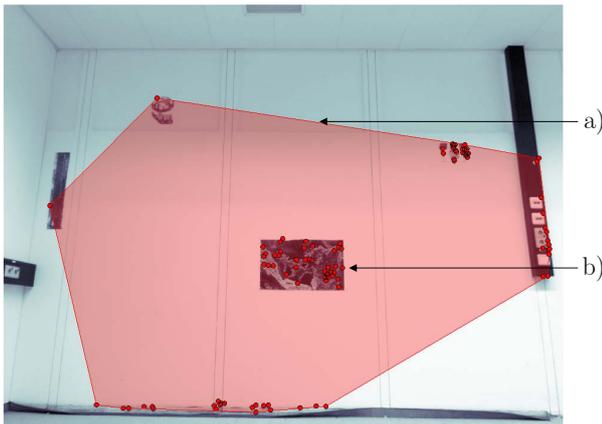


Abb. 6.6: Evaluierung der Merkmalsverteilung im Bild anhand der Fläche der konvexen Hülle
a) Konvexe Hülle
b) Merkmalspunkte

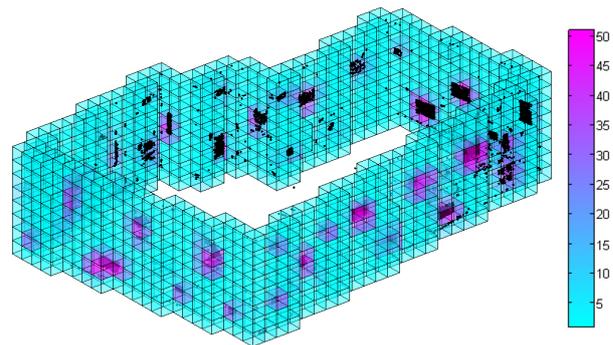


Abb. 6.7: Evaluierung der Merkmalsverteilung im Objekt durch die Einteilung der Szene in Voxel. Einfärbung der Voxel in Abhängigkeit der Objektpunktzahl pro Voxel (Skala).

Bestimmung der Konfidenzellipsoide

Das Rekonstruktionsmodul gibt die Kofaktoren q_{xixi} (vgl. Gleichung A.39) jedes Objektpunktes als auch den a posteriori Schätzwert s_0^2 für die Varianz der Gewichtseinheit zurück. So ergeben sich die Halbachsen D_{Ki} des Konfidenzellipsoids gemäß Gleichung A.49 über:

$$D_{Ki} = \sqrt{s_0^2 \cdot \lambda_i \cdot 3 \cdot F_{0.95,3,n-u}} \quad (6.2)$$

6.2.1 Parametervariationen

Im Folgenden wird der Einfluss von zwei wesentlichen Parametern (*outlier reprojection error: ORE* und *bundle final full min views: BMV*)⁵ untersucht. Als Datenbasis dienen die Aufnahmen einer Einzelmessung der Versuchsumgebung (vgl. Messreihe 1 in Abschnitt 6.2.2).

Variation des Schwellwertes für den Reprojektionsfehler

Der Parameter *ORE* gibt den maximal zulässigen Reprojektionsfehler aller Beobachtungen im Bündelausgleich vor, also den maximalen Versatz, dem ein beobachteter Punkt im Bild unterliegen darf (vgl. Kapitel 5.1.2). So führt eine strengere Wahl des *ORE* dazu, dass nur die Beobachtungen verwendet werden, die im Bündelmodell ausreichend genau mit den gleichzeitig ermittelten Kameraposen und Objektpunkten übereinstimmen. Ob sich mit der Verwendung von weniger, aber im Hinblick auf das Modell stimmigeren Beobachtungen in der Praxis eine höhere Gesamtgenauigkeit erzielen lässt, wurde durch eine Versuchsreihe unter Variation des *ORE* bestimmt.

⁵siehe im Anhang A.14 (rot hinterlegte Zeilen)

Die Wahl des *ORE* sollte prinzipiell in Abhängigkeit von der Genauigkeit des vorliegenden Datenmaterials geschehen. Eine Auskunft darüber geben die im Bündelausgleich an den Beobachtungen angebrachten Verbesserungen, welche in Abbildung 6.8 für den vorliegenden Datensatz abgebildet sind.

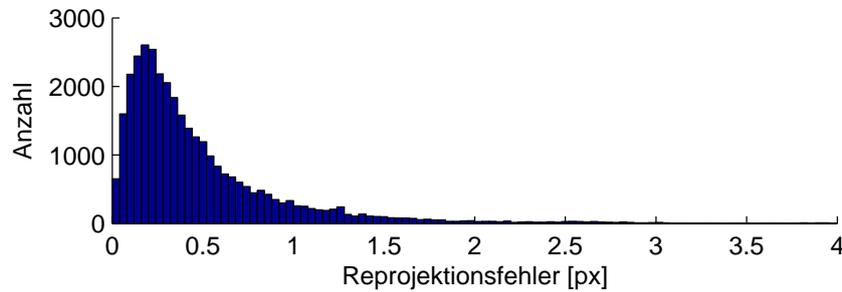


Abb. 6.8: Verteilung der Reprojektionsfehler aller Beobachtungen in den Aufnahmen eines Datensatzes

Entsprechend dieser Verteilung wurde in der Versuchsreihe der *ORE* zwischen 0.5 und 4.0 Pixeln variiert. Die Ergebnisse des Versuchs finden sich in Tabelle 6.15.

	Allgemein					Beobachtungen							Genauigkeiten										
maximaler Reprojektionsfehler <i>ORE</i> [px]	s_0 [px]	Anzahl der Posen []	Anzahl der Aufnahmen []	zurückgelegte Strecke [m]	Anzahl rekonstruierter Punkte []	∅ Anzahl der Merkmale []	∅ Merkmalsverteilung im Bild [%]	∅ Punkte pro Volumenelement: 0 [%]	∅ Punkte pro Volumenelement: < 10 [%]	∅ Punkte pro Volumenelement: 10 – 50 [%]	∅ Punkte pro Volumenelement: > 50 [%]	Mit. Koordinatengen. [cm]	∅ Halbachse A [cm]	∅ Halbachse B [cm]	∅ Halbachse C [cm]	∅ Volumen des Konfidenzellipsoids [cm ³]	Isotropie [m]	Spur- Var. Kriterium [m]	∅ Lotabstände [cm]	Ausreißer [%]	∅ Posedifferenzen [cm]	∅ Posedifferenzen [°]	
0.5	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x
0.75	0.26	70	70	62.45	4830	310.4	39.9	73.2	17.5	6.3	3.0	1.8e-1	3.2e-1	1.1e-1	7.9e-2	1.6e-2	4.8e3	4.5e-3	4.95	2.1e-2	9.77	1.16	
1.0	0.31	70	70	62.45	5298	355.0	39.8	72.5	17.6	6.1	3.7	1.5e-1	3.6e-1	1.3e-1	9.4e-2	2.1e-2	2.4e2	3.5e-3	3.91	7.6e-2	9.22	1.22	
1.5	0.40	70	70	62.45	5812	374.5	48.5	67.9	21.8	6.6	3.7	1.6e-1	4.6e-1	1.7e-1	1.2e-1	4.4e-2	7.5e2	4.1e-3	4.87	0.10	5.21	0.55	
2.0	0.45	70	70	62.45	6027	423.2	45.1	71.2	18.4	6.4	4.0	1.8e-1	5.2e-1	1.9e-1	1.3e-1	7.2e-2	6.3e3	5.3e-3	3.42	0.12	3.67	0.62	
4.0	0.53	70	70	62.45	6364	440.6	52.3	65.9	22.6	7.2	4.2	1.5e-1	5.8e-1	2.2e-1	1.5e-1	9.1e-2	7.5e2	4.3e-3	3.51	0.22	2.00	0.55	

Tab. 6.15: Testergebnisse: Variation des Schwellwertes für den Reprojektionsfehler *ORE*

Bei einem *ORE* Wert von 0.5 scheiterte die Rekonstruktion aufgrund der zu geringen Punktzahl bereits nach der inkrementellen Einbindung von ca. 20 Bildern.

Die Betrachtung der im Bündelausgleich ermittelten s_0 bestätigt zunächst die theoretische Qualitätssteigerung des verwendeten Datenmaterials⁶. Entsprechend ist bei strengerer Wahl des *ORE* ein konstantes Absinken der Anzahl der Modell- als auch der Merkmalspunkte zu verzeichnen. Auch die Größe der Konfidenzellipse verhält sich erwartungsgemäß und verkleinert sich mit einer Verringerung des *ORE*. Die damit zusammenhängende Mittlere Koordinatengenauigkeit $\sigma_{\bar{x}}$ verändert sich jedoch nicht. Dies läßt sich darauf zurückführen, dass in allen Versuchen vereinzelte Punkte mit sehr hohen Varianzen q_{xixi} zu beobachten waren, die einen erheblichen Einfluss auf $\sigma_{\bar{x}}$ haben. Dieser Einfluss ist bei der Bestimmung der Ellipsoidhalbachsen geringer⁷, wodurch der zu erwartende Trend hier sichtbar bleibt. Bei Betrachtung der Ellipsenform ist kein Trend feststellbar.

Zwischen den theoretischen und den praktischen Genauigkeiten ist eine deutliche Diskrepanz erkenn-

⁶ s_0 = „sigma a posteriori“

⁷siehe Gleichungen (6.2) und (A.51)

bar. Vor allem fällt der Unterschied im Genauigkeitsniveau auf. Dieser läßt sich zumindest teilweise damit erklären, dass in die praktischen Genauigkeiten die Fehler der Registrierung mit eingehen, während die Konfidenzellipse nur die Innere Modellgenauigkeit widerspiegeln. Die praktischen Genauigkeiten verbessern sich bei einer strengeren Wahl des *ORE* wider erwarten nicht. Lediglich einer Verringerung des Prozentsatzes der als Ausreißer deklarierten Punkte ist festzustellen. Insgesamt läßt sich sagen, dass eine strengere Wahl des *ORE* keine Verbesserung des Rekonstruktionsergebnisses mit sich bringt. Für *ORE* wurde folglich in den folgenden Versuchen ein Wert von 4.0 gewählt.

Variation der Mindestanzahl von Einzelpunktaufnahmen

Wie in Kapitel 5.1.2 beschrieben, ist das Rekonstruktionsmodul in der Lage korrespondierende Merkmalspunkte über mehrere Aufnahmen hinweg zuzuordnen. Je größer die Anzahl der Aufnahmen, in denen ein Merkmalspunkt wiedererkannt wurde, desto geringer ist die Wahrscheinlichkeit einer fehlerhaften Zuordnung. Im Rahmen der 3D-Rekonstruktion kann der endgültige Bündelausgleich mit dem Parameter *BMV* unter der Forderung erfolgen, nur mindestens *BMV*-fach zugeordnete Punkte zu verwenden.

In folgender Versuchsreihe wurde der schon im vorigen Versuch genutzte Aufnahmeverband, unter variierendem *BMV* ausgeglichen. Die Ergebnisse der Versuchsreihe sind in Tabelle 6.16 abgebildet.

	Allgemein				Beobachtungen								Genauigkeiten									
	minimale Redundanz im Bündel <i>BMV</i> [px]	Anzahl der Posen []	Anzahl der Aufnahmen []	zurückgelegte Strecke [m]	Anzahl rekonstruierter Punkte []	∅ Anzahl der Merkmale []	∅ Merkmalsverteilung im Bild [%]	∅ Punkte pro Volumenelement: 0 [%]	∅ Punkte pro Volumenelement: < 10 [%]	∅ Punkte pro Volumenelement: 10 – 50 [%]	∅ Punkte pro Volumenelement: > 50 [%]	Mit. Koordinatengen. [cm]	∅ Halbachse A [cm]	∅ Halbachse B [cm]	∅ Halbachse C [cm]	∅ Volumen des Konfidenzellipsoids [cm ³]	Isotropie [m]	Spur- Var. Kriterium [m]	∅ Lotabstände [cm]	Ausreißer [%]	∅ Posedifferenzen [cm]	∅ Posedifferenzen [°]
2	70	70	62.45	7110	498.1	53.9	66.0	21.6	7.4	5.0	1.5e-1	5.7e-1	2.2e-1	1.5e-1	9.1e-2	7.7e2	4.2e-3	2.68	0.36	1.90	0.57	
3	70	70	62.45	6735	468.9	47.7	68.0	20.7	6.8	4.4	1.2e-1	4.4e-1	1.8e-1	1.4e-1	4.8e-2	1.1e2	1.2e-3	2.51	0.27	2.75	0.50	
4	70	70	62.45	4494	318.8	42.2	71.6	20.5	4.9	3.0	1.4e-1	5.2e-1	2.0e-1	1.5e-1	7.1e-2	3.9e2	1.9e-3	2.50	0.34	6.39	0.58	
5	70	70	62.45	4444	364.9	43.1	73.7	17.2	6.4	2.7	1.3e-1	5.0e-1	2.0e-1	1.5e-1	6.9e-2	7.3e2	1.8e-3	5.82	1.91	11.03	1.32	
6	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x

Tab. 6.16: Testergebnisse: Variation der minimalen Redundanz im Bündel *BMV*

Bei einem *BMV* Wert von 6 scheiterte die Rekonstruktion aufgrund der zu geringen Punktzahl bereits nach der inkrementellen Einbindung von ca. 35 Bildern.

Entsprechend des ersten Versuchs war die Erwartung, mit einer Erhöhung von *BMV* zwar eine Verringerung der Punktzahl, jedoch eine Verbesserung der Rekonstruktionsgenauigkeit zu erzielen. Dennoch ist auch bei Betrachtung der praktischen Genauigkeiten keine Verbesserung erkennbar. Überdies erhöhen sich die Posedifferenzen mit steigendem *BMV*.

Es zeigt sich, dass die geringere Stabilität der Konfiguration, herrührend von der geringeren Punktzahl, einen stärkeren, negativen Einfluss auf die Rekonstruktion hat, als die vermeintliche Robustheitssteigerung, in diesem Fall durch eine Erhöhung von *BMV*. Da mit *BMV* = 3 das theoretisch und praktisch genaueste Rekonstruktionsergebnis erzielt werden konnte, wurde dieser Wert für die folgenden Versuche beibehalten.

6.2.2 Untersuchung der Wiederholgenauigkeit

In diesem Versuch sollte die Wiederholgenauigkeit des Systems untersucht werden, also die Variation des Rekonstruktionsergebnisses, wenn das System eine Umgebung unter Angabe derselben Eingangsgrößen und Kameraposen mehrmals vermisst. Entsprechend der Einmessung aus Abschnitt 6.2.1 wurden zwei weitere Einmessvorgänge bzw. Rekonstruktionen mit einer geforderten Redundanz von 4 durchgeführt. Die Ergebnisse der drei Versuche sind in Tabelle 6.17 gegenübergestellt.

Messreihe	Allgemein				Beobachtungen								Genauigkeiten									
	Anzahl der Posen []	Anzahl der Aufnahmen []	zurückgelegte Strecke [m]	Anzahl rekonstruierter Punkte []	∅ Anzahl der Merkmale []	∅ Merkmalsverteilung im Bild [%]	∅ Punkte pro Volumenelement: 0 [%]	∅ Punkte pro Volumenelement: < 10 [%]	∅ Punkte pro Volumenelement: 10 – 50 [%]	∅ Punkte pro Volumenelement: > 50 [%]	Mit. Koordinatengen. [cm]	∅ Halbachse A [cm]	∅ Halbachse B [cm]	∅ Halbachse C [cm]	∅ Volumen des Konfidenzellsoids [cm ³]	Isotropie [m]	Spur- Var. Kriterium [m]	∅ Lotabstände [cm]	Ausreißer [%]	∅ Posedifferenzen [cm]	∅ Posedifferenzen [°]	
1	70	70	62.45	6364	440.6	52.3	65.9	22.6	7.2	4.2	1.5e-1	5.8e-1	2.2e-1	1.5e-1	9.1e-2	7.5e2	4.3e-3	3.51	0.22	2.00	0.55	
2	77	77	63.53	7781	534.2	57.7	61.3	25.1	8.9	4.7	1.3e-1	5.1e-1	2.0e-1	1.4e-1	7.0e-2	1.9e2	3.6e-3	2.67	0.10	1.60	0.32	
3	76	76	68.61	8268	514.2	59.0	60.1	25.4	9.7	4.9	1.4e-1	5.2e-1	2.0e-1	1.5e-1	7.2e-2	2.1e2	3.8e-3	2.85	0.50	1.49	0.53	
∅	74.3	74.3	64.86	7471.0	496.3	56.3	62.4	24.4	8.6	4.6	1.4e-1	5.4e-1	2.1e-1	1.5e-1	7.8e-2	3.8e2	3.9e-3	3.00	0.27	1.70	0.47	

Tab. 6.17: Testergebnisse: Wiederholgenauigkeit

Zunächst zeigt sich, dass die Anzahl der durch die Positionierungsstrategie ermittelten Posen zur vollständigen Aufnahme des Raumes in den drei Versuchen um 10% variiert. Durch die höhere Posenzahl im zweiten und dritten Durchgang erhöhte sich hier auch die Anzahl der Beobachtungen bzw. der rekonstruierten Punkte. Zudem ist eine leichte Verbesserung der theoretischen als auch der praktischen Genauigkeiten bei den Einmessungen mit höherer Posenzahl zu erkennen. Insgesamt betrachtet, konnte anhand der Positionierungsstrategie wiederholt eine Rekonstruktion auf gleichbleibendem Niveau durchgeführt werden.

6.2.3 Variation der Redundanz

Der vorige Versuch motiviert dazu die Anzahl der genutzten Kameraposen weiter zu variieren, was sich durch eine Änderung der geforderten Redundanz erzielen läßt. So wurden zwei weitere Einmessvorgänge mit Redundanzwerten von 3 und 5 durchgeführt. Deren Ergebnisse sind den Durchschnittswerten aus Abschnitt 6.2.2 in Tabelle 6.18 gegenübergestellt.

Der Datensatz mit $Red = 3$ hatte ursprünglich nur 61 Posen und konnte nicht vollständig rekonstruiert werden. Stattdessen entstanden zunächst 2 Subkonfigurationen. So wurden mit der in Kapitel 5.3.4 erläuterten Methode zwei weitere Posen hinzugefügt, durch die eine gemeinsame Prozessierung aller Aufnahmen möglich war. Eine Einmessung der vorliegenden Versuchsumgebung mit $Red = 3$ ist also als nicht ausreichend zu erachten. Dies bestätigt die theoretische Untersuchung aus Abschnitt 6.1.5.

Wie zu erwarten, steigt die Anzahl der definierten Kameraposen mit zunehmender Redundanz. Entsprechend ändert sich auch die Anzahl der Beobachtungen und der rekonstruierten Punkte. Auch die Größen der Konfidenzellipse verringern sich mit zunehmender Posenzahl, was wie in Abschnitt 6.2.1 auf die erhöhte Anzahl an Freiheitsgraden im Ausgleichungsmodell zurückzuführen ist. Hinsichtlich

	Allgemein					Beobachtungen						Genauigkeiten										
	geforderte Redundanz []	Anzahl der Posen []	Anzahl der Aufnahmen []	zurückgelegte Strecke [m]	Anzahl rekonstruierter Punkte []	Ø Anzahl der Merkmale []	Ø Merkmalsverteilung im Bild [%]	Ø Punkte pro Volumenelement: 0 [%]	Ø Punkte pro Volumenelement: < 10 [%]	Ø Punkte pro Volumenelement: 10 – 50 [%]	Ø Punkte pro Volumenelement: > 50 [%]	Mit. Koordinatengen. [cm]	Ø Halbachse A [cm]	Ø Halbachse B [cm]	Ø Halbachse C [cm]	Ø Volumen des Konfidenzellipsoids [cm ³]	Isotropie [m]	Spur- Var. Kriterium [m]	Ø Lotabstände [cm]	Ausreißer [%]	Ø Posedifferenzen [cm]	Ø Posedifferenzen [°]
3	63	63	56.45	6872	482.1	52.3	65.0	23.1	7.7	4.1	1.8e-1	7.4e-1	2.7e-1	1.8e-1	1.9e-1	4.8e3	4.7e-3	3.81	0.80	1.84	0.71	
4	74.3	74.3	64.86	7471.0	496.3	56.3	62.4	24.4	8.6	4.6	1.4e-1	5.4e-1	2.1e-1	1.5e-1	7.8e-2	3.8e2	3.9e-3	3.00	0.27	1.70	0.47	
5	92	92	72.00	9027	552.8	57.0	61.7	23.8	9.0	5.5	1.4e-1	5.1e-1	1.8e-1	1.3e-1	5.7e-2	1.3e3	5.5e-3	2.77	0.40	1.97	0.48	

Tab. 6.18: Testergebnisse: Variation der Redundanz

der richtungsbezogenen Fehlerverteilungen, also der Ellipsoidformen ist hingegen keine Verbesserung festzustellen. Bei den praktischen Genauigkeiten ist eine Verbesserung bei Erhöhung der Redundanz von 3 auf 4 festzustellen. Der Redundanzwert von 5 führt jedoch zu keiner weiteren Genauigkeitssteigerung. Auch hier bestätigen sich die Ergebnisse der theoretischen Untersuchung aus Abschnitt 6.1.3, bei denen Redundanzwerte >4 keine wesentlichen Genauigkeitssteigerungen erbrachten.

Eine Erhöhung der Aufnahmeanzahl führt dafür zu einer Erhöhung der Anzahl rekonstruierter Punkte. Wie bereits in Abschnitt 6.2.1 festgestellt, ist eine höhere Objektpunktzahl hinsichtlich der Stabilität des Bündelmodells von Nutzen. Zudem ist eine hohe Punktzahl bzw. Datendichte für eine anschließende Modellierung prinzipiell von Vorteil. Da dabei jedoch eine gleichmäßige Verteilung der Punkte im Objektraum, das ausschlaggebende Kriterium ist, sieht man bei Betrachtung der Werte für die Punktverteilung im Objekt, dass mit der Erhöhung der Redundanz diesbezüglich keine wesentliche Verbesserung erreicht werden konnte.

6.2.4 Variation der Merkmalsdichte

In der Versuchsumgebung wurden mehrere Poster angebracht, um die Zahl der Merkmalspunkte und damit die Robustheit der Rekonstruktion zu erhöhen (Abbildung 6.6). Durch eine Variation der Anzahl dieser Poster wurde in folgender Versuchsreihe untersucht, welchen Einfluss die Texturbeschaffenheit der Umgebung auf die 3D-Rekonstruktion hat. Abgesehen von einer geringeren Datendichte der resultierenden 3D-Punktewolke können sich texturarme Umgebungsbereiche negativ auf die Rekonstruktionsgenauigkeit auswirken. Eine geringe Anzahl, aber auch eine ungünstige Verteilung von Merkmalspunkten führen zu Genauigkeitseinbußen bei der Bestimmung der Bildorientierungen und der Objektpunkte (vgl. Abschnitt 6.1.5).

In der Versuchsreihe wurden drei Datensätze erstellt, in denen die Anzahl der Poster zunehmend reduziert wurde, während die verwendeten Kameraposen beibehalten wurden. Es wurde wieder der bereits in Abschnitt 6.2.1 genutzte Posensatz verwendet. Die Testergebnisse finden sich in Tabelle 6.19.

Durch eine erste Verringerung der Merkmale reduzierte sich erwartungsgemäß die Anzahl der rekonstruierten Punkte. In die Rekonstruktion konnten nur noch 69 Aufnahmen eingebunden werden. Die theoretischen Genauigkeiten verbessern sich zwar leicht, auf praktischer Seite ist jedoch insbesondere bei den Posedifferenzen ein negativer Trend zu verzeichnen.

Selbst im Versuch mit spärlicher Merkmalsdichte verblieben einige Poster an den Wänden der Ver-

Merkmalsdichte	Allgemein			Beobachtungen							Genauigkeiten										
	Anzahl der Posen []	Anzahl der Aufnahmen []	zurückgelegte Strecke [m]	Anzahl rekonstruierter Punkte []	∅ Anzahl der Merkmale []	∅ Merkmalsverteilung im Bild [%]	∅ Punkte pro Volumenelement: 0 [%]	∅ Punkte pro Volumenelement: < 10 [%]	∅ Punkte pro Volumenelement: 10 – 50 [%]	∅ Punkte pro Volumenelement: > 50 [%]	Mit. Koordinatengen. [cm]	∅ Halbachse A [cm]	∅ Halbachse B [cm]	∅ Halbachse C [cm]	∅ Volumen des Konfidenzellsoids [cm ³]	Isotropie [m]	Spur- Var. Kriterium [m]	∅ Lotabstände [cm]	Ausreißer [%]	∅ Posedifferenzen [cm]	∅ Posedifferenzen [°]
normal	70	70	62.45	6364	440.6	52.3	65.9	22.6	7.2	4.2	1.5e-1	5.8e-1	2.2e-1	1.5e-1	9.1e-2	7.5e2	4.3e-3	3.51	0.22	2.00	0.55
gering	70	69	62.45	4670	270.2	41.1	68.8	22.2	6.5	2.5	1.6e-1	5.6e-1	2.2e-1	1.4e-1	8.4e-2	4.8e2	2.9e-3	3.80	0.66	14.39	1.64
spärlich	70	63	62.45	3753	234.9	29.6	82.2	11.2	4.4	2.1	1.4e-1	5.1e-1	2.0e-1	1.4e-1	6.5e-2	2.3e2	1.8e-3	22.77	25.95	5.9e12	55.21

Tab. 6.19: Testergebnisse: Variation der Merkmalsdichte

suchsumgebung. Obwohl noch 63 Aufnahmen in die Rekonstruktion eingebunden werden konnten, ist diese im Hinblick auf die praktischen Genauigkeiten als fehlgeschlagen zu interpretieren, da nur ein Teil der Umgebung rekonstruiert werden konnte. Dies spiegelt sich einerseits in der geringen Anzahl rekonstruierter Punkte wieder. Die sehr großen Abweichungen in den Posedifferenzen weisen zudem darauf hin, dass Aufnahme-Posen völlig falsch rekonstruiert wurden.

So zeigt sich, dass eine Rekonstruktion der vorliegenden Versuchsumgebung ohne das Anbringen zusätzlicher Merkmale nicht möglich ist. Die einheitlich weißen Wände der Umgebung sind zwar ein sehr ungünstiger, aber in der Praxis durchaus zu erwartender Fall für eine texturbasierte Rekonstruktion. Folglich ist die ausschließliche Verwendung von SIFT-Merkmalen an dieser Stelle nicht zielführend.

6.2.5 Vergleich mit Photosynth Strategie

Eine alternative Bewegungsstrategie bzw. ein Regelwerk zur Wahl von Standpunkten bei einer photogrammetrischen Rekonstruktion von Innenräumen findet sich beim Photosynth Projekt der Microsoft Live Labs [74]. Über das Regelwerk wird versucht dem menschlichen Nutzer zu erläutern, von welchen Posen aus dieser innerhalb einer Innenraumszene Aufnahmen zu tätigen hat, um die Szene erfolgreich rekonstruieren zu können. Die Regeln lassen sich folgendermaßen zusammenfassen:

Durch folgenden Versuch sollte ein Vergleich zwischen der im Rahmen dieser Arbeit entwickelten Positionierungsstrategie und der Photosynth Strategie angestellt werden. Dazu wurde für die Innenraumszene manuell ein Satz an Kameraposen gewählt, der sich bestmöglich an den genannten Aufnahmeregeln orientiert (Abbildung 6.9). Für den Vergleich wurden die Durchschnittswerte aus Abschnitt 6.2.3 herangezogen. Um vergleichbare Resultate zu erzielen, wurde im Fall der Photosynth Strategie eine ähnliche Zahl von Kameraposen gewählt. Die Rekonstruktionsresultate der beiden Strategien entstanden unter Verwendung derselben Parametrisierungen und sind in Tabelle 6.20 dargestellt.

Der Versuch zeigt, dass sich durch die Photosynth Strategie keine vergleichbaren Ergebnisse erzielen lassen. Die Anzahl der Bildmerkmale und damit auch der rekonstruierten Punkte ist hier geringer. Zudem weisen diese bezüglich der praktischen Genauigkeiten größere Lotabweichungen als auch eine höhere Ausreißerquote auf. Einen negativen Einfluss auf die Rekonstruktionsgenauigkeit kann unter anderem die Merkmalsverteilung der Punkte im Bild haben, die hier wesentlich geringer ausfällt. Vergleichsweise positiv aber zweitrangig ist dagegen die geringere Strecke, die das System zurücklegen

Photosynth Grundregeln:

- Überlappende Aufnahmen von der Mitte des Raumes mit $\geq 50\%$ Überlappung
- Überlappende Aufnahmen von den Ecken des Raumes
- Überlappende Aufnahmen von den Mitten der Wände
- Zusätzliche Aufnahmen interessanter Details

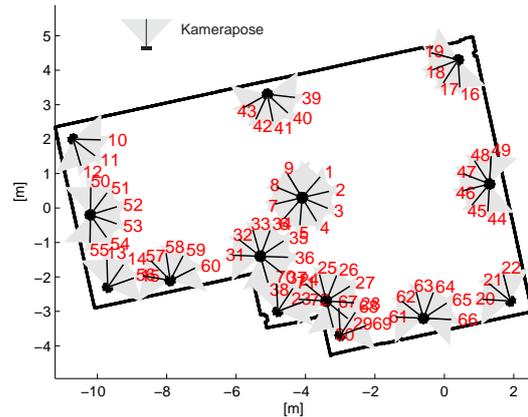


Abb. 6.9: 72 entsprechend den Regeln von Photosynth gewählte Kameraposen

Weitere Regeln:

- Bei Umrundung von Objekten sollen die Differenzen zwischen Aufnahmewinkeln aufeinanderfolgender Aufnahmen 25° nicht überschreiten
- Um Nahaufnahmen durchzuführen, sollen zusätzliche Zwischenaufnahmen getätigt werden, so dass das Abstandsverhältnis aufeinanderfolgender Aufnahmen zum Objekt den Faktor 2 nicht überschreitet

Messstrategie	Allgemein				Beobachtungen						Genauigkeiten										
	Anzahl der Posen []	Anzahl der Aufnahmen []	zurückgelegte Strecke [m]	Anzahl rekonstruierter Punkte []	Ø Anzahl der Merkmale []	Ø Merkmalsverteilung im Bild [%]	Ø Punkte pro Volumenelement: 0 [%]	Ø Punkte pro Volumenelement: < 10 [%]	Ø Punkte pro Volumenelement: 10 – 50 [%]	Ø Punkte pro Volumenelement: > 50 [%]	Mit. Koordinatengen. [cm]	Ø Halbachse A [cm]	Ø Halbachse B [cm]	Ø Halbachse C [cm]	Ø Volumen des Konfidenz-ellipsoids [cm ³]	Isotropie [m]	Spur- Var. Kriterium [m]	Ø Lotabstände [cm]	Ausreißer [%]	Ø Posedifferenzen [cm]	Ø Posedifferenzen [°]
3D RDM mobile	74.3	74.3	64.86	7471.0	496.3	56.3	62.4	24.4	8.6	4.6	1.4e-1	5.4e-1	2.1e-1	1.5e-1	7.8e-2	3.8e2	3.9e-3	3.00	0.27	1.70	0.47
Photosynth	72	72	41.34	5152	374.9	42.3	63.8	26.1	8.2	2.0	2.3e-1	9.4e-1	3.4e-1	2.3e-1	4.5e-1	1.2e3	7.0e-3	5.35	1.42	5.25	0.38

Tab. 6.20: Testergebnisse: Vergleich mit Photosynth Strategie

muss.

Aufgrund dieser Ergebnisse läßt sich feststellen, dass der Aufwand einer genauigkeitsprognostizierenden Strategie gerechtfertigt ist.

6.2.6 Analyse von Einzelpunktabständen

Eine Möglichkeit eine Genauigkeitsaussage über die aus der 3D-Vermessung resultierenden Punktwolken zu treffen ist es, einzelne Punktabstände zwischen gewählten Punkten abzugreifen und diese mit Referenzabständen zu vergleichen. Um dies zu ermöglichen, müssen zunächst Punkte manuell im Objekt identifiziert werden. Dazu wurden die rekonstruierten Merkmalspunkte im Aufnahmemateri-

al⁸ betrachtet und insgesamt 29 Punkte herausgegriffen, die über den gesamten Objektraum verteilt waren und sich zudem für eine nachträgliche Einmessung mit dem Tachymeter eigneten. Nach der Einmessung mit dem Tachymeter konnten die Soll- und die Istabstände der Punkte untereinander verglichen werden. Diese Betrachtungsweise erlaubt eine Genauigkeitsaussage bezüglich der Inneren Genauigkeit der Punktwolke unabhängig von der Genauigkeit, mit der die Punktwolke bezüglich des Referenzmodells registriert wurde. Dieser Aspekt ist insofern interessant, als dass auch der menschliche Nutzer Maße aus den rekonstruierten Daten für weiterführende Aufgaben abgreifen will.

Die eingemessenen Punkte sowie eine farbige Darstellung der Differenzbeträge zwischen den Soll- und den Istabständen ist in Abbildung 6.10 dargestellt. Für die Differenzbeträge wurde nach Gleichung A.37 eine Standardabweichung von $s_0 = 1.24$ cm bei einer mittleren Abweichung von -0.77 cm ermittelt. Bei Betrachtung von Abbildung 6.10 sind vor allem im vorderen Raumbereich größere Abstandsdifferenzen erkennbar. Somit zeigt sich, dass dieser Bereich in der vorliegenden Rekonstruktion mit größeren Fehlern behaftet ist. Dies läßt vermuten, dass der Bereich bezüglich der im Bündelausgleich verwendeten Merkmalspunkte nur eine geringe Überlappung zum restlichen Bildverband aufweist. Eine detaillierte Evaluierung bleibt hier jedoch aus.

Ein weiterer Aspekt, der sich auf die Rekonstruktionsgenauigkeit auswirken kann und an dieser Stelle untersucht wurde, ist die Anzahl der Aufnahmen A_{Anz} , in denen ein rekonstruierter Objektpunkt beobachtet wurde. Generell ist zu vermuten, dass sich mit steigendem A_{Anz} , also einer erhöhten Beobachtungsredundanz, auch die Rekonstruktionsgenauigkeit erhöht. So wurden die Abstandsdifferenzen jedes Punktes in Abhängigkeit von A_{Anz} betrachtet. Die Punkte wurden in drei Gruppen mit $A_{Anz} = 1-5$, $A_{Anz} = 6-10$ und $A_{Anz} = 11-15$ unterteilt und deren Standardabweichungen ermittelt (Abbildung 6.11a). Zwischen A_{anz} und den Abstandsdifferenzen ist jedoch keine Korrelation feststellbar.

In Abbildung 6.11b sind die Abstandsdifferenzen in Abhängigkeit von den absolut gemessenen Abständen abgebildet. Hier zeigt sich dagegen ein Trend in Form der in schwarz dargestellten Regressionsgerade. Dieser läßt sich mit einem verbleibenden Fehler in der Skalierung der rekonstruierten Punktwolke erklären (vgl. Kapitel 5.3.5). So könnte eine Verbesserung der Skalierungsmethode auch zu einer Steigerung der Genauigkeit führen.

6.2.7 Vergleich der ermittelten Varianzen mit der Schätzung

Folgende Untersuchung stellt einen Vergleich zwischen den durch die Bündelausgleichung ermittelten Varianzen der Objektpunkte und den im Rahmen der Positionierungsstrategie (vgl. Kapitel 5.2.4) prognostizierten Varianzen. Durch eine Gegenüberstellung soll geklärt werden, inwiefern die in der Positionierungsstrategie eingesetzte Genauigkeitsprädiktion zutrifft und somit legitimiert ist. Da an dieser Stelle 2D-Fehlerellipsen mit 3D-Fehlerellipsoiden verglichen werden sollen, gilt es letztere auf den \mathbb{R}^2 zu reduzieren. Bei Betrachtung der Fehlerellipsoide zeigt sich zunächst, dass deren Ausrichtung, also die Richtung der großen Halbachse stark von der Richtung der Aufnahmeasen abhängig ist (Abbildung 6.12).

Die horizontale Ausrichtung der Kamera führt dazu, dass alle Umgebungspunkte aus einer annähernd horizontalen Richtung erfasst wurden. So kann jedem Ellipsoid neben der großen Halbachse eindeutig eine weitere horizontale als auch eine vertikale Achse zugeordnet werden. Werden letztere ver-

⁸verwendet wurde der Datensatz aus Abschnitt 6.2.3 mit der geforderten Redundanz 4

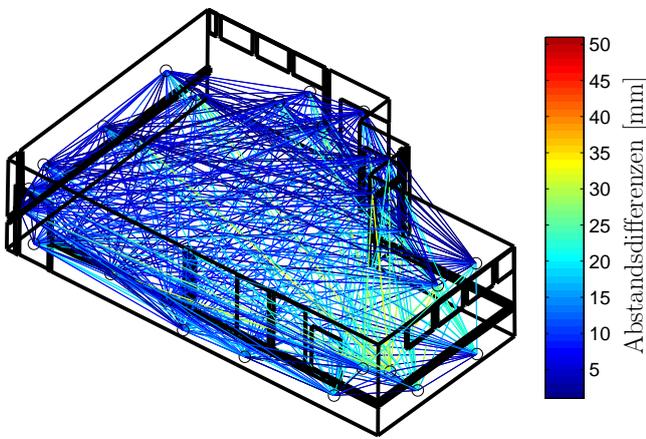


Abb. 6.10: Farbabhängige Darstellung der Differenzbeträge zwischen den Soll- und den Istabständen manuell gewählter Objektpunkte

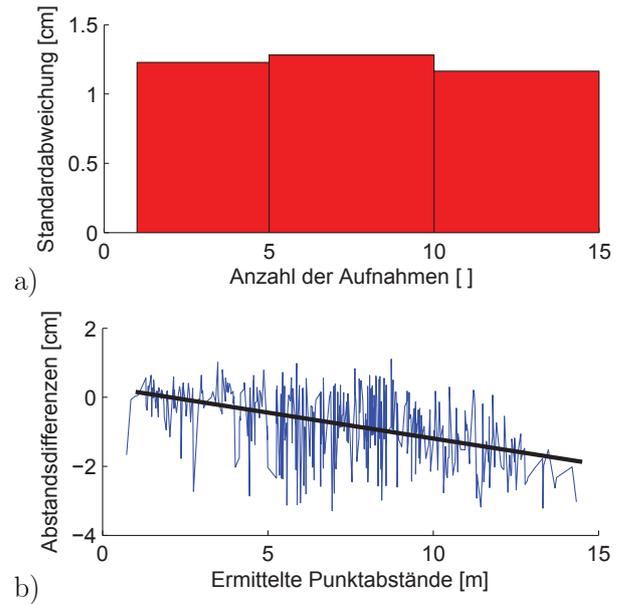
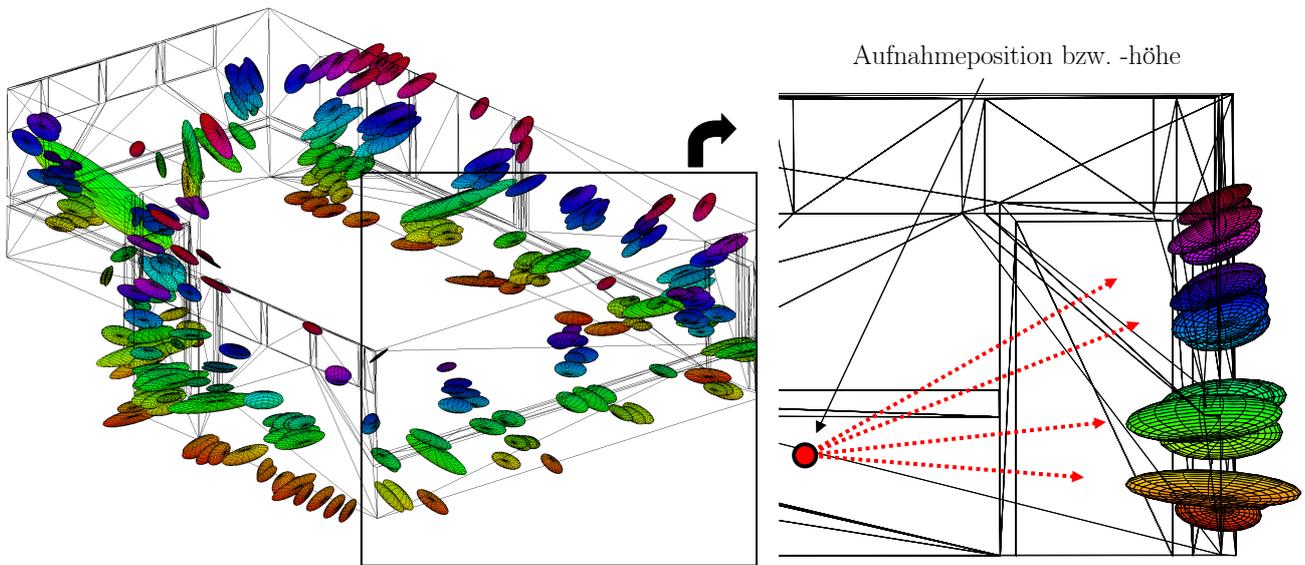


Abb. 6.11:
 a) Standardabweichung der Differenzbeträge in Abhängigkeit von A_{Anz}
 b) Abstandsabweichungen in Abhängigkeit von den Abstandsabständen



a) Schrägansicht

b) Seitenansicht

Abb. 6.12: 3D Tachymetermodell der Versuchsumgebung samt der aus dem Bündelausgleich resultierenden Fehlerellipsoide (ausgedünnt und vergrößert)

nachlässigt, lassen sich 2D-Fehlerellipsen F_{bun} erzeugen, indem die beiden verbleibenden Achsen auf die Horizontalebene transformiert werden, wobei der Richtungswinkel der großen Halbachse die Ausrichtung vorgibt.

Abbildung 6.13 stellt die prognostizierten Fehlerellipsen F_{kam} ⁹ und F_{ges} ¹⁰ der beiden, in der Positionierungsstrategie verwendeten, Ausgleichsvarianten den aus dem Bündelausgleich abgeleiteten, Feh-

⁹resultierend aus Ausgleichung bei Festhalten aller Kameraposen
¹⁰resultierend aus Ausgleichung anhand eine Gesamtpurminimierung

lerellipsen F_{bun} gegenüber. Abbildung 6.13a zeigt die abgeleiteten Fehlerellipsen F_{bun} in ausgedünnter Form. Um einen Vergleich anstellen zu können und eine klarere Vorstellung bezüglich der Ellipsenformen zu erhalten, wurden für die Ellipsen in festen Abständen¹¹ Mittelwerte gebildet (Abbildung 6.13b).

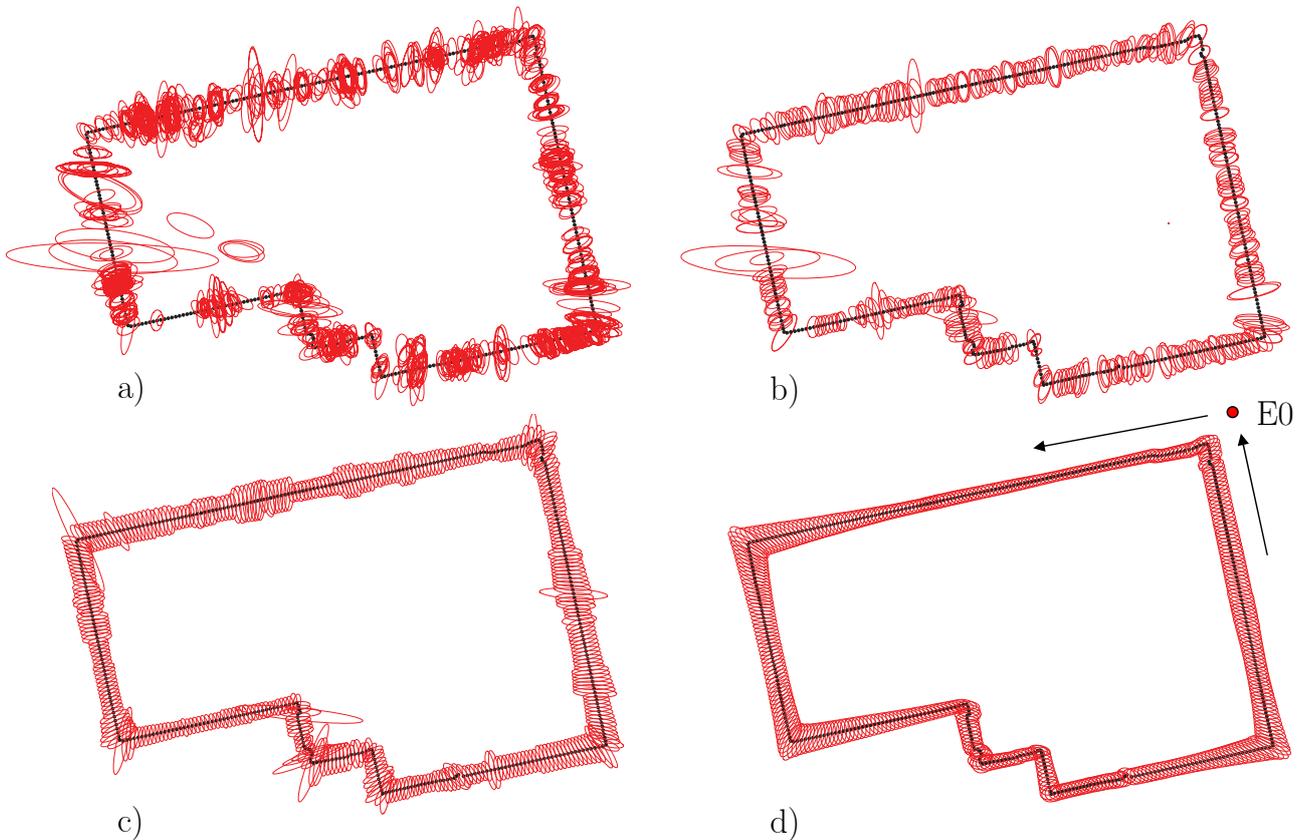


Abb. 6.13: In der Positionierungsstrategie prognostizierte und tatsächlich resultierende Fehlerellipsen (vergrößerte Darstellung)

- a) ausgedünnte Fehlerellipsen F_{bun}
- b) mittlere Fehlerellipsen \bar{F}_{bun} aus a)
- c) Prognostizierte Fehlerellipsen F_{kam} bei Ausgleichungsansatz: Festhalten aller Kameraposen
- d) Prognostizierte Fehlerellipsen F_{ges} bei Ausgleichungsansatz: Gesamtpurminimierung

Die im Rahmen der Positionierungsstrategie ermittelten a priori Genauigkeiten im Fall des Festhaltens aller Kameraposen und die durch die Fehlerfortpflanzung im Bündelausgleich ermittelten Genauigkeiten weisen ein vergleichbares Niveau auf¹². Im Fall der Gesamtpurminimierung ergab sich dagegen ein zu hohes durchschnittliches Fehlerniveau. Dies lässt sich darauf zurückführen, dass hier zur Datumsverfügung keine Parameter festgehalten werden, was allgemein zu einer Verbesserung des ermittelten Genauigkeitsniveaus führt.

Aus Darstellungsgründen wurden die verschiedenen Ellipsengruppen an dieser Stelle auf ein einheitliches Größenniveau skaliert. Da für die Positionsplanung ausschließlich die relativen Ellipsengrößen innerhalb der Strategie relevant sind, ist ein Vergleich der Absolutgrößen für die Gütebewertung sekundär. Für den Vergleich wurden folgende Größen evaluiert:

¹¹entsprechend der Umgebungselemente E vgl. Kapitel 5.2.4

¹²so z.B. die Mittleren Koordinatengenauigkeiten in den Tabellen 6.7 und 6.18

- **sDA**: Standardabweichung der Ausrichtungs­differenzen der Ellipsen D_A [°] (Abbildung 6.14)
- **sVAB**: Standardabweichung der Achsverhältnisse DV_{AB} [] mit:

$$DV_{AB} = \frac{B_{kam/ges}}{A_{kam/ges}} - \frac{B_{bun}}{A_{bun}} \quad (6.3)$$

- **sFAB**: Standardabweichung der Flächendifferenzen D_F [cm²] mit: $D_F = F_{kam,ges} - \bar{F}_{bun}$ und $F = \pi AB$

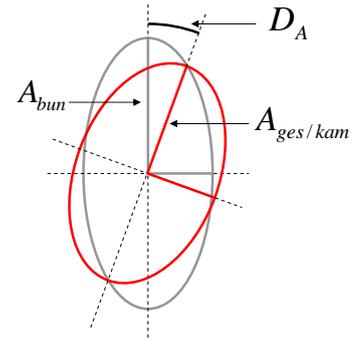
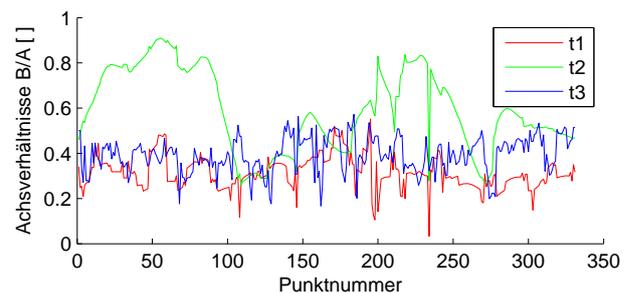
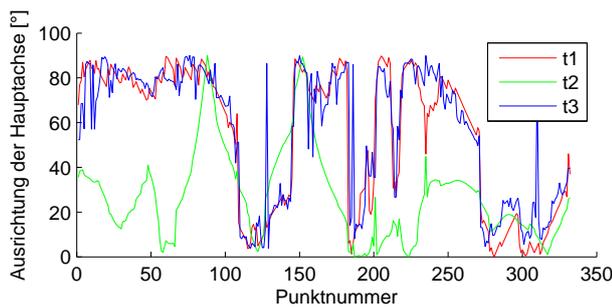


Abb. 6.14: Beispiel

Evaluations­größe	Ausgleichungsansatz A	
	A_{ges}	A_{kam}
sDA	41.3°	12.0°
sVAB	0.28	0.13
sFAB	1.72 cm ²	2.04 cm ²

Abb. 6.15: Testergebnisse: Evaluation der Fehlerellipsen

Die Untersuchung zeigt, dass durch die Ausgleichungsvariante A_{kam} , bei der alle Kameraposen als feste Größen in die Ausgleichung eingehen, eine bessere Nachbildung der realen Fehlergrößen gelingt (vgl. Tabelle 6.15). Dies gilt insbesondere für die Größen sDA und $sVAB$. Aufgrund einer verbesserten Veranschaulichung sind in Abbildung 6.16 die Einzelwerte von D_A und DV_{AB} nochmals dargestellt. Die Reihenfolge der Punktnummern entspricht der Umlaufreihenfolge im Objekt beginnend bei $E0$ (Abbildung 6.13d). Gerade im Hinblick auf die Ausrichtung der Ellipsen ist eine deutlich höhere Korrelation bei A_{kam} erkennbar, so dass damit eine gute Prognose gelingt. Die resultierenden $sFAB$ sind dagegen bei einer durchschnittlichen Ellipsenfläche von 2 cm² nicht aussagekräftig. Dies ist in erster Linie darauf zurückzuführen, dass die Größen benachbarter F_{bun} stark variieren können. Insgesamt läßt sich feststellen, dass die Anwendung eines 2D-Richtungsnetzes zur Abbildung des 3D-Fehlermodells der Bündelausgleichung erfolgreich war.



a) Achsausrichtungen $\rightarrow D_A$

b) Achsverhältnisse $\rightarrow DV_{AB}$

Abb. 6.16: Vergleich der Fehlerellipsen

t1) Fehlerellipsen aus: Festhalten aller Kameraposen $\rightarrow F_{kam}$

t2) Fehlerellipsen aus: Gesamtpurminimierung $\rightarrow F_{ges}$

t3) auf \mathbb{R}^2 reduzierte und gemittelte Fehlerellipsoide der Bündelausgleichung $\rightarrow \bar{F}_{bun}$

6.2.8 Vergleich des Tachymetermodells mit einem automatisch generierten Modell

Wie im 2D-Fall soll auch hier die Analyse eines aus den Daten erzeugten Raummodells die Untersuchungen abschließen. Zur automatischen Ableitung eines Raummodells konnten die von Budroni

entwickelten Algorithmen [14] genutzt werden. Anhand dieser ließ sich ein Modell der Szene ableiten, in dem die generellen Geometrien der Szene, also die Wände, in Form von orthogonal¹³ zueinander stehenden Rechtecken abgebildet sind. Für eine Evaluierung der rekonstruierten Geometrien wurden diese mit deren Gegenstücken im Referenzmodell verglichen, wobei folgende Größen untersucht wurden (vgl. Abbildung 6.18):

- **sD**: Standardabweichung der Abstandsdifferenzen zwischen benachbarten Modellpunkten [m]
- **sP**: Standardabweichung der Abstände korrespondierender Punkte [m]
- **sN**: Standardabweichung der Normalenvektordifferenzen [°]
- **sF**: Standardabweichung der Flächendifferenzen korrespondierender Geometrieelemente [m]

Es ergaben sich folgende Größen:

$$\mathbf{sD} = 5.28 \text{ cm} \quad \mathbf{sP} = 6.01 \text{ cm} \quad \mathbf{sN} = 0.51^\circ \quad \mathbf{sF} = 0.22 \text{ m}^2$$

Die Untersuchung zeigt, dass eine grobe, automatisierte Modellierung der Szene möglich ist. Für eine Modellierung feinerer Strukturen wie Türen und Kabelschächte war die rekonstruierte Punktwolke erwartungsgemäß zu karg (vgl. Abbildung 6.17). Um nicht von der Manhattan-World Annahme abhängig zu sein, müsste zudem ein alternativer Modellierungsansatz gewählt werden. Eine Beurteilung hinsichtlich der Tauglichkeit für Vermessungszwecke bleibt hier, wie auch im 2D-Fall aus, da die Anforderungen dabei sehr stark variieren können.

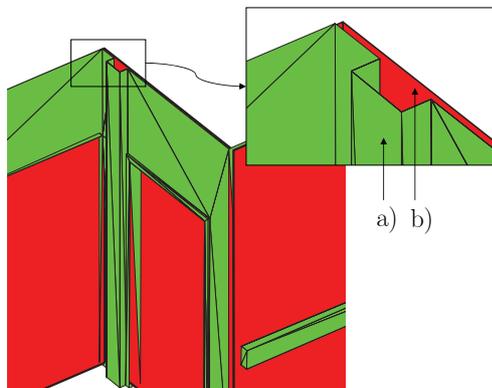


Abb. 6.17: Überlagerung der 3D-Modelle
a) Detailliertes Tachymetermodell
b) Grobes, automatisch erstelltes Modell

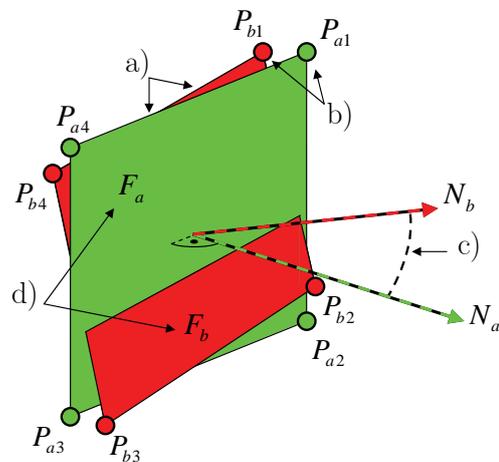


Abb. 6.18: Beispiel
a) sD
b) sP
c) sN
d) sF

6.3 Diskussion

In diesem Kapitel wurde eine Positionierungsstrategie präsentiert, durch die sich ein Bildverband einer Innenraumszene derart aufnehmen lässt, dass mit diesem eine präzise und vollständige Rekonstruktion mittels eines Bündelausgleichs möglich ist.

¹³Manhattan-World Annahme

Die entwickelte Strategie wurde in Abschnitt 6.1 einer ausführlichen Evaluierung anhand von synthetischen Daten unterzogen, um verschiedene Strategien zu vergleichen bzw. optimieren zu können und Einflüsse auf den Messprozess, wie z.B. die Merkmalsanzahl bzw. -verteilung im Objektraum in einem adäquaten Zeitraum beobachten zu können. Anschließend erfolgte eine empirische Evaluierung des Gesamtsystems, um das praktisch erreichbare Genauigkeitsniveau zu beurteilen.

Die Reduktion auf den \mathbb{R}^2 bei der Wahl der Kameraposen bringt den Vorteil, die kombinatorische Vielfalt erheblich zu senken. In Abschnitt 6.2.7 wurde gezeigt, dass eine Abbildung der aus der Bündelausgleich resultierenden theoretischen Genauigkeiten auf den \mathbb{R}^2 in Form eines Richtungswinkelnetzes legitimiert ist. Die konforme Ausrichtung der Fehlerellipse entlang der Horizontalen führt dazu, dass sich durch ein Richtungswinkelnetz brauchbare Prognosen bezüglich der räumlichen Fehlerrichtungen als auch des gesamten Genauigkeitsniveaus anstellen lassen.

Die Ausprägung der Fehlerellipse im Bündelausgleich hängt davon ab, welche Parameter zur Definition des Datums festgehalten werden. Die beiden in der Positionierungsstrategie genutzten Ausgleichungsansätze beinhalten eine andere Datumsverfügung als die im Bündelausgleich verwendete. Die Simulation der realen Verhältnisse ist damit nicht optimal. Jedoch schöpfen sie die vorhandenen Möglichkeiten aus, denn eine Datumsverfügung entsprechend des Bündelausgleichs ist in der Vorplanung nicht möglich. Die Kameraposen, durch die das Datum definiert wird, werden erst im Verlauf der Rekonstruktion bestimmt (vgl. Kapitel 5.1.2).

Es wurde gezeigt, dass das Genauigkeitsniveau der im Zuge des Bündelausgleichs durchgeführten theoretischen Genauigkeitsbetrachtung mit den empirischen Messgrößen nicht übereinstimmt. Wie im Versuch in Kapitel 6.2.7 festgestellt, hat die Genauigkeit der Datenreferenzierung hierauf einen wesentlichen Einfluss. Eine präzisere Bestimmung der relativen Orientierung zwischen den Sensoren im Vorfeld des Messprozesses erbrächte hier eine Verbesserung des Referenzierungsverfahrens.

Der Nachweis einer relativen Punktgenauigkeit von $s_0 = 1.24$ cm in Kapitel 6.2.7 bescheinigt dem in dieser Arbeit verwendeten Systemaufbau Punktwolken in einer Genauigkeit zu erzeugen, die für einige vermessungstechnische Anwendungen ausreichend ist. Durch den Einsatz eines Verfahrens der passiven Merkmalerkennung, ist das System auf die Textureigenschaften der Umgebung angewiesen. So zeigt sich in den Versuchen auch, dass die Rekonstruktion eines typischen Innenraumes allein durch dieses Verfahren und ohne die Anbringung zusätzlicher Textur nicht möglich ist (vgl. Kapitel 6.2.4). Die bei der Verwendung von zusätzlichen Postern rekonstruierten Punktwolken weisen zwar eine hohe Genauigkeit auf, sind in den meisten Umgebungsbereichen jedoch nur sehr dünn besetzt. Eine detaillierte Modellierung der Umgebung, wie es mit dem Systemaufbau aus Kapitel 3 möglich war, konnte hier daher nicht erfolgen.

Denkbar ist jedoch eine soft- oder auch hardwareseitige Erweiterung des Systemaufbaus. Wie in [33] bereits gezeigt, können die durch den Bündelausgleich präzise bestimmten Kameraorientierungen als Eingangsgrößen für dichte Stereoverfahren verwendet werden, um die Anzahl der rekonstruierten Punkte zu erhöhen. Der Ansatz wurde auch auf einen der hier erzeugten Datensätze angewandt (vgl. Abbildung 6.19). Im Vergleich mit Abbildung 5.26 zeigt sich, dass die Anzahl der rekonstruierten Punkte erheblich erhöht werden konnte und sich zum Teil texturschwächere Umgebungsbereiche rekonstruieren ließen. Da das vorliegende Beispiel nur einen Ausblick auf eine mögliche Fortführung der Arbeit geben soll, wurde auf eine detaillierte Evaluierung der so erzeugten Daten an dieser Stelle verzichtet. Eine subjektive Betrachtung ließ eine relativ große Streuung der Punkte erkennen. Eine Möglichkeit wäre es daher die genauer bestimmten Merkmalspunkte dazu zu verwenden, die Gesamtgenauigkeit der Punktwolke zu erhöhen, indem diese als Grundlage für Plausibilitätsprüfungen oder weiteren Me-

thoden genutzt werden.

Auch die Erweiterung des Systems um eine projektive Einheit wäre denkbar. Durch die Projektion künstlicher Merkmale lassen sich anhand von bildbasierten Methoden auch von texturlosen Umgebungsbereichen hochauflösende Punktwolken erzeugen. Hierbei wären z.B. Verfahren wie die Projektion von Streifenmustern, Laserpunkten oder auch Mustern im UV-Bereich [51] denkbar.

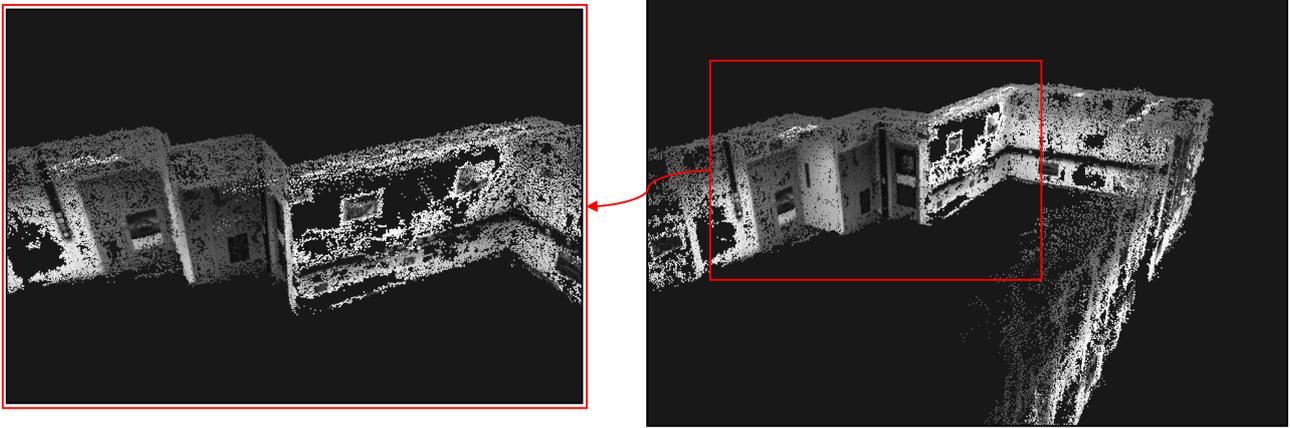


Abb. 6.19: Anhand des PMVS Frameworks [34] erzeugte Punktwolke der Versuchsumgebung unter Verwendung eines in den praktischen Versuchen aufgenommenen Datensatzes

Die Untersuchungen in Kapitel 6 zeigten, dass die Bestimmung der Kameraposen als auch die Rekonstruktion der Punktwolke stark von der Anzahl bzw. der Verteilung der Umgebungsmerkmale abhängt. Zur Steigerung von Robustheit und Datendichte könnten Verfahren zur Detektion von Merkmalspunkten eingesetzt werden, die speziell für texturarme Oberflächen ausgelegt sind (so z.B.: [28]). Aufgrund der charakteristischen Beschaffenheit von Innenraumgeometrien in Form von sich schneidenden, planaren Flächen wäre auch der Einsatz von Kantendetektoren sinnvoll (so z.B.: [3]).

Die Detektion von Subkonfigurationen ist ein wesentlicher Schritt im Verlauf des vorgestellten Rekonstruktionsverfahrens. In der vorgestellten Strategie besteht zunächst keine integrierte Kontrollmöglichkeit für eine solche Überprüfung, denn eine Suche nach Subkonfigurationen im Verlauf der Posenwahl ist nicht sinnvoll. Mit der Bestimmung des maximalen Flusses nach der Posenwahl wurde eine Methode gefunden, die sich gut in die Modellierung des Posenverbandes in Form eines 2D-Richtungsnetzes einfügen läßt. Auch deren Anwendung bei einer 3D-Modellierung wäre prinzipiell möglich. Die theoretische Detektion von Subkonfigurationen in der Planungsphase kann jedoch nur basierend auf der Kamera- bzw. Umgebungsgeometrie erfolgen, da über die objektseitige Verteilung der Merkmale kein Vorwissen vorhanden ist. Die grundsätzliche Annahme gleicherverteilter Merkmale in Form der Umgebungselemente E kann unter Umständen erheblich von den realen Verhältnissen abweichen. Ein weiterer möglicher Arbeitsschritt wäre daher eine grobe Umgebungsbeobachtung vor dem Messprozess. Bei weniger komplexen Umgebungen wäre hier eine Panoramaaufnahme von einem einzelnen Standort aus denkbar. Durch diese ließ sich die Verteilung der Merkmale im Objektraum abschätzen und in der folgenden Positionierungsstrategie berücksichtigen.

Ein weiterführender und ursprünglich auch geplanter Schritt wäre es den Messprozess ohne die zwischenzeitlichen Scannermessungen zur Relokalisierung durchzuführen, da dies eine erhebliche Reduktion des Gesamtaufwands mit sich brächte. Das wäre möglich, wenn das System die entsprechenden Lokalisierungsinformationen über die photogrammetrische Rekonstruktion erhielte. Dann müsste die Aufnahmereihenfolge so geplant werden, dass sich jede neu gemachte Aufnahme direkt in die Rekon-

struktion einfügen ließe. Aufgrund mangelnder Kenntnis über die auf den Oberflächen zur Verfügung stehende Texturinformation kann dies vorab jedoch nicht sicher gewährleistet werden. Die nötige Referenzierungsinformation ließe sich bereits ableiten, wenn der Laserscanner nur bei den ersten (z.B. 3) Messungen genutzt werden würde. Durch die geringere Anzahl an Messungen wären weitere Genauigkeitseinbußen die Folge. Die vorab unbekannte Rekonstruktionsreihenfolge der Aufnahmen¹⁴ erschwert diesen Ansatz zusätzlich. Da ein zwischenzeitliches Auftreten von Subkonfigurationen nicht ausgeschlossen werden kann, könnte es sein, dass die anfänglichen Aufnahmen mit zusätzlicher Scannermessung nicht zur Menge der rekonstruierten Aufnahmen gehören und eine Referenzierung damit nicht möglich wäre.

Die Positionierungsstrategie basiert auf einer vorigen 2D-Exploration der Szene. Eine elegantere Lösung wäre eine Wahl der Kameraposen basierend auf dem Informationsstand zum jeweiligen Zeitpunkt des Einmessprozesses, wie z.B. bei [53] der Fall. Grundbedingung dafür wäre es die Szene nach jeder Aufnahme zu rekonstruieren. Weitere Kameraposen müssten dann basierend auf Prognosen bezüglich der noch unbekanntem Umgebungsgeometrien an den Rändern der bereits rekonstruierten Bereiche definiert werden. Zudem steigt die Wahrscheinlichkeit bei noch unvollständigen Messdaten, dass die Rekonstruktion in Subkonfigurationen unterteilt ist bzw. fehlschlägt. Eine rein bildbasierte Exploration bzw. Vermessung der Szene mit dem hier genutzten Systemaufbau wäre daher nicht sinnvoll.

Abschließend läßt sich feststellen, dass wie bereits im 2D-Bereich, auch bei der 3D-Vermessung die vollständige Prozesskette zur automatisierten Erzeugung eines Innenraummodells grundsätzlich dargestellt werden konnte. Durch soft- oder auch hardwareseitige Erweiterungen ließe sich das Leistungsvermögen des Systemaufbaus, wie er in dieser Arbeit verwendet wurde, jedoch noch erheblich steigern.

¹⁴vgl. Abschnitt 5.1.2

Fazit

Die Erfassung und Modellierung von Innenraumszenen stellt einen grundlegenden aber auch zeitintensiven Arbeitsschritt dar, der durchzuführen ist, wenn diese baulich verändert werden sollen. Ein exaktes und detailliertes Modell bildet dabei die notwendige Basis für weitere Planungsschritte. Das Voranschreiten in der Entwicklung verwendbarer Messsysteme und Sensoren zuzüglich weiterverarbeitender Software erlaubt eine zunehmende Automatisierung der Erfassung bis hin zur Modellbildung. Die vorliegende Arbeit widmet sich den Möglichkeiten zur Automatisierung eines solchen Messprozesses. Dies erforderte die Konzeption eines robotischen und mobilen Messsystems. Dabei stellte der Einsatz kostengünstiger Sensoren hinsichtlich der Entwicklung eines marktfähigen Produktes eine wesentliche Randbedingung beim Entwurf der Systemarchitektur dar. Mit dem Einsatz eines neu entwickelten Low-Cost Laserscanners sowie eines photogrammetrischen Messsystems wurde dieser Anforderung Rechnung getragen und eine monetäre Abgrenzung zu vergleichbaren robotischen Systemen geschaffen.

Der Aufbau des Messsystems erfolgte in einem mehrstufigen Prozess. In einer Basisversion ist das System ausschließlich mit einem 2D-Laserscanner bestückt. Durch das Messen horizontaler Distanzen in einem Umfeld von 360° ermöglicht es dieser eine präzise Grundrisskarte der Umgebung zu erstellen. Die zusätzliche Anbringung eines bildgebenden Sensors an der Plattform macht eine 3D-Erfassung der Innenraumgeometrie möglich. Dies geschieht durch die Detektion von Merkmalspunkten auf den Oberflächen und der 3D-Rekonstruktion dieser Punkte nach dem photogrammetrischen Prinzip.

Der in Kapitel 3 vorgestellte Systemaufbau zur Generierung von 2D-Grundrisskarten stellt an sich kein wissenschaftliches Novum im Bereich der Robotik dar, sondern schlägt vielmehr eine Brücke zwischen Theorie und Praxis. Durch die Verwendung eines präzisen 2D-Laserscanners war in dieser Arbeit der Nachweis einer automatisierten Erfassung von charakteristischen Innenraumumgebungen mit hoher Genauigkeit möglich. Bestehende Verfahren zur Datenregistrierung sowie zur Umgebungsexploration wurden der vorliegenden Messaufgabe angepasst und für diese optimiert. Eine den Sensordaten und den Genauigkeitsansprüchen angepasste Variante des ICP Algorithmus, das *IKQM* wird an dieser Stelle vorgestellt. Die Variante zielt nicht, wie bei vielen anderen Abwandlungen, auf eine optimierte Laufzeit, sondern auf eine möglichst hohe Genauigkeit und Robustheit des Scan-Matchings ab. Durch eine intelligente Datenverwaltung werden neue Datenpunkte, die bereits erfasste Umgebungsbereiche abbilden, verworfen. In einer an den Messprozess angepassten Explorationsstrategie werden vorhandene Datenlücken erkannt und durch die Wahl von entsprechenden Messposen geschlossen. Das Vorhaben, Innenräume zu vermessen und zu modellieren, setzt eine möglichst vollständige und lückenlose Erfassung der Szene voraus. So wird die Exploration vorangetrieben, bis dem System eine Punktwolke vorliegt, die alle Umgebungsbereiche in einer geforderten Auflösung abbildet. Vom Sensor nicht messbare Umgebungsbereiche, wie transparente oder spiegelnde Oberflächen sowie vom System nicht einsehbare Bereiche bilden dabei die natürlichen Grenzen des Systems. Für die der Datenerfassung folgende Modellierung stellt die Arbeit eine Algorithmik vor, die sowohl den Eigenschaften des Sensors, als auch der geometrischen Beschaffenheit von Innenräumen angepasst ist. So erzeugt das Messsystem direkt im Anschluss an die Datenerfassung ein linienhaftes Grundrissmodell der Umge-

bung, welches auf der Extraktion planarer Raumelemente beruht. Das System beinhaltet somit alle zu einer vollständig autonomen Generierung eines Grundrissmodells notwendigen Schritte und kann die anfangs angestrebte Systemfunktionalität prinzipiell darstellen.

Die 3D-Raumvermessung wird in der Arbeit durch die Verwendung eines photogrammetrischen Monokamera-Messsystems realisiert. Eine 3D-Rekonstruktion der Umgebung erfolgt durch eine Verknüpfung der Einzelbilder in einem Bündelausgleich. Im Rahmen der Arbeit wird eine Positionierungsstrategie vorgestellt, die den Eigenschaften und Anforderungen einer photogrammetrischen Rekonstruktion Rechnung trägt. Vergleichbare Verfahren sind bisher nicht bekannt. Die Datengrundlage für das Verfahren bildet die Grundrisskarte einer vorangegangenen 2D-Vermessung. Die dabei definierten befahrbaren Bereiche sowie die bereits erfassten 2D-Oberflächen erlauben schon im Vorfeld eine Wahl empfehlenswerter Messposen. Durch die vereinfachte Abbildung des der Bündelausgleichung zu Grunde liegenden Modells in Form eines 2D-Richtungswinkelnetzes gelingt bei der Wahl von Kameraposen eine Prädiktion der zu erwartenden Genauigkeiten. Mit der Berücksichtigung der gegebenen Restriktionen sowie der Genauigkeitsprädiktion konnte ein Messsystem entwickelt werden, mit dem sich präzise Punktwolken von Innenraumumgebungen rekonstruieren lassen. Die Datenerfassung beschränkt sich allein auf die Detektion markanter Oberflächenpunkte anhand von Merkmalsdeskriptoren. Die texturlosen Oberflächen von Innenräumen führen daher dazu, dass die rekonstruierten Punktwolken die für eine adäquate Modellierung notwendige Datendichte vermissen lassen. Der Versuch einer automatischen Modellierung konnte dementsprechend nur ein grobes Raummodell erzeugen, welches für Vermessungszwecke nicht geeignet ist. Daher ist der Einsatz von zusätzlichen Rekonstruktionsmethoden zur Datenverdichtung der hier notwendige nächste Schritt.

Die baldige kommerzielle Verwirklichung eines Messsystems, wie es in dieser Arbeit vorgestellt wurde, ist nicht realistisch. Eher zu erwarten ist ein handgehaltenes System, in dem eine entsprechende Positionierungsstrategie softwareseitig integriert ist. Dadurch wäre es möglich den menschlichen Nutzer anhand eines HMI's durch eine Innenraumszene zu navigieren und diesem passende Messposen vorzuschlagen [82]. So stellt sich die Frage nach der Übertragbarkeit der in dieser Arbeit vorgestellten Strategien auf eine solche Applikation. Im Fall der 2D-Vermessung ist dies gut vorstellbar. Einerseits könnte dem Nutzer ein Standortvorschlag entsprechend der durch das „2D-RDM mobile“ bestimmten Messposen unterbreitet werden. Alternativ wäre auch die Darstellung der gesamten Score-Map denkbar, um dem Nutzer einen Überblick über die Eignung verschiedener Standortbereiche zu geben, während diesem die konkrete Wahl der nächsten Messposen überlassen wird. Im Fall der 3D-Vermessung ist ein Vorschlag der nächsten Messpose im Verlauf des Messprozesses nicht ohne weiteres möglich, da die vorgestellte Strategie ein Grundrissmodell der Messumgebung voraussetzt. Bei einem rein photogrammetrischen Messsystem könnte jedoch der Nutzer dem System die notwendige Information über das HMI zuführen, indem dieser die Messumgebung skizziert. Die Positionierungsstrategie könnte dann auf die Skizze angewandt werden, so dass der Nutzer auch hier Vorschläge für Aufnahmeposen erhalten würde, wie dies beim mobilen Messsystem der Fall ist.

A Anhang

A.1 Odometrie

Odometrie oder auch Koppelnavigation ist die Wissenschaft von der Posebestimmung eines Fahrzeugs durch die Beobachtung seiner Räder. Poseänderungen Δ_x , Δ_y und Δ_α lassen sich anhand der folgenden Gleichungen ermitteln (vgl. Kapitel 3.3).

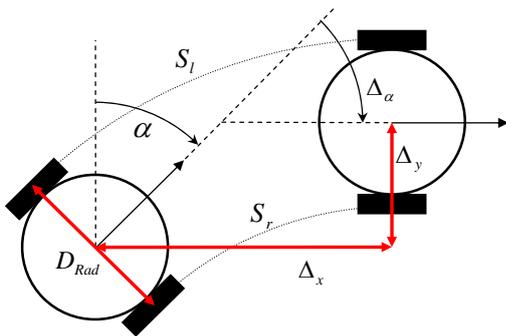


Abb. A.1: Bestimmung der aktuellen Roboterpose anhand der Radencodewerte

$$S_{l/r} = \frac{ET_{l/r}}{ETU_{l/r} \cdot U_{l/r}}$$

$$\Delta_S = \frac{S_r + S_l}{2}$$

$$\Delta_\alpha = \frac{S_r - S_l}{D_{Rad}}$$

$$\Delta_x = \frac{\Delta_S}{\Delta_\alpha} \left(\sin\left(\frac{\pi}{2} + \alpha - \Delta_\alpha\right) + \sin\left(\alpha - \frac{\pi}{2}\right) \right)$$

$$\Delta_y = \frac{\Delta_S}{\Delta_\alpha} \left(\cos\left(\frac{\pi}{2} + \alpha - \Delta_\alpha\right) + \cos\left(\alpha - \frac{\pi}{2}\right) \right) \quad (\text{A.1})$$

A.2 Linien- und Geradensegmente

Ein *Liniensegment* bezeichnet eine Gruppe von benachbarten Datenpunkten, die einen zusammenhängenden Oberflächenbereich repräsentieren (Abbildung A.2). Deren Bestimmung erfolgt durch eine iterative nächste Nachbar Suche, ausgehend von einem in den Daten beliebig gewählten Startpunkt. Segmentenden werden über einen Abstandsschwellwert D_{gap} definiert (vgl. [40]).

Ein *Geradensegment* bezeichnet eine Gruppe von Datenpunkten, die in einer Schwellwert-basierten (vgl. Δ_{maxGer} in Kapitel 3.5.2), linearen Regression eine Gerade bilden und zudem einem gemeinsamen Liniensegment angehören (Abbildung A.2). Einen guten Überblick über die Thematik inklusive verschiedener Lösungsansätze findet sich in [80].

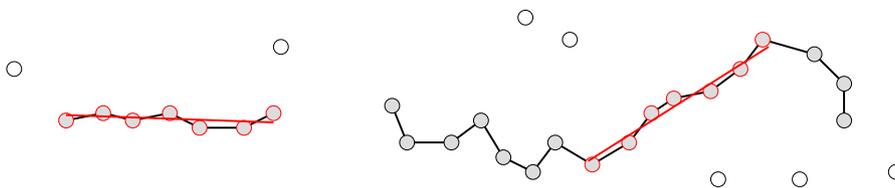


Abb. A.2: Beispiel für Liniensegmente in schwarz und Geradensegmente in rot

A.3 Algorithmen zur graphenbasierten Pfadsuche

Dijkstra Algorithmus

Der Dijkstra Algorithmus [22] dient zur Bestimmung des kürzesten Pfades zwischen zwei Knoten k_a und k_e innerhalb eines kantengewichteten Graphen. Bedingung ist eine positive Gewichtung der

Kanten. Gesucht werden die Verbindungen mit den geringsten Kosten zwischen dem Ausgangsknoten k_a und allen anderen Knoten. Die Suche erfolgt in der Regel anhand zweier Listen L_o und L_g . Potentielle Folgeknoten k_p sind die an den aktuellen Knoten angrenzenden und noch nicht besuchten Knoten. Diese werden in die *offene* Liste L_o aufgenommen. Abgearbeitete Knoten werden dagegen in die *geschlossene* Liste L_g übertragen. Der Algorithmus läßt sich folgendermaßen zusammenfassen:

1. Initialisierung

Setzen aller Knoten auf *nicht besucht* und aller Kantengewichtungen auf ∞ . Initialisierung von L_o mit k_a und dessen direkten Nachbarn.

2. Knotenwahl

Wahl des Knotens mit geringsten Kosten k_{min} aus L_o oder beenden des Algorithmus, falls Liste leer.

3. L_o Update

Bestimmung der von k_{min} direkt erreichbaren Folgeknoten k_p und Eintrag in L_o samt Kosten. Die Kosten setzen sich zusammen aus den Kosten von k_{min} und den Verbindungskosten zu den k_p .

4. L_g Update

Verschieben von k_{min} nach L_g .

Um später den Pfad zurückverfolgen zu können, müssen zusätzlich die Vorgängerknoten aller Knoten gespeichert werden.

A* Algorithmus

Der von Nilsson in [84] vorgestellte A* Algorithmus bildet eine optimierte Erweiterung des Dijkstra-Algorithmus. Der Dijkstra Algorithmus hat den Nachteil, dass der Graph vollständig durchsucht werden muss. Die A* Suche dagegen verläuft zielführender, da die Wahl des Folgeknotens auf einer zweiteiligen Kostenfunktion f basiert:

$$f(k_p) = l(k_p) + h(k_p) \quad (\text{A.2})$$

Diese ergibt sich aus der Summe der bisher aufgewendeten Kosten $l(k_p)$, also der Entfernung zwischen k_a und k_p , und den prädizierten Kosten zum Zielpunkt k_e . Für diese Heuristik wird häufig die direkte Verbindung, also die euklidische Distanz, zum Zielpunkt eingesetzt. So durchschreitet der Algorithmus den Graphen jeweils in Richtung des k_p mit minimalen Kosten $f(k_p)$ (Abbildung A.3).

LPA & D*

Der A* Algorithmus hat sich in der robotischen Bahnplanung zu einem Standard-Suchalgorithmus entwickelt. Erweiterungen des A* Algorithmus wie der LPA (*Lifelong Planning A**) [54] oder auch der D* Algorithmus [99] vermögen die Pfadbestimmung auch dann durchzuführen, wenn die Umgebung zeitlichen Variationen unterliegt. Dies erfolgt durch das dynamische Aufnehmen bzw. Entfernen von Knoten aus den Berechnungen sowie einer entsprechenden Variation der Kantengewichte. Die Verfahren eignen sich damit vorallem für robotische Systeme, die sich in dynamischen Umgebungen zurechtfinden müssen.

Funktionales Modell:

$$E(l) = Ax \quad (\text{A.3})$$

Stochastisches Modell:

$$D(l) = \sigma^2 P^{-1} = \sigma^2 Q_{ll} \quad (\text{A.4})$$

mit der Dispersion D der Beobachtungen l .

Funktionales Modell

Das funktionale Modell beschreibt die mathematischen Beziehungen zwischen den Beobachtungen und den unbekanntem Parametern. Gesucht wird hierbei eine lineare Funktion, die einen $(n, 1)$ -Beobachtungsvektor l mit einem $(u, 1)$ -Vektor der unbekanntem Parameter x in Relation setzt. Aufgrund von Beobachtungsfehlern in l muss zunächst der Erwartungswert von $E(l)$ verwendet werden. Es ergibt sich folgendes Modell:

$$E(l) = Ax \quad (\text{A.5})$$

Bei einer direkten Verwendung von l muss diesen zur Wahrung der Konsistenz ein $(n, 1)$ -Verbesserungsvektor v beigefügt werden, der deren Fehler berücksichtigt:

$$l + v = Ax \quad (\text{A.6})$$

bzw. nach v aufgelöst:

$$v = Ax - l \quad (\text{A.7})$$

Im einfachen Ausgleichungsansatz wird davon ausgegangen, dass alle eingebrachten Beobachtungen dieselbe Genauigkeit aufweisen. Es gilt die Ausgleichungsforderung der Minimierung der Verbesserungsquadratsumme:

$$v^T v \Rightarrow \min \quad (\text{A.8})$$

Im Gauß-Markoff-Modell wird dieser Ansatz durch das Einführen einer Gewichtsmatrix P erweitert. Diese erlaubt eine Angabe von Genauigkeitsrelationen zwischen den einzelnen Beobachtungen (siehe Stochastisches Modell). Die Ausgleichungsanforderung ist jetzt gegeben durch:

$$v^T P v \Rightarrow \min \quad (\text{A.9})$$

Durch ein Einfügen von A.7 und ein Auflösen nach dem Vektor der unbekanntem Parameter läßt sich folgendes Normalgleichungssystem für die erwartungstreue Schätzung \hat{x} der unbekanntem Parameter definieren:

$$\hat{x} = (A^T P A)^{-1} A^T P l \quad (\text{A.10})$$

Wobei mit $N = A^T P A$ das *System der Normalgleichungen* bzw. die *Normalgleichungsmatrix* als gebräuchliche Abkürzung eingeführt wird. Dabei werden lineare Beziehungen zwischen den Messgrößen und den Parametern vorausgesetzt. Ist dies nicht der Fall, ist eine Linearisierung der Beziehungen erforderlich. Diese läßt sich durch eine Reihenentwicklung nach Taylor² durchführen. Ist der Funktionswert f_0 einer stetig differenzierbaren Funktion f an der Stelle X^0 bekannt, kann durch eine Reihenentwicklung (Taylorreihe) der Funktionswert an der Stelle $X^0 + x$ bei kleinem x approximiert werden. Somit

²Brook Taylor: * 18. August 1685 in Edmonton, Middlesex; † 29. Dezember 1731 in Somerset House, London. Britischer Mathematiker

ist an dieser Stelle eine Einführung von Näherungswerten für die unbekannt Parameter notwendig. Es ergibt sich die Form:

$$f(X^0 + x) = f(X^0) + \left(\frac{\delta f}{\delta X}\right)|_{X^0} \cdot x + \frac{1}{2} \left(\frac{\delta^2 f}{\delta X^2}\right)|_{X^0} \cdot x^2 + O^3 \quad (\text{A.11})$$

Das vorliegende Modell beruht auf der Annahme, dass jede Beobachtung L_i sowie deren Verbesserung v_i zu allen, durch das Modell eingeführten, Parametern in Beziehung steht:

$$L_i + v_i = f_i(X_1, X_2, X_3, \dots, X_u) \quad (\text{A.12})$$

Eine Linearisierung dieses Modells führt zu:

$$L_i + v_i = f_i(X_1^0, X_2^0, \dots, X_u^0) + \left(\frac{\delta f_i}{\delta X_1}\right)|_{X^0} \cdot \hat{x}_1 + \left(\frac{\delta f_i}{\delta X_2}\right)|_{X^0} \cdot \hat{x}_2 + \dots + \left(\frac{\delta f_i}{\delta X_u}\right)|_{X^0} \cdot \hat{x}_u \quad (\text{A.13})$$

Die Koeffizienten- oder auch Designmatrix A ergibt damit sich aus den partiellen Ableitungen der n Beobachtungsgleichungen nach den u unbekannt Parametern:

$$A_{n,3} = \begin{pmatrix} a_{1,1} & a_{1,2} & \dots & a_{1,u} \\ a_{2,1} & a_{2,2} & \dots & a_{2,u} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n,1} & a_{n,2} & \dots & a_{n,u} \end{pmatrix} \quad (\text{A.14})$$

mit:

$$a_{n,u} = \left(\frac{\delta f_i}{\delta X_\alpha}\right) \quad (\text{A.15})$$

Gemäß der Reihenentwicklung setzen sich die ausgeglichenen Parameter aus den Näherungswerten X^0 und den Koordinatenzuschlägen \hat{x} , den im linearisierten Ausgleichsmodell eigentlich geschätzten Größen, zusammen:

$$\hat{X} = X^0 + \hat{x} \quad (\text{A.16})$$

Die Beobachtungen L lassen sich entsprechend zerlegen in die Näherungswerte L^0 der Messgrößen und einen verkürzten Beobachtungsvektor l :

$$L = L^0 + l \quad (\text{A.17})$$

Dieser wird relevant, sobald eine Linearisierung erfolgen muss. Bei einem linearen Zusammenhang von Beobachtungen und Parametern, lassen sich die Beobachtungen direkt in Gleichung A.6 einbringen und sich diese einmalig auswerten. Ist jedoch eine Linearisierung notwendig, wird stattdessen der verkürzte Beobachtungsvektor verwendet und der Ausgleichsprozess muss bis zu einer Konvergenz iteriert werden.

Stochastisches Modell

Im einfachen Ausgleichsmodell werden alle Beobachtungen als gleich genau angenommen. Liegen a priori Informationen über die Genauigkeiten bzw. Genauigkeitsrelationen der Beobachtungen vor, können diese innerhalb der Ausgleichung berücksichtigt werden. Die a priori Genauigkeiten der Beobachtungen nehmen einen direkten Einfluss auf die Genauigkeitsmaße der Parameter. Mit der (n, n) -Kovarianzmatrix der Beobachtungen Σ_{ll} kann eine vollständige Genauigkeitsaussage für den $(n, 1)$ -

Beobachtungsvektor l getroffen werden. Während sich auf deren Hauptdiagonalen die Varianzen σ_i^2 der Beobachtungen finden, repräsentieren die Nebendiagonalelemente die Korrelationen zwischen den Beobachtungen.

$$\Sigma_{ll} = \begin{pmatrix} \sigma_1^2 & \rho_{12}\sigma_1\sigma_2 & \dots & \rho_{1n}\sigma_1\sigma_n \\ \rho_{22}\sigma_1\sigma_2 & \sigma_2^2 & \dots & \rho_{2n}\sigma_2\sigma_n \\ \dots & \dots & \ddots & \dots \\ \rho_{22}\sigma_1\sigma_2 & \rho_{2n}\sigma_2\sigma_n & \dots & \sigma_n^2 \end{pmatrix} \quad (\text{A.18})$$

Für gewöhnlich sind keine vollständigen Informationen über die absolute Genauigkeit der Beobachtungen verfügbar. Viel eher können Aussagen über die Genauigkeitsrelationen zwischen den Beobachtungen getroffen werden. In beiden Fällen läßt sich die Kovarianzmatrix durch die Herausnahme eines gemeinsamen Varianzfaktors σ_0^2 zerlegen.

$$\Sigma_{ll} = \sigma_0^2 \cdot Q_{ll} \quad (\text{A.19})$$

Der Varianzfaktor muss gegebenenfalls als unbekannte Größe betrachtet werden, läßt sich aber im Rahmen des Auswerteprozesses bestimmen. In der Kofaktormatrix Q_{ll} verbleiben so die Informationen über die relativen Genauigkeiten der Beobachtungen. Die Gewichtsmatrix P ist als Inverse der Kofaktormatrix definiert. Geht man von unkorrelierten Beobachtungen aus, erhält die Gewichtsmatrix folgende Form:

$$P = Q_{ll}^{-1} = \begin{pmatrix} \frac{\sigma_0^2}{\sigma_1^2} & & & 0 \\ & \frac{\sigma_0^2}{\sigma_2^2} & & \\ & & \ddots & \\ 0 & & & \frac{\sigma_0^2}{\sigma_n^2} \end{pmatrix} \quad (\text{A.20})$$

Es ist ersichtlich, dass durch das Auftreten der Standardabweichungen σ_i^2 im Nenner Beobachtungen mit einer hohen Genauigkeit ein entsprechend höheres Gewicht erhalten. So läßt sich der Einfluss bestimmter Beobachtungen auf die Parameterschätzung durch eine Veränderung ihrer Varianz gezielt beeinflussen.

Nach einer Festlegung der Kofaktormatrix der Beobachtungen lassen sich auch Qualitätsmaße für die zu schätzenden Parameter ableiten. Dies gelingt durch die Anwendung des Varianz-Fortpflanzungsgesetzes auf Gleichung A.10. Es ergibt sich die Kofaktormatrix Q_{xx} des Parametervektors \hat{x} .

$$\begin{aligned} Q_{xx} &= (A^T P A)^{-1} A^T P Q_{ll} P A (A^T P A)^{-1} \\ &= (A^T P A)^{-1} A^P A (A^T P A)^{-1} \\ &= (A^T P A)^{-1} \end{aligned} \quad (\text{A.21})$$

A.4.2 Bündelausgleich

Unter dem Begriff „Bündelausgleich“ (oder auch: Bündelausgleichung) versteht man ein Ausgleichungsverfahren, in dem simultan die Kameraposen eines Bildverbandes sowie die 3D-Koordinaten der in den Bildern zugeordneten Punkte bestimmt werden. Für jede Aufnahme werden Strahlenbündel erzeugt, die über eine Ausgleichung nach Gauß-Markoff bestmöglich aufeinander eingepasst und zu einem Ge-

samtmodell zusammengefügt werden (Abbildung A.4).

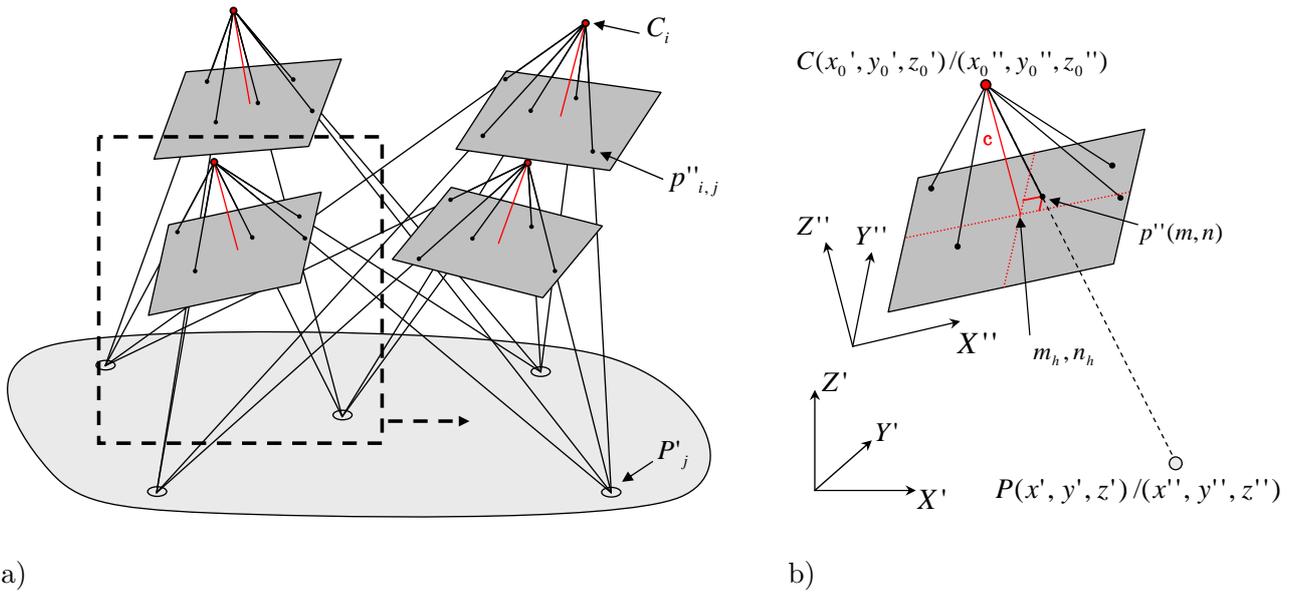


Abb. A.4: Prinzip des Bündelausgleichs

- a) Strahlenbündel bilden den Zusammenhang zwischen den Kameraposen C_i , den Objektkoordinaten P'_j sowie den Bildkoordinaten $p''_{i,j}$
- b) Bildstrahl als Verbindung zwischen den Projektionszentren C , den Bildpunkten p und den Objektpunkten P

Mathematischer Zusammenhang zwischen Bild- und Objektkoordinaten

Der funktionale Zusammenhang zwischen den Bildkoordinaten $p''(m, n)$ und den Objektkoordinaten $P(x', y', z')$ wird durch eine Zentralprojektion definiert und lässt sich über die sogenannten Kollinearitätsgleichungen beschreiben:

$$\begin{aligned}
 m'' &= m_h - c \cdot \frac{r_{11}(x' - x'_0) + r_{21}(y' - y'_0) + r_{31}(z' - z'_0)}{r_{13}(x' - x'_0) + r_{23}(y' - y'_0) + r_{33}(z' - z'_0)} + dx' \\
 n'' &= n_h - c \cdot \frac{r_{12}(x' - x'_0) + r_{22}(y' - y'_0) + r_{32}(z' - z'_0)}{r_{13}(x' - x'_0) + r_{23}(y' - y'_0) + r_{33}(z' - z'_0)} + dy'
 \end{aligned}
 \tag{A.22}$$

Innere Orientierung

Zur grundsätzlichen Beschreibung der inneren Orientierung bzw. inneren Geometrie einer Kamera genügen drei Parameter: die Kammerkonstante c sowie die Lage des Bildhauptpunktes m_h, n_h . Optische Systeme führen in der Praxis zu geometrischen Abbildungsfehlern, also Abweichungen von den Gesetzen der Zentralprojektion, in den Kollinearitätsgleichungen berücksichtigt als dx' und dy' . In der Photogrammetrie kommen verschiedene parametrische Modelle zum Einsatz, die versuchen die Fehlerquellen, also die zu Grunde liegenden physikalischen Begebenheiten zu erfassen, wie z.B. gegeben in [13, 32]. Ein entsprechender Satz an Verzeichnungsparametern kann im Rahmen einer Kalibrierung ermittelt und auf die beobachteten Größen angewandt werden.

Äußere Orientierung

Die äußere Orientierung beschreibt die Position der Kameraprojektionszentren $\vec{C}_0 = [X_0 \ Y_0 \ Z_0]^T$ sowie die Kameraorientierungen $R(\omega, \phi, \kappa) = R_z(\kappa) \cdot R_y(\phi) \cdot R_x(\omega)$ ³ im Objektkoordinatensystem. Es

³ $R_{x,y,z}$ = Rotationsmatrizen um die entsprechenden Koordinatenachsen

ergeben sich die, die Rotation beschreibenden, Elemente $r_{i,j}$:

$$R(\omega, \phi, \kappa) = \begin{bmatrix} r_{11} & r_{12} & r_{13} \\ r_{21} & r_{22} & r_{23} \\ r_{31} & r_{32} & r_{33} \end{bmatrix} \quad (\text{A.23})$$

Eine detailliertere Beschreibung der mathematischen Zusammenhänge findet sich in Kraus [56].

Funktionales Modell

Die Ausgleichung erfolgt nach der Methode der kleinsten Quadrate. Gewählt wird das Modell nach *Gauß-Markoff*. Basierend auf den Kollinearitätsgleichungen lassen sich die Beobachtungsgleichungen gemäß A.12 aufstellen:

$$\begin{aligned} x_j + v_x^j &= f_j(X_0^i, Y_0^i, Z_0^i, \alpha_i, \omega_i, \kappa_i, c_k, m_h^k, n_h^k, dx_k', X_j, Y_j, Z_j) \\ x_j + v_y^j &= f_j(X_0^i, Y_0^i, Z_0^i, \alpha_i, \omega_i, \kappa_i, c_k, m_h^k, n_h^k, dy_k', X_j, Y_j, Z_j) \end{aligned} \quad (\text{A.24})$$

mit: j : Objektpunktindize

i : Bildindize

k : Kameraindize

Das sich so ergebende Gleichungssystem ist nicht linear in den unbekanntenen Elementen der Ausgleichung, was jedoch Voraussetzung für den hier vorliegenden Fall der Parameterschätzung ist. Deshalb gilt es zunächst das Gleichungssystem zu linearisieren. Eine Linearisierung kann über eine Reihenentwicklung nach Taylor geschehen, wenn für die unbekanntenen Parameter Näherungswerte mit ausreichender Genauigkeit⁴ bereitgestellt werden (vgl. Gleichung A.11). Diese müssen also im Vorfeld auf anderem Wege bestimmt werden.

A.4.3 Gesamtspurminimierung

Bedingungsgleichungen zur Gesamtspurminimierung

Für die Durchführung einer Gesamtspurminimierung müssen zusätzliche Bedingungsgleichungen in das Gleichungssystem eingeführt werden. Diese Bedingungen bzw. Forderungen an das Ausgleichungsmodell zielen darauf ab den Datumsdefekt zu beheben. In einem Lagenetz können folgende Bedingungen an die zu schätzenden Transformationsparameter \hat{x}_i und \hat{y}_i aufgestellt werden:

$$\begin{aligned} \text{Translation in x:} & \quad \sum \hat{x}_i = 0 \\ \text{Translation in y:} & \quad \sum \hat{y}_i = 0 \\ \text{Rotation um z:} & \quad \sum (Y_i^0 \hat{x}_i - X_i^0 \hat{y}_i) = 0 \\ \text{Maßstab:} & \quad \sum (X_i^0 \hat{x}_i + Y_i^0 \hat{y}_i) = 0 \end{aligned}$$

(A.25)

⁴ausreichend nahe an der durch die Taylor-Entwicklung zu detektierenden Nullstelle gelegen, um eine Konvergenz zu dieser gewährleisten zu können

wobei X_i^0 und Y_i^0 die Näherungskoodinaten der Objektpunkte darstellen sollen. Die Bedingungsgleichungen bewirken, dass die Translationen, die Rotation und der Maßstab konstant bleiben und sich die Netzgeometrie auf den Näherungskoodinaten „einschwingt“. Bei einer Darstellung der Bedingungsgleichungen in einem Gleichungssystem $B^T x = 0$, gilt für die Bedingungsmatrix B^T :

$$B^T = \begin{bmatrix} 1 & 0 & 1 & 0 & \cdots & 1 & 0 \\ 0 & 1 & 0 & 1 & \cdots & 0 & 1 \\ Y_1^0 & -X_1^0 & Y_2^0 & -X_2^0 & \cdots & Y_p^0 & -X_p^0 \\ X_1^0 & Y_1^0 & X_2^0 & Y_2^0 & \cdots & X_p^0 & Y_p^0 \end{bmatrix}, p = \frac{u}{2} \quad (\text{A.26})$$

Das erweiterte Normalgleichungssystem lautet dann:

$$\begin{bmatrix} N & B \\ B^T & 0 \end{bmatrix} \cdot \begin{bmatrix} \hat{x} \\ k \end{bmatrix} = \begin{bmatrix} n \\ 0 \end{bmatrix} \quad (\text{A.27})$$

mit $n = A^T Pl$ (vgl. Gleichung A.10). Zur Auflösung des Gleichungssystems nach den unbekanntem Parametern \hat{x} muss eine Inversion erfolgen:

$$\begin{bmatrix} Q_{11} & Q_{12} \\ Q_{21} & Q_{22} \end{bmatrix} = \begin{bmatrix} N & B \\ B^T & 0 \end{bmatrix}^{-1} \quad (\text{A.28})$$

Wobei mit N die Normalgleichungsmatrix gemäß A.10 gemeint ist. Entsprechend ergibt sich die Lösung:

$$\hat{x} = Q_{11} \cdot n; \quad Q_{xx} = Q_{11} \quad (\text{A.29})$$

Eliminierung der Beobachtungsunbekannten

Wird eine allgemeine Bedingungsgleichung der Form

$$B^T \hat{x} = 0 \quad (\text{A.30})$$

für den gesamten Parametervektor \hat{x} aufgestellt, spricht man vom Modell der Gesamtpurminimierung. Einzige an B zu stellende Bedingung ist, dass der Rangdefekt ausgeglichen wird. Um die genannten Bedingungsgleichungen für den gesamten Parametervektor einführen zu können, müssen alle Parameter vom Typ „Koordinate“ sein. Da im vorliegenden Fall des Richtungsnetzes Orientierungsunbekannte zur Menge der Parameter zählen, müssen diese zunächst eliminiert werden. Hierfür steht unter anderem die Methode der „Schreiberschen Regel“ zur Verfügung. Dabei erfolgt die Eliminierung der Orientierungsunbekannten durch das Einfügen zusätzlicher fingierter Beobachtungen in das Gleichungssystem, das zur Bildung der Designmatrix A dient. Aus dem Gleichungssystem entfernt werden dafür die Ableitungen nach den Orientierungsunbekannten. Die Faktoren der zusätzlichen Beobachtung ergeben sich durch die Summation aller bisherigen Faktoren einer Spalte:

$$\begin{array}{lll} v_1 = a_{11}x_1 & + b_{11}y_1 & + \cdots - l_1 \\ v_2 = a_{21}x_1 & + b_{21}y_1 & + \cdots - l_2 \\ \vdots & & \\ v_m = a_{m1}x_1 & + b_{m1}y_1 & + \cdots - l_m \end{array}$$

$$v_s = x_1 \sum_{i=1}^m a_{i1} + y_1 \sum_{i=1}^m b_{i1} + \dots - \sum_{i=1}^m l_i \quad (\text{A.31})$$

Für die zusätzliche Beobachtung wird das Gewicht $p_s = -1/m$ eingeführt, wobei alle anderen Beobachtungen ein Gewicht von $p_i = 1$ erhalten. Mit $e_{1,m} = \{1, 1, \dots, 1\}$ ergibt sich:

$$\begin{aligned} A_s &= e^T A_1 \\ l_s &= e^T l \\ P_s &= -1/m \end{aligned} \quad (\text{A.32})$$

Somit erweitert sich das funktionale Modell aus A.6 zu:

$$\begin{bmatrix} l \\ l_s \end{bmatrix} + \begin{bmatrix} \bar{v} \\ v_s \end{bmatrix} = \begin{bmatrix} A_1 \\ A_s \end{bmatrix} \hat{x}_1 \quad (\text{A.33})$$

A.5 SIFT - Scale Invariant Feature Transform

SIFT bezeichnet ein Verfahren zur skaleninvarianten Merkmalsextraktion. Grundlage des Verfahrens ist das *Difference-of-Gaussian* Filter (DoG), bei dem die Differenz zweier verschieden stark geglätteter Gaußbilder gebildet wird. Dieses stellt eine mit geringerem Berechnungsaufwand verbundene Näherung an das *Laplacian-of-Gaussian* Filter dar. Eine für das Verfahren sehr günstige Eigenschaft ist dessen Isotropie. Durch mehrfaches Resampling und zusätzlicher Glättung durch das Gaußfilter wird zunächst für jedes Bild ein Skalenraum zur Simulation verschiedener Skalierungsstufen aufgebaut. Aus den Bildern mit benachbarter Glättungs- und gleicher Resamplingstufe werden nun Differenzbilder (DoG) erzeugt. In die Menge der Merkmalspunkte (engl: *key points*) werden diejenigen Punkte aufgenommen, welche lokale Extrema in den DoG-Bildern über alle Maßstäbe aufweisen. Jeder so gewählte Merkmalspunkt erhält einen sogenannten Deskriptor, einen 128-dimensionalen reelwertigen Vektor, der zur individuellen Beschreibung jedes Punktes dient. Der Deskriptor ergibt sich aus einer Betrachtung der Bildumgebung des Merkmalspunktes. Hierbei wird ein 16×16 Pixel großes Fenster in 16 Teilregionen unterteilt, für die wiederum ein in 8 Richtungen unterteiltes Gradientenhistogramm erstellt wird. Zu jedem Merkmalspunkt werden zudem die Orientierung und die Skalierung bestimmt, so dass eine entsprechende Normierung der Deskriptoren erfolgen kann. Ein Vergleich der Deskriptoren erfolgt letztendlich über deren euklidische Distanz.

Die Arbeiten von Mikolajczyk [75] und Bauer [2] konzentrieren sich auf eine Evaluierung der Leistungsfähigkeit des SIFT-Operators. Laut Mikolajczyk liegt die *Recall Rate*, also der Prozentsatz richtig zugeordneter Punkte, bei Aufnahmen mit Blickwinkelvariationen von 40° - 60° schwellwertabhängig bei rund 30% - 50%. Bei Bauer wird ein starkes Abfallen korrekter Zuordnungen bereits ab einem Unterschied von 10° - 20° bemerkt. Bei 50° verbleiben nahezu keine korrekten Zuordnungen.

Die unterschiedlichen Resultate lassen sich unter anderem auf das verwendete Bildmaterial zurückführen. Während die Aufnahmen bei Mikolajczyk texturierte Wände enthalten, wird in [2] eine Naturszene betrachtet. Somit erschwert sich bei letzterem die Wiedererkennung von Punkten alleine durch

die geometrischen Abschattungen, die durch einen Wechsel des Aufnahmestandortes entstehen. Bei der Rekonstruktion von Innenraumszenen ist eher ein Fehlerverhalten entsprechend der Ergebnisse aus [75] zu erwarten.

A.6 Messgenauigkeit 2D-RDM

Zur Evaluierung der Distanzmessgenauigkeit des 2D-Laserscanners wurde eine Messreihe auf einer Referenzmessstrecke aufgezeichnet. Bei konstantem Messwinkel wurde wiederholt ein weißes Target angemessen, dessen Abstand zum Sensor variiert wurde. Die wahren Distanzen des auf einem Messschlitten angebrachten Targets waren mit übergeordneter Genauigkeit bekannt. Es wurden insgesamt 88 Distanzen in einem Entfernungintervall von 0.5 m bis 7.2 m gemessen. Der Test wurde anschließend mit einem schwarzen Target unter Verwendung derselben Entfernungen wiederholt. Die ermittelten Soll-Ist Differenzen sind in Abbildung A.5a dargestellt. Zur Analyse der Messwerte wurden diese in 3 Subintervalle unterteilt, um die Steigerung der Messungenauigkeit mit zunehmender Distanz quantifizieren zu können. Bei der Bildung von Regressionsgeraden zeigt sich, dass die gemessenen Distanzen durch das Anbringen eines Skalierungsfaktors sowie eines Versatzes verbessern lassen. Die um die mittlere Regressionsgerade reduzierten Werte sind in Abbildung A.5b illustriert. Bei der Nutzung des Sensors lassen sich die ermittelten Reduktionswerte in situ verwenden.

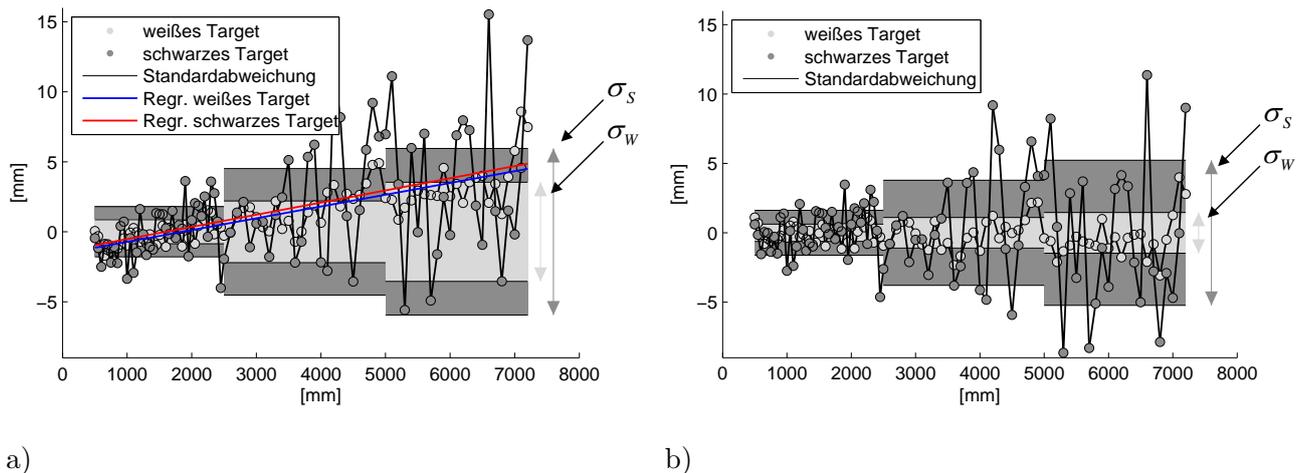


Abb. A.5: Soll-Ist Differenzen bei Distanzmessungen in einem Entfernungintervall von 0.5 m bis 7.2 m. Unterteilung in 3 Subintervalle SIV (mit: $SIV_1 = [0.5 \text{ m} - 2.5 \text{ m}]$; $SIV_2 = [2.5 \text{ m} - 5.5 \text{ m}]$; $SIV_3 = [5.5 \text{ m} - 7.2 \text{ m}]$) und Darstellung derer Standardabweichungen σ (mit: $\sigma_W \hat{=}$ weißes Target; $\sigma_S \hat{=}$ schwarzes Target)
a) Rohdifferenzen
b) Um mittlere Regressionsgerade reduzierte Differenzen

A.7 Ungarische Methode

Die Ungarische Methode (engl.: *hungarian algorithm*), auch Kuhn-Munkres Algorithmus genannt, ist ein kombinatorischer Algorithmus zur Lösung des Zuordnungsproblems (engl.: *assignment problem*) in polynomineller Laufzeit ($O(n^3)$). Entwickelt und veröffentlicht wurde sie 1955 von Kuhn [57], dem sie ihren Namen zu verdanken hat. Kuhn berücksichtigte bei der Namensgebung zwei ungarische Mathematiker, auf deren Arbeiten die Ungarische Methode im Wesentlichen basiert.

Aufgabenstellung

Gegeben seien zwei Objektgruppen $A = \{a_1, a_2, \dots, a_n\}$ und $B = \{b_1, b_2, \dots, b_n\}$. Das Ziel ist jedem Element der Gruppe A genau ein Element der Gruppe B zuzuordnen. Sind die Gruppen von unterschiedlicher Größe, wird die kleinere Gruppe durch das Einführen von Dummy-Elementen entsprechend erweitert. Jede mögliche Zuordnung zwischen den Elementen ist mit bestimmten Kosten verbunden. Der Algorithmus vermag nun eine eindeutige Zuordnung unter Maximierung (Minimierung) der Gesamtkosten durchzuführen.

Mathematische Formulierung

Die Elemente der Objektgruppen können als Knoten eines bipartiten Graphen $G = (A \cup B, A \times B)$ betrachtet werden, dessen Kanten ab sich aus den zulässigen Zuordnungen bilden und entsprechend der Kosten $w(ab)$ gewichtet sind. In einer typischen Anwendung könnte A eine Anzahl an Arbeitnehmern und B eine Anzahl an Jobs darstellen. Die Eignung eines Arbeitnehmers einen bestimmten Jobs auszuführen wäre über $w(ab)$ beschrieben.

Mathematisch läßt sich die Problemstellung als eine $n \times n$ Matrix W , gefüllt mit den Gewichten der Zuordnungen darstellen. Unterscheidet sich die Zahl der Jobs von der Zahl der Arbeitnehmer, muss W an den entsprechenden Stellen mit 0 Einträgen aufgefüllt werden. Die optimale Zuordnung ergibt sich aus der Suche nach der Permutation Φ von $1, 2, 3, \dots, n$ für die

$$\sum_{i=1}^n w(x_i y_{\Phi(i)}) \quad (\text{A.34})$$

maximal (minimal) wird.

Algorithmus nach [15]

Gegen sei die Kostenmatrix W .

1. Subtrahiere von jedem Element einer Zeile das jeweilige Zeilenminimum
2. Subtrahiere von jedem Element einer Spalte das jeweilige Spaltenminimum
3. Verwende so wenige senkrechte und waagrechte Linien wie möglich um alle 0 Einträge in W zu überdecken (Try & Error).

- Annahme: Es werden k Linien benötigt
- wenn $k < n$ ist und m die kleinste, nicht überdeckte Zahl darstellt:
 - Subtrahiere m von allen unbedeckten Zahlen.
 - Addiere m auf alle Zahl die von 2 Linien überdeckt werden.
 - Führe Schritt 3 erneut aus.
- wenn $k = n$, gehe über zu Schritt 4.

4. Durchsuche die Matrix zeilenweise, beginnend bei der obersten Zeile. Enthält eine Zeile r genau eine 0 an der Stelle $[r, s]$, können die Elemente a_r und b_s einander eindeutig zugeordnet werden. Lösche die Zeile r und die Spalte s aus W . Reduziere die Indizes der Elemente in A und B entsprechend.

Wenn nicht alle n Zuordnungen vollzogen werden können und alle verbleibenden Zeilen jeweils mehr als eine 0 enthalten, führe eine Spaltenweise Suche nach einzelnen 0 Einträgen

durch, beginnend mit der linken Spalte.

Wechsle die Zeilen- und Spaltensuche iterierend ab, bis keine eindeutigen Zuordnungen mehr möglich sind. Wenn bisher keine n Zuordnungen erfolgen konnten, ist keine eindeutige Zuordnung aller Elemente möglich. Führe eine Zuordnung verbleibender 0 Einträge zufällig durch und versuche anschließend die Elemente eindeutig zuzuordnen.

A.8 Projektionsfilter

Das Projektionsfilter ist ein im Rahmen von Scan-Matching Anwendungen häufig verwendetes Filter und dient dazu, die Sichtbarkeit von Scanpunkten in Abhängigkeit der Betrachtungsrichtung zu überprüfen (vgl. [71]). Mit diesem soll die Menge der für das Matching verwendeten, bestehenden Daten verringert und die Zuordnung fehlerhafter Matchingpartner vermieden werden. Ein Scanpunkt ist per Filterdefinition nicht sichtbar, wenn er durch einen oder mehrere bestehende Scanpunkte verdeckt wird (Abbildung A.6a). Da jeder Scanpunkt einen Teil einer Oberfläche repräsentiert, muss zudem differenziert werden, von welcher Seite aus ein Punkt betrachtet wird. Rückseitige Oberflächenbetrachtungen müssen erkannt und ausgeschlossen werden. Dazu wird die Richtung R_2 , aus der ein neuer Scanpunkt aufgezeichnet wurde, mit den Richtungen R_1^i der benachbarten Punkte im bestehenden Datensatz abgeglichen (Abbildung A.6b). Übersteigt die Differenz zwischen diesen Richtungen einen gewählten Schwellwert, wird der Punkt als nicht sichtbar eingestuft und für das Scan-Matching bzw. die Erweiterung des Datensatzes nicht verwendet.

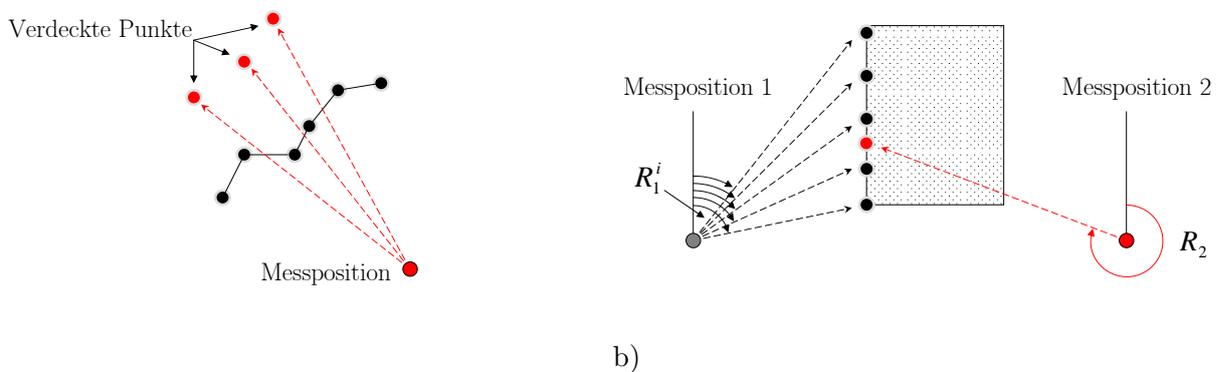


Abb. A.6: Funktionalität des Projektionsfilters (Modifizierte Grafik nach Lu [71])

In der praktischen Umsetzung wird die Umgebung ausgehend von der prädefinierten Messposition in radial auseinanderlaufende Zonen Z gleicher Größe unterteilt⁵. Die Ausdehnung der Zonen ist an die Reichweite des Sensors angepasst. In jeder Zone Z_i wird der Datenpunkt $D_{next}(i)$ gesucht, der der Messposition MP am nächsten gelegen ist. Als sichtbar werden zunächst die Datenpunkte $D(i)$ jeder Zone eingestuft, deren Abstand zur Messposition nicht größer als D_{VS} ist:

$$D_{VS} = |MP - D_{next}| + D_{view} \quad (\text{A.35})$$

wobei mit D_{view} ein Abstandsbereich definiert wird, in dem sichtbare Punkte liegen dürfen. Es ergeben sich die in Abbildung A.7 rot dargestellten Sichtbarkeitsbereiche. Im Anschluss werden die verbleibenden Datenpunkte entsprechend des Projektionsfilters auf ihre richtungsspezifische Sichtbarkeit überprüft. Anhand der lokalen Segmentrichtung wird der Normalenvektor \vec{N} der lokalen Oberfläche

⁵vergleichbar mit der Vorgehensweise in Abbildung 3.9

jedes Datenpunktes D gebildet (Abbildung 3.10) und mit der Richtung $R(D \rightarrow MP)$ verglichen, aus der der Datenpunkt ursprünglich erfasst wurde. Datenpunkte, die Winkeldifferenzen $< DV_{max}$ mit $DV_{max} = |\vec{N} - R(D \rightarrow MP)|$ aufweisen, werden als sichtbar eingestuft und im weiteren Matching Prozess verwendet.

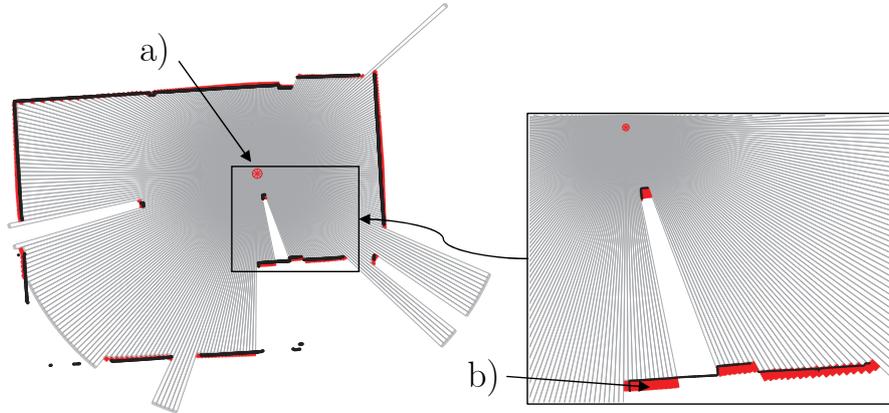


Abb. A.7: Bestimmung der von einer Messposition sichtbaren Datenpunkte durch radiale Sichtbarkeitszonen
 a) Messposition MP
 b) Bereiche der als sichtbar eingestuften Datenpunkte

A.9 Messinstrumente



	a) Entfernungsmesser Bosch DLE50	b) Tachymeter Leica TPS400
Messunsicherheit		
Winkelmessung		3" (1.5 mgon)
Distanzmessung	1.5 mm	2 mm + 2 ppm
Messbereich	0.05 m - 50 m	1.7 m - 170 m
typ. Messdauer	0.5 s	3 s
Gewicht	170 g	5.2 kg
Modellierungssoftware	Matlab	TachyCAD [102]



a) DLE50 [8]

b) TPS400 [9]

Abb. A.8: Spezifizierung der Messinstrumente

A.10 Korrelationskoeffizient

Der Korrelationskoeffizient r_{xy} ist gemäß [66] eine statistische Maßzahl, um Aussagen über die Kovarianz zweier Messreihen treffen zu können. Er wird gebildet über:

$$r_{xy} = \frac{sxy}{\sqrt{ssx \cdot ssy}} \quad \text{mit :} \quad \begin{aligned} sxy &= \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) \\ ssx &= \sum_{i=1}^n (x_i - \bar{x})(x_i - \bar{x}) \\ ssy &= \sum_{i=1}^n (y_i - \bar{y})(y_i - \bar{y}) \end{aligned} \quad (\text{A.36})$$

A.11 Untersuchung der Odometriegenauigkeit

Zur Untersuchung der Odometriegenauigkeit wurden folgende Versuche ausgeführt:

360° Drehungen

Die Encoderwerte werden in diskreten Zeitschritten ausgelesen. Daher hat sich das System häufig bereits ein Stück zu weit bewegt bevor das Erreichen der angestrebten Pose registriert wird. Eine Regelung mit langsameren Bewegungen bringt das System darum im Anschluss in die korrekte Pose. Die Regelung bricht ab, sobald ein gefordertes Werteintervall⁶ erreicht wird. Die in dieser Untersuchung ermittelten Drehwerte im Bereich von 360° wurden mit den aus den Tachymetermessungen resultierenden Richtungen verglichen. In Abbildung A.9 sind die 50 in der Messreihe ermittelten Abweichungen in einem Histogramm dargestellt. Anhand von Gleichung A.38 wurde eine empirische Standardabweichung von $s_0 = 2.6^\circ$ ermittelt. Der sich ergebende Mittelwert von -2.0° stellt einen Korrekturfaktor dar, der in der praktischen Anwendung an den resultierenden Werten anzubringen ist.

4 m Geradeausfahrten

Zur Genauigkeitsuntersuchung der Geradeausfahrten wurde eine 4 m lange Strecke wiederholt abgefahren. Verglichen wurde die aus der Odometrie resultierende euklidische Distanz von Start und Endpunkt mit den entsprechenden Tachymeterdaten. Die Ergebnisse sind in Abbildung A.10 in einem Histogramm dargestellt. Es wurde bei einem empirischen Mittelwert von $\bar{x} = -0.4$ cm eine Standardabweichung von $s_0 = 1.1$ cm ermittelt. Auch hier dienten die Ergebnisse als Korrekturfaktor für folgende Anwendungen.

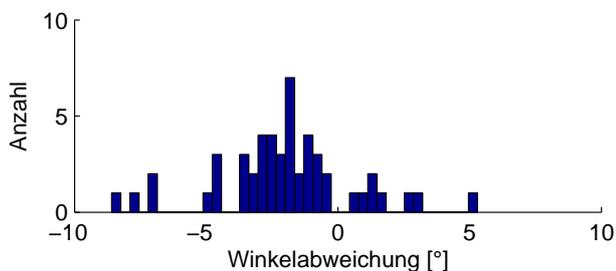


Abb. A.9: Verteilung der Winkelabweichungen bei Drehbewegungen

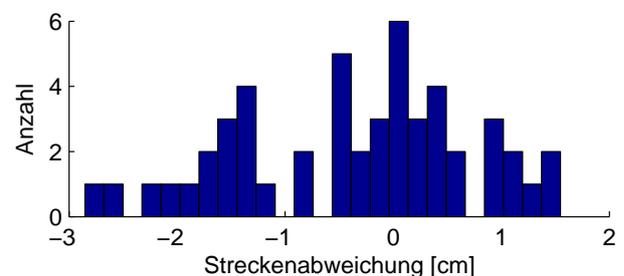


Abb. A.10: Verteilung der Streckenabweichungen bei Geradeausfahrten

Pfade

Um das Zusammenwirken der beschriebenen Fehler zu betrachten, wurde dem System zudem eine 9 m lange Trajektorie aus mehreren Drehungen und Geradeausfahrten vorgegeben, welche es insgesamt 20 mal abzufahren hatte. Dabei wurden die Position und die Orientierung der Plattform zwischen allen Einzelbewegungen beobachtet. In der Versuchsreihe erreichten die Positions- und Orientierungsabweichungen zwischen der durch die Odometrie bestimmten und der wahren⁷ Pose Maximalwerte von 11 cm bzw. 12° . Die Abweichungen zwischen den wahren und den geplanten Posen wiesen Höchstwerte von 10 cm bzw. 10° auf. Die maximale Differenz zwischen den laut Odometrie erreichten und den geplanten Posen betrug 5 cm bzw. 5° . In den Abbildungen A.11 und A.12 sind die Abweichungen der ermittelten Pose laut Odometrie bzw. der wahren Pose bezüglich der geplanten Trajektorie im Verlauf

⁶im Falle von Drehbewegungen ist dies $\pm 1^\circ$

⁷tachymetrisch gemessenen

der Trajektorienverfolgung am Beispiel einer einzelnen Fahrt dargestellt.

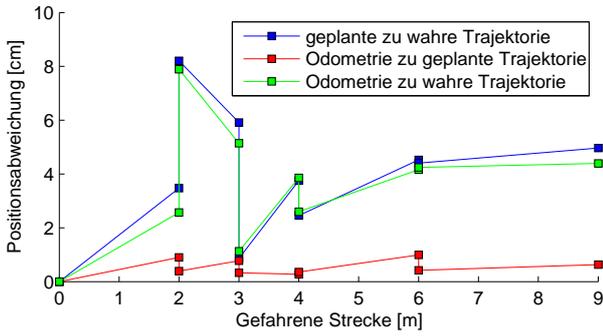


Abb. A.11: Positionsabweichungen in Beispielfahrt

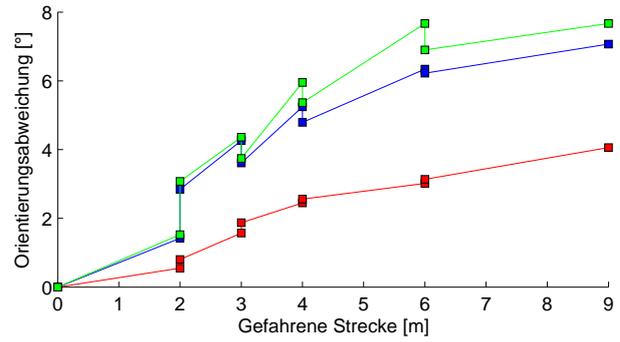


Abb. A.12: Orientierungsabweichungen in Beispielfahrt

A.12 Abbildungen zu Kapitel 4.4

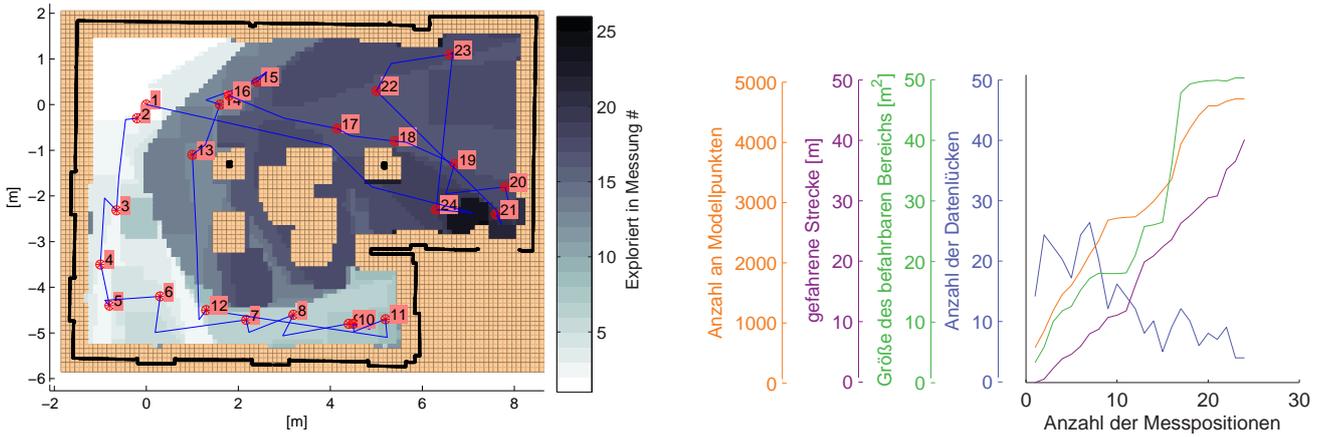


Abb. A.13: Schematische Darstellung der Messfahrt und Parameterverlauf bei $D_{gap} = 2$ cm

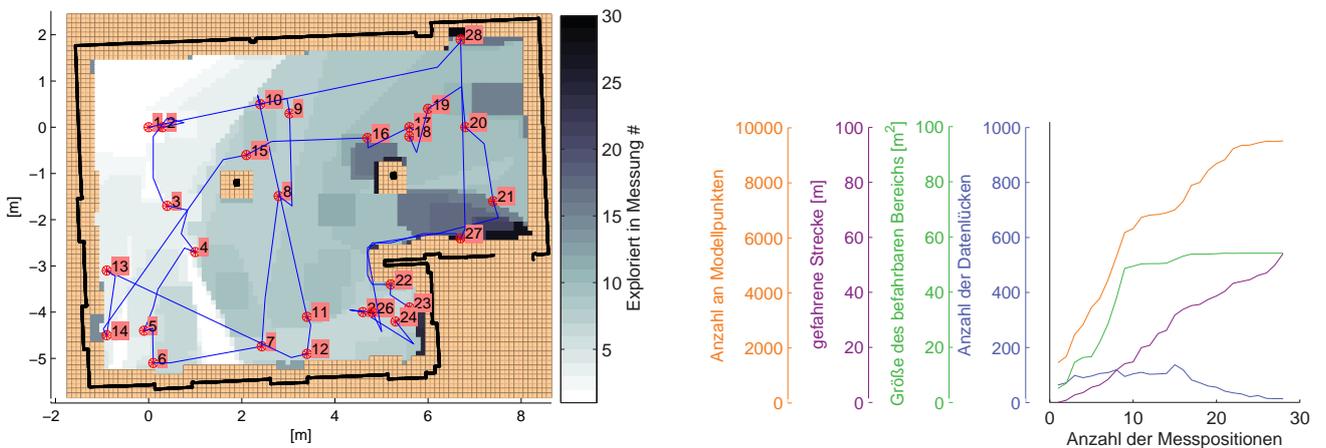


Abb. A.14: Schematische Darstellung der Messfahrt und Parameterverlauf bei $D_{gap} = 1$ cm

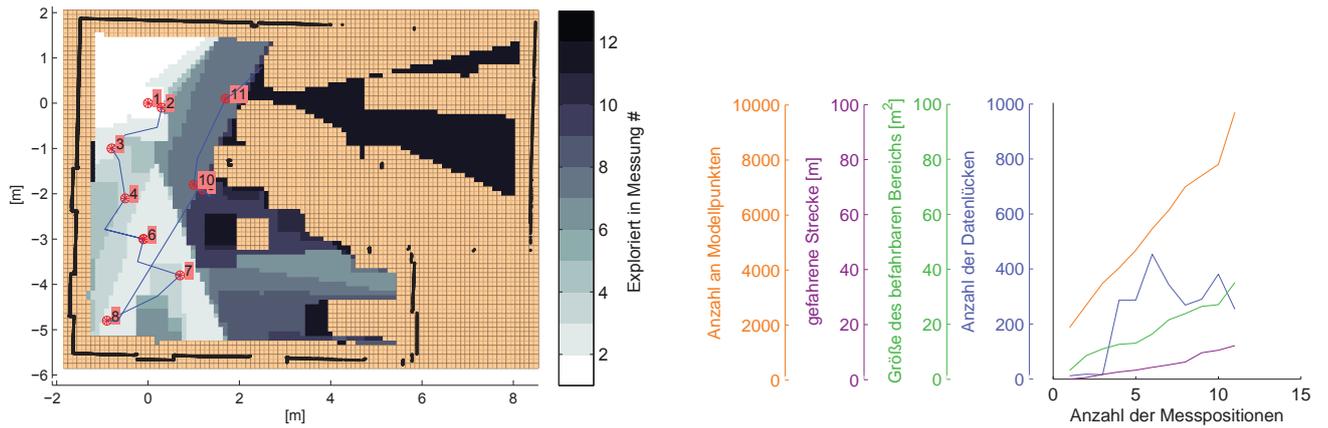


Abb. A.15: Schematische Darstellung der Messfahrt und Parameterverlauf bei $D_{gap} = 0.5$ cm

A.13 Abbildungen zu Kapitel 4.5

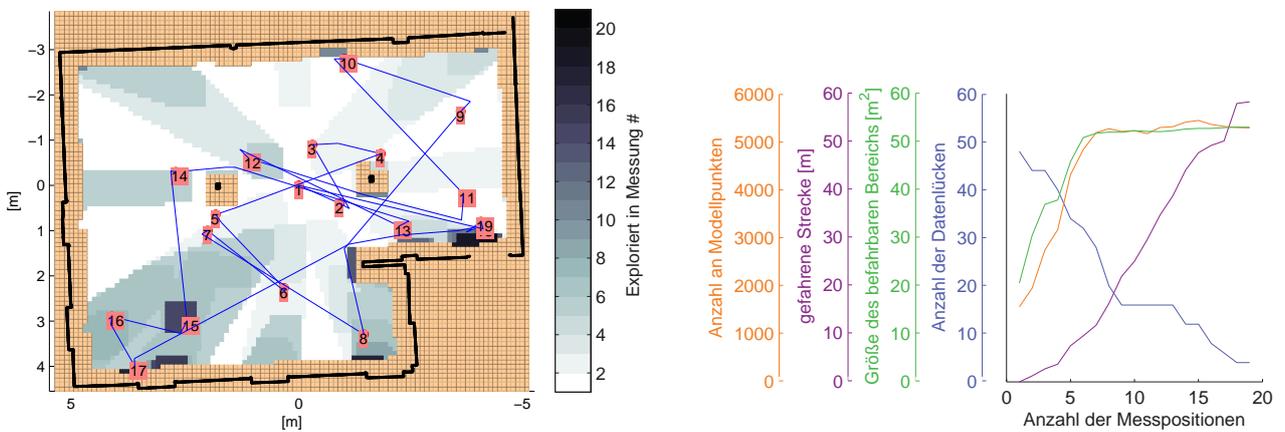


Abb. A.16: Schematische Darstellung und Parameterverlauf der Messfahrt mit Startpunkt: Raummitte

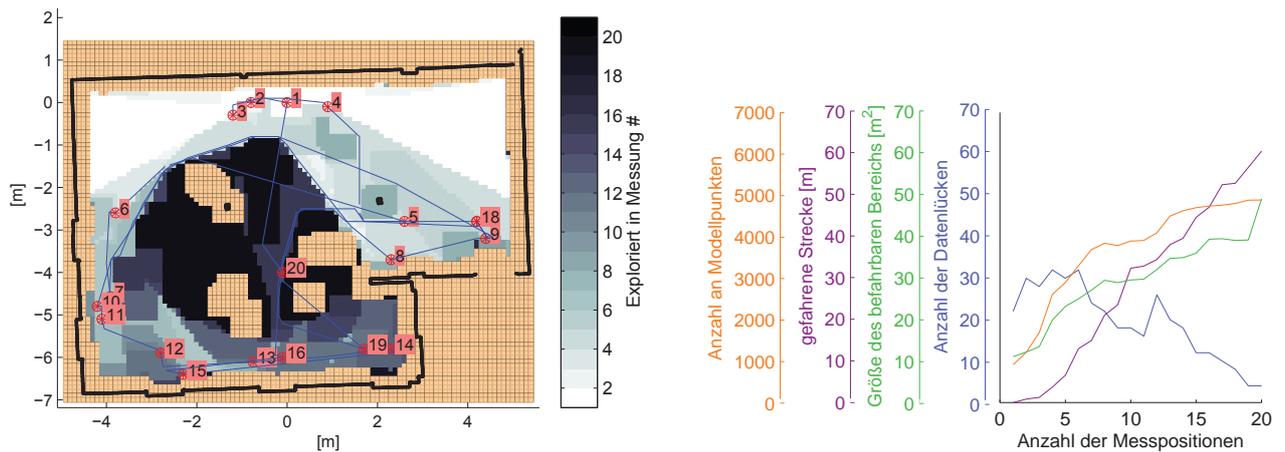


Abb. A.17: Schematische Darstellung und Parameterverlauf der Messfahrt mit Startpunkt: Wandmitte

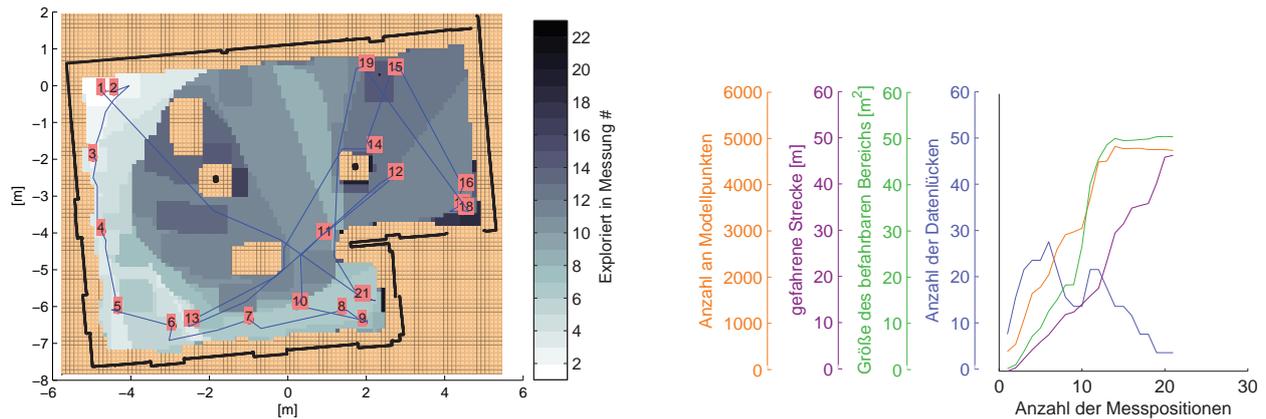


Abb. A.18: Schematische Darstellung und Parameterverlauf der Messfahrt mit Startpunkt: Ecke des Raumes

A.14 Konfigurationsdatei des Rekonstruktionsmoduls

Intrinsic camera parameters

```

intrinsic image width           = 2592
intrinsic image height         = 1944
intrinsic focal length         = 1975.389021546941
intrinsic aspect ratio        = 1.000651470307884
intrinsic pp x                 = 1263.072848069163
intrinsic pp y                 = 1001.448408942958
intrinsic distortion1          = -0.362899005641406
intrinsic distortion2          = 0.149821536822473
intrinsic distortion3          = -0.000149506495739
intrinsic distortion4          = 0.000027177812621
intrinsic distortion5          = 0.0000000000000000

```

Feature Extraction

```

FEATURE SCALESPEACE
feature nb octaves             = 3
feature nb octave images      = 3
feature sigma                  = 1.4142
feature pre sigma              = 0

```

```

FEATURE DETECTOR
feature min dog threshold factor = 0.03
feature max steps location tuning = 5
feature edge response           = 7.0

```

```

FEATURE DESCRIPTOR
feature ori hist sigma factor   = 1.5
feature ori hist percent       = 1.0
feature ori hist nb bins       = 36
feature nb subwindows          = 4
feature nb orientations         = 8
feature sigma scale factor      = 3.0
feature truncate threshold     = 0.2

```

Geometric consistent Feature Matching using ANN-Search and some kind of Outlier Detection Algorithm

```

% Descriptor matching
matcher min distance            = 0.1
matcher ratio 1st 2nd          = 0.8
matcher reverse                 = 1 % match 1- $i_2$  and 2- $i_1$  and merge

matcher geometric consistent method = 0
matcher ransac squared sampson threshold = 0.0001
matcher reprojection error threshold = 4 % RANSAC's post process booster
matcher ransac max iterations    = 100 % number of max RANSAC iterations
matcher good feature ratio      = 0.5001 % at least 50matcher min nb inliers 32 % minimal number of needed inliers

matcher make matches symmetric = 1 % make graph undirected
matcher rebuild matches from tracks = 1 % rebuild complete match lists from tracks

```

Initialization of the 3D Map

```

map init min nb matches        = 80
map init match threshold       = 32
map init apical angle          = 4
map init inlier ratio          = 0.75

```

Incremental Update of the 3D Map

map ransac pose threshold	= 4 % value for reprojection error outlier in pixel
map ransac max iterations	= 5000 % number of max RANSAC iterations
map refine least squares	= 1 % run least-squares pose estimate from all ransac inliers
map post process refine	= 1 % run least-squares pose estimate from all post process inliers
map min nb inliers	= 14 % minimal number of needed inliers
map triangulation angle threshold	= 1 % only insert features in the map with greater intersection angles
map triangulation threshold	= 4 % only insert features in the map with smaller reprojection errors

Thresholds for geometric outlier detection

outlier skip one time outliers	= 0
outlier reprojection error	= 2.0

Bundle Adjustment

bundle run local pose	= 0
bundle run global pose	= 1
bundle run global point	= 1
bundle run final full	= 1 % run a final and full bundle adjustment after
bundle final full min views	= 3 % run the final adjustment only with 3-view points
bundle min redundancy p	= 2
bundle max iterations	= 100 % number iterations without outlier detection
bundle outlier detection	= 1 % perform iterative outlier detection
bundle outlier runs	= 100 % number outlier iterations
bundle outlier value	= 6.0 % reprojection error in pixel
bundle outlier onestep	= 5 % number of max removed outlier / iteration step
bundle use weights	= 0 % use weights
bundle iteration value	= 0.03
bundle sigma apriori	= 1.0

A.15 Definition der Genauigkeit

A.15.1 Messunsicherheit nach GUM

Um die Zuverlässigkeit eines Messergebnisses beurteilen zu können, muß zusätzlich ein Genauigkeitsmaß angegeben werden. Diese sogenannte *Messunsicherheit* wurde mit dem *Guide to the expression of Uncertainty in Measurement* [21] wie folgt definiert:

- Dem Messergebnis zugeordneter Parameter, der die Streuung der Werte kennzeichnet, die vernünftigerweise der Messgröße zugeordnet werden konnte

Das Gesamtbudget der Messunsicherheit enthält in der Regel mehrere Komponenten, die in statistisch berechenbare und systematische Anteile untergliedert werden. Falls möglich, sollten die Komponenten in Form von Standardabweichungen ausgedrückt werden.

A.15.2 Genauigkeitsmaße von Messreihen

Eine genauigkeitsbezogene Aussage zur Kennzeichnung einer endlichen Messreihe bildet die *empirische Standardabweichung*. Hier ist zu unterscheiden, ob der wahre Wert der zu bestimmenden Größe bekannt ist.

Empirische Standardabweichung bei Vorliegen des wahren Wertes \tilde{X} :

Die empirische Standardabweichung s_0 ist ein Maß für die Streuung der Werte einer endlichen Messreihe bei bekanntem wahren Wert \tilde{X} und ist definiert als positive Wurzel der empirischen Varianz:

$$s_0 = \sqrt{\frac{1}{n} \sum_{i=1}^n \varepsilon_i^2} \quad (\text{A.37})$$

mit: $\varepsilon = l - e\tilde{X}$ den wahren Abweichungen ε und $e^T = [1, 1, \dots, 1]$

Empirische Standardabweichung bei Vorliegen des empirischen Mittels \bar{x} :

$$s_0 = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (\text{A.38})$$

mit: $(x_i - \bar{x}^2)$ den Abweichungen vom empirischen Mittel

A.15.3 Genauigkeitskriterien geodätischer Netze

Im Rahmen der Ausgleichsrechnung nach Anhang A.4 finden sich alle zur Genauigkeitsbeurteilung notwendigen Informationen unter Berücksichtigung des Varianzfaktors σ_0^2 in der Kofaktormatrix Q_{xx} wieder. In der Regel wird zwischen *lokalen* und *globalen Genauigkeitskriterien* unterschieden. Lokal bedeutet in diesem Falle eine Betrachtung, die sich auf ausgewählte Elemente der Kofaktormatrix begrenzt, während im globalen Fall die gesamte Kofaktormatrix berücksichtigt wird.

Lokale Genauigkeitskriterien

Das gebräuchlichste Kriterium zur Beurteilung der Netzqualität ist die Berechnung der *Standardabweichung der einzelnen Koordinatenunbekannten*. Werden in der Ausgleichung 2D-Koordinaten geschätzt, ergibt sich eine Kofaktormatrix mit 2×2 Submatrizen, die die Genauigkeiten der Punkte beinhalten:

$$Q_{xx} = \begin{pmatrix} \begin{bmatrix} q_{x1x1} & q_{x1y1} \\ q_{y1x1} & q_{y1y1} \end{bmatrix} & q_{x1x2} & q_{x1y2} & \dots & q_{x1xn} & q_{x1yn} \\ & q_{y1x2} & q_{y1y2} & \dots & q_{x1xn} & q_{x1yn} \\ q_{x2x1} & q_{x2y1} & \begin{bmatrix} q_{x2x2} & q_{x2y2} \\ q_{y2x2} & q_{y2y2} \end{bmatrix} & \dots & q_{x2xn} & q_{x2yn} \\ & & & \dots & q_{x2xn} & q_{x2yn} \\ & \vdots & \vdots & \ddots & \vdots & \vdots \\ q_{xnx1} & q_{xny1} & q_{xnx2} & q_{xny2} & \dots & \begin{bmatrix} q_{xnxn} & q_{xnyn} \\ q_{ynxn} & q_{ynyn} \end{bmatrix} \\ q_{ynx1} & q_{yny1} & q_{ynx2} & q_{yny2} & \dots & \end{pmatrix} \quad (\text{A.39})$$

Bei Verwendung des theoretischen Varianzfaktors σ_0^2 gilt :

$$\sigma_{xi} = \sigma_0 \cdot \sqrt{q_{xixi}} \quad (\text{A.40})$$

bei Vorliegen des Schätzwertes s_0^2 gilt :

$$s_{xi} = s_0 \cdot \sqrt{q_{xixi}} \quad (\text{A.41})$$

Der Schätzwert s_0^2 von σ_0^2 wird gebildet über:

$$s_0^2 = \frac{v^T P v}{n - u} \quad (\text{A.42})$$

und ergibt sich damit abhängig von den Fehlern des Beobachtungsmaterials.

Die Darstellung eines Genauigkeitsbereiches der Koordinatenunbekannten ist geometrisch anschaulicher und interpretierbarer. Im \mathbb{R}^n geschieht dies über n-dimensionale Hyperellipsoide, im \mathbb{R}^2 also über Ellipsen.

Gegeben sei z.B. ein Punkt P eines 2D-Netzes, samt der entsprechenden Kofaktormatrix Q_{xx} . Die zu P gehörenden Elemente in Q_{xx} bilden eine Submatrix Q_{xx}^j auf der Hauptdiagonalen von Q_{xx} . Das Vorliegen des Varianzfaktors σ_0^2 vorausgesetzt, lassen sich die große und die kleine Halbachse A_H und B_H sowie der Richtungswinkel θ_H der zugehörigen *Helmertschen Fehlerellipse* aus Q_{xx}^i direkt ableiten:

$$\begin{aligned} A_H^2 &= \frac{1}{2} \cdot \sigma_0^2 \cdot (q_{xx} + q_{yy} + w) \\ B_H^2 &= \frac{1}{2} \cdot \sigma_0^2 \cdot (q_{xx} + q_{yy} - w) \\ \tan(2\theta_H) &= 2 \cdot \frac{q_{xy}}{q_{xx} - q_{yy}} \end{aligned} \quad (\text{A.43})$$

mit der Hilfsgröße w :

$$w^2 = (q_{xx} - q_{yy})^2 + 4 \cdot q_{xy}^2 \quad (\text{A.44})$$

Grundsätzlich lassen die Halbachsen der Fehlerellipsen bzw. -ellipsoide über eine Spektral- bzw. Eigenwertzerlegung von Q_{xx}^j herleiten:

$$[\lambda_i, \Lambda_i] = \text{eig}(Q_{xx}^j) \quad (\text{A.45})$$

Wobei die Eigenwerte λ_i den Achslängen und die Eigenvektoren Λ_i den Achsrichtungen entsprechen. Im \mathbb{R}^2 resultieren die Eigenwerte λ_i z.B. aus:

$$\det \begin{vmatrix} q_{ii} - \lambda & q_{ij} \\ q_{ij} & q_{jj} - \lambda \end{vmatrix} = 0 \quad (\text{A.46})$$

Die Halbachsen der Helmertschen Fehlerellipsen ergeben sich damit über:

$$\begin{aligned} A_H^2 &= \sigma_0^2 \cdot \lambda_1 \\ B_H^2 &= \sigma_0^2 \cdot \lambda_2 \end{aligned} \quad (\text{A.47})$$

Die Ausprägung von σ_0^2 bzw. s_0^2 ist abhängig von der Anzahl der Netzfreiheitsgrade. Daher bilden die Helmertschen Fehlerellipsen kein statistisches Maß. Um einen Bereich um die geschätzte Punktlage zu ermitteln, der die wahre Punktlage mit einer gegebenen Sicherheitswahrscheinlichkeit $1 - \alpha$ beinhaltet, können Konfidenzellipsen bzw. -ellipsoide herangezogen werden. Dafür ist im 2D-Fall die Helmertsche Fehlerellipse abhängig vom Vorliegen des Schätzwertes s_0^2 mit einem entsprechenden Verteilungsquantil zu erweitern.

Liegt kein Schätzwert s_0^2 vor, muss auf den theoretischen Varianzfaktor σ_0^2 und die χ^2 -Verteilung zurückgegriffen werden. Die Achsen D_{Ki} der Konfidenzellipsoide ergeben sich aus den Helmert-Achsen D_{Hi} über:

$$D_{Ki}^2 = \chi_{f,1-\alpha}^2 \cdot D_{Hi}^2 \quad (\text{A.48})$$

wobei f den Dimensionen des Netzes entspricht.

Ist dagegen ein verlässlicher Schätzwert s_0^2 verfügbar, sollte dieser auch mit einbezogen werden. So

ergeben sich die D_{Ki} über die F -Verteilung:

$$D_{Ki}^2 = s_0^2 \cdot \lambda_i \cdot r \cdot F_{1-\alpha, r, n-u} \quad (\text{A.49})$$

wobei r den Dimensionen des Netzes entspricht und $n - u$ die überschüssigen Beobachtungen bei der Schätzung von s_0^2 bezeichnet.

Globale Genauigkeitskriterien

Globale Genauigkeitskriterien dienen für eine Beurteilung des gesamten Netzes und können für deren Optimierung aber auch zum Vergleich gegenüber weiteren Netzen verwendet werden.

An dieser Stelle sei zum Einen das *Varianzkriterium* hervorgehoben, das vergleichbar mit einer Summation aller Ellipsenachsen ist. Es fordert:

$$sp(\sum_{xx}) = \lambda_1 + \lambda_2 + \dots + \lambda_u = \sum_{i=1}^u \lambda_i \rightarrow \min \quad (\text{A.50})$$

wobei λ_i die Eigenwerte der Kovarianzmatrix \sum_{xx} in absteigender Reihenfolge bezeichnen. Im Gegensatz zum *Volumen des Konfidenzhyperboloids* bei dem die Eigenwerte multipliziert werden und einzelne große Ellipsen das Ergebnis verfälschen können.

Ein weiteres Maß bildet die *Mittlere Koordinatengenauigkeit* $\bar{\sigma}_x^2$, die sich mit den lokalen Genauigkeitsmaßen vergleichen läßt.

$$\bar{\sigma}_x^2 = sp(\sum_{xx}) \cdot \frac{1}{u} \quad (\text{A.51})$$

Weitere globale Genauigkeitswerte bilden die *Isotropie* und die *Homogenität*. Die Homogenität fordert die Konformität der Fehlerellipsen innerhalb eines Netzes. Die Isotropie verlangt eine Richtungsunabhängigkeit der Genauigkeit also eine Kreisform der Ellipsen. Homogene und isotrope Netze weisen Eigenwerte λ_i gleicher Größe auf. Daher kann hier folgende, gemeinschaftliche Forderung gestellt werden:

$$\frac{\lambda_{max}}{\lambda_{min}} \rightarrow 1 \quad (\text{A.52})$$

A.16 Min-Cut-Max-Flow-Theorem

Das Max-Flow-Min-Cut-Theorem dient dazu den *maximalen Fluss* F_{max} (engl: *max-flow*) innerhalb eines Netzwerks von einem Startpunkt Q zu einem Zielpunkt S zu beschreiben, indem ein minimaler Schnitt (engl.: *min-cut*) angelegt wird. Das Netzwerk liegt dabei in Form eines gerichteten und gewichteten Graphen $G(A, O)$ mit den Kanten $A(m, n)$ und den Knoten O vor. Jede Kante $A(m, n)$ verfügt über eine richtungsabhängige Gewichtung $a_{m \rightarrow n}$ bzw. $a_{n \rightarrow m}$. Der minimale Schnitt C_{min} teilt die Knoten des Graphen in zwei disjunkte Teilmengen T_1 mit $Q \in T_1$ und T_2 mit $S \in T_2$. Die Kanten zwischen den beiden Teilmengen bilden C_{min} , die Gewichtssumme der Kanten $T_1 \rightarrow T_2$ entspricht F_{max} . Abbildung A.19 veranschaulicht dies in einem Beispiel. Ein Algorithmus zur Bestimmung des maximalen Flusses ist z.B. in [29] gegeben.

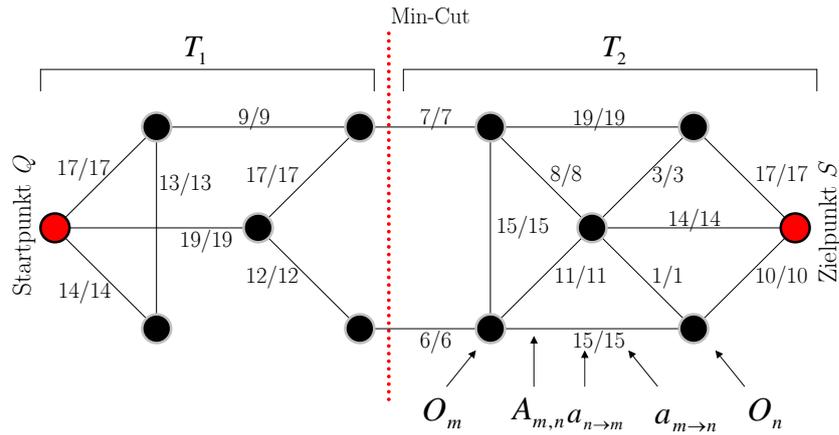


Abb. A.19: Max-Flow und Min-Cut in einem Beispielnetzwerk. $F_{max} = 6 + 7 = 13$

A.17 Registrierung mittels Singulärwertzerlegung

Eine Möglichkeit um die Parameter zur Transformation einer Menge von n 3-dimensionalen Punkten Y'' in das Koordinatensystem einer korrespondierenden Punktmenge X' zu ermitteln, stellt die Singulärwertzerlegung (engl.: *single value decomposition* oder kurz *SVD*) dar.

Zunächst gilt es die beiden Datensätze um ihren Schwerpunkt zu reduzieren:

$$\begin{matrix} X'_r \\ (n,3) \end{matrix} = X' - \bar{X}' \qquad \begin{matrix} Y''_r \\ (n,3) \end{matrix} = Y'' - \bar{Y}'' \qquad (A.53)$$

Eine Singulärwertzerlegung der Matrix M führt zu deren Darstellung als Produkt der 3 Matrizen u , s und v :

$$[u, s, v] = svd(M) \quad \text{mit:} \quad \begin{matrix} M \\ (3,3) \end{matrix} = Y''_r X'_r \qquad (A.54)$$

Die gesuchten Transformationsparameter R , T und a ergeben sich dann über:

$$\begin{aligned} \begin{matrix} R \\ (3,3) \end{matrix} &= v u^T & (A.55) \\ \begin{matrix} T \\ (1,3) \end{matrix} &= -Y''_r R^T X'_r \\ \begin{matrix} a \\ (1,1) \end{matrix} &= \frac{Spur(MR)}{Spur(Y''_r^T Y''_r)} \end{aligned}$$

Y'' läßt sich schließlich in das Koordinatensystem K' transformieren über:

$$Y' = a R^T Y'' + T \qquad (A.56)$$

Literaturverzeichnis

- [1] A* Pathfinding for Beginners. Domain: <http://www.policyalmanac.org/games/aStarTutorial.html>. (20.09.10)
- [2] **J. Bauer, N. Sünderhauf, P. Protzel.** *Comparing several implementations of two recently published feature detectors.* In: Proc. of the International Conference on Intelligent and Autonomous Systems. (2007)
- [3] **H. Bay, V. Ferrari, L. Van Gool.** *Wide-baseline stereo matching with line segments.* In: IEEE Conf. on Computer Vision and Pattern Recognition, vol. I, pp. 329–336. (2005)
- [4] **J. Beis, D.G. Lowe.** *Shape indexing using approximate nearest-neighbour search in high-dimensional spaces.* In: Conference on Computer Vision and Pattern Recognition, Puerto Rico, pp. 1000–1006. (1997)
- [5] **P. Besl, N. McKay.** *A method for Registration of 3D shapes.* In IEEE Transaction on Pattern Analysis and Machine Intelligence 14, Nr. 2, Seiten 239-256. (1992)
- [6] **P. Biber, H. Andreasson, T. Duckett, and A. Schilling.** *3D Modeling of Indoor Environments by a Mobile Robot with a Laser Scanner and Panoramic Camera.* In Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS'04), Sendai, Japan. (2004)
- [7] Bildquelle: <http://commons.wikipedia.org>.
- [8] Bildquelle: <http://www.bosch.co.jp>.
- [9] Bildquelle: *TPS400_Brochüre_de.pdf* - www.leica.de.
- [10] **J.-Y. Bougurt.** *Camera calibration toolbox for Matlab.* Domain: http://www.vision.caltech.edu/bouguet/calib_doc/. (2011)
- [11] **C. Brenner.** *Building reconstruction from images and laser scanning.* International Journal of Applied Earth Observation and Geoinformation. (2004)
- [12] **C. Bräuer-Burchardt.** *Automatic Monocular 3D-Reconstruction of Indoor Environments Using Mobile Vehicles.* DAGM, LNCS 2449, pp.370-378. (2002)
- [13] **D. Brown.** *Decentering distortion of lenses.* Photometric Engineering, 32(3):444 – 462. (1966)
- [14] **A. Budroni, J. Böhm.** *Automatic 3D modelling of indoor manhattan-world scenes from laser data.* ISPRS Vol. 18, Part 5 Commission V Symposium. (2010)
<http://www.ams.jhu.edu/castello/362/Handouts/hungarian.pdf>
- [15] **B. Castello.** *The Hungarian Algorithm.* Handout. Domain: <http://www.ams.jhu.edu/castello/362-Handouts/hungarian.pdf>. (17.01.2011)
- [16] **A. Censi.** *An icp variant using a point-to-line metric.* in Proceedings of the IEEE International Conference on Robotics and Automation (ICRA). (2008)
- [17] **C. Connolly.** *The Determination of Next Best Views.* Proc. IEEE Int'l Conf. Robotics and Automation, pp. 432-435. (1985)

- [18] **J. M. Coughlan, A. L. Yuille.** *Manhattan World: Compass Direction from Single Image by Bayesian Inference.* Proceedings of the 7th International Conference on Computer Vision ICCV, Kerkyra, Greece, pp. 941-947. (1999)
- [19] **I. J. Cox.** *Blanche: Position estimation for an autonomous robot vehicle.* In: Cox und Wilfong, Seiten 221-228. (1990)
- [20] **E. Delage, H. Lee.** *Automatic single-image 3D reconstructions of indoor manhattan world scenes.* In Proc. IEEE Comp. Software and Applications Conf. pp. 433-438. (2005)
- [21] DIN ENV 13005. *Leitfaden zur Angabe der Unsicherheit beim Messen (GUM).* Beuth Verlag, Berlin. (1999)
- [22] **E. W. Dijkstra.** *A note on two problems in connexion with graphs.* In: Numerische Mathematik. 1, S. 269–271. (1959)
- [23] **M. Dorigo, L. M. Gambardella.** *Ant Colony System: A cooperative learning approach to the traveling salesman problem.* IEEE Transactions on Evolutionary Computation, vol. 1, no. 1, pp. 53–66, (1997).
- [24] **A. Elfes.** *Using occupancy grids for mobile robot perception and navigation.* IEEE Computer, 22(6):46–57. (1989)
- [25] **M.A. Fischler, R.C. Bolles.** *Random Sample Consensus: A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography.* In.: Commun. ACM 24, 381–395. (1981)
- [26] **R. Fisher, S. Perkins, A. Walker, E. Wolfart.** *A Computational Approach To Edge Detection.* IEEE Trans. Pattern Analysis and Machine Intelligence, 8:679–714. (1986)
- [27] **W. Förstner.** *Manual of Photogrammetry.* Chapter 3, Mathematics of Photogrammetry. American Society of Photogrammetry ASPRS. (1980)
- [28] **W. Förstner, T. Dickscheid, F. Schindler.** *Detecting Interpretable and Accurate Scale-Invariant Keypoints.* In: 12th IEEE International Conference on Computer Vision. (2009)
- [29] **L. R. Ford Jr., D. R. Fulkerson.** *Maximal flow through a network.* Can. J. Math. 8, 399-404. (1956)
- [30] **D. Fox, W. Burgard, F. Dellart, S. Thrun.** *Monte Carlo Localization: Efficient Position Estimation for Mobile Robots.* In: Proc. of the National Conference on Artificial Intelligence. (1999)
- [31] Fraunhofer IAIS Projekt: VolksBot. Domain: <http://www.volksbot.de/>. (29.09.2009)
- [32] **J. Fryer, D. Brown.** *Lens distortion for close-range photogrammetry.* Photogrammetric Engineering and Remote Sensing, 52(1):51 – 58. (1986)
- [33] **Y. Furukawa, B. Curless, S. M. Seitz, R. Szeliski.** *Reconstructing building interiors from images.* Reconstructing building interiors from images. In Intl. Conf. on Computer Vision (ICCV). (2009)
- [34] **Y. Furukawa, J. Ponce.** *PMVS.* Domain: <http://www.cs.washington.edu/homes/furukawa/research/pmvs>. (15.09.2010)
- [35] **N. Gelfand, L. Ikemoto, S. Rusinkiewicz, M. Levoy.** *Geometrically stable smapling for the ICP algorithm.* In Proceedings of Fourth International Conference on 3-D Digital Imaging and Modeling 3DIM, page 260. (2003)
- [36] **F. Glover.** *Tabu search – part I.* ORSA Journal on Computing, vol. 1, no. 3, pp. 190–206. (1989)
- [37] **H. H. González-Baños, J. C. Latombe.** *Navigation strategies for exploring indoor environments.* International Journal of Robotics Research. (2001)

- [38] **T. Gramegna, G. Attolico, A. Distanti.** *Planar map and 3D model construction using a mobile robot.* In Proceedings of the International Symposium on Automation and Robotics in Construction ISARC, Ferrara (Italy). (2005)
- [39] **J. S. Gutmann, K. Konolige.** *Incremental mapping of large cyclic environments.* In Proceedings of the IEEE International Symposium on Computational Intelligence in Robotics and Automation (CIRA), California. (1999)
- [40] **J. S. Gutmann.** *Robuste Navigation autonomer mobiler Systeme.* Akademische Verlagsgesellschaft Aka, Berlin. Doktorarbeit an der Universität Freiburg. (2000)
- [41] **D. Hähnel.** *Mapping with Mobile Robots.* Dissertation, Universität Freiburg. (2004)
- [42] **C. Harris, M. Stephens.** *A combined corner and edge detector.* In: ALVEY Vision Conference, Seiten 147-151. (1988)
- [43] **R. Hartley, A. Zisserman.** *Multiple view geometry in computer vision.* Cambridge University Press: Cambridge, UK. (2000)
- [44] **Y. Hwang, N. Ahuja.** *Gross motion planning – a survey.* In: ACM Computing Surveys, 24(3):219–291. (1992)
- [45] **S. M. Jackisch, M. Roland, B. Pitzer.** *Technischer Abschlussbericht Funktionsmuster 2 - Concept-study AEG-520 Prototype system for photogrammetric survey of complex 3D room geometry with 3DIM (3D Indoor Measuring).* Interner Bericht, CRAEG0901 Robert Bosch GmbH Schwieberdingen. (2011)
- [46] **A. R. Jiménez-Sánchez, J. D. Mendiola-Santibañez, I. R. Terol-Villalobos, G. Herrera-Ruiz, D. Vargas-Vázquez, J. J. García-Escalante, A. Lara-Guevara.** *Morphological Background Detection and Enhancement of Images With Poor Lighting.* IEEE transaction on Image Processing vol. 18, no. 3. (2009)
- [47] **T. Kahlmann.** *Range imaging metrology: Investigation, calibration and development.* Dissertation, Institute of Geodesy and Photogrammetry, ETH Zurich (2008).
- [48] **H. Kahmen.** *Vermessungskunde.* 19. Auflage, Walter de Gruyter, Berlin, New York, pp. 475 – 482 (1997)
- [49] **O. Khatib.** *Real-Time Obstacle Avoidance for Manipulators and Mobile Robots.* Int. J. Robotics Res., vol. 5, pp 90-98. (1986)
- [50] **Y. M. Kim, C. Theobald, J. Diebel, J. Kosecka, B. Mircusik, S. Thrun.** *Multi-view image and tof sensor fusion for dense 3d reconstruction.* In Proc. of 3DIM Conf. (2009)
- [51] Kinect Spielekonsole. Domain: <http://www.xbox.com/Kinect/>. (29.11.10)
- [52] **G. Klein, D. Murray.** *Parallel Tracking and Mapping for Small AR Workspaces.* In Proc. of ISMAR 2007, pp225-234. (2007)
- [53] **K. Klein.** *Automatisierung der 3D-Rekonstruktion aus mehreren Tiefenbildern durch Optimierung präzidierter Qualitätsgewinne.* Dissertation, Universität Darmstadt. (2008)
- [54] **S. Koenig, M. Likhachev, D. Furcy.** *Lifelong Planning A*.* Artificial Intelligence, 155(1-2):93–146. (2004)
- [55] **G. K. Krättschmar, G. Pagás Gasull, K. Uhl.** *Probabilistic quadrees for variable-resolution mapping of large environments.* In: Proceedings of the 5th IFAC/EURON Symposium on Intelligent Autonomous Vehicles, M.I. Ribiero and J. Santos Victor, Eds. (2004)

- [56] **K. Kraus.** *Photogrammetrie, Band1, Grundlagen und Standardverfahren.* 6. Aufl., Ferd. Dümmlers Verlag, Bonn, ISBN: 3-427-78646-3. (1997)
- [57] **H. W. Kuhn.** *The hungarian method for the assignment problem.* Naval Research Logistic Quarterly, 2 83–97. (1955)
- [58] **B. Kuipers.** *Modeling spatial knowledge.* Cognitive Science, 2:129–153. (1978)
- [59] **B. Kuipers, Y. T. Byun.** *A robot exploration and mapping strategy based on a semantic hierarchy of spatial representations.* Journal of Robotics and Autonomous Systems, 8. (1991)
- [60] **S. Lacroix, A. Mallet, D. Bonnafous, G. Bauzil, S. Fleury, M. Herrb, R. Chatila.** *Autonomous Rover Navigation on Unknown Terrains: Functions and Integration.* International Journal of Robotics Research, vol. 21, issue 10. (2002)
- [61] **M. Langerwisch, B. Wagner.** *Registration of indoor 3D Range images using virtual 2D scans.* 7th International Conference on Informatics in Control, Automation and Robotics - ICINCO. (2010)
- [62] **J.-C. Latombe.** *Robot Motion Planning.* Kluwer, Boston, MA. (1991)
- [63] **S. LaValle.** *Rapidly-exploring random trees: A new tool for path planning.* Technical Report 98-11, Computer Science Dept., Iowa State University, Oct. (1998)
- [64] **S. LaValle, J. J. Kuffner.** *Rapidly-exploring random trees: Progress and prospects.* In Proceedings Workshop on the Algorithmic Foundations of Robotics. (2000)
- [65] **S. LaValle.** *Planning Algorithms.* Cambridge University Press. (2006)
- [66] **J. Lehn, H. Wegmann.** *Einführung in die Statistik.* Darmstadt. (1985)
- [67] **K.-L. Low.** *Some Conditions for Accurate Surface Registration.* Technical Report TR05-008, Department of Computer Science, University of North Carolina at Chapel Hill. (2005)
- [68] **K.-L. Low, A. Lastra.** *An Adaptive Hierarchical Next-Best-View Algorithm for 3D Reconstruction of Indoor Scenes.* In: 14th Pacific Conference on Computer Graphics and Applications (2006)
- [69] **D. G. Lowe.** *Object recognition from local scale-invariant features.* International Conference on Computer Vision, Corfu, Greece, pp. 1150-1157. (1999)
- [70] **D. G. Lowe.** *Distinctive image features from scale-invariant keypoints.* International Journal of Computer Vision, 60, 2 (2004), pp. 91-110. (2004)
- [71] **F. Lu, E. Milios.** *Robot pose estimation in unknown environments by matching 2D range scans.* In: IEEE Computer Vision and Pattern Recognition. (1996)
- [72] **D. Marr, E. Hildreth.** *Theory of edge detection.* Proc. Roy. Soc. London, vol. B 207, pp. 187-217. (1980)
- [73] **S. Mason, A. Grün.** *Automating the sensor placement task for accurate dimensional inspection.* Computer Vision and Image Understanding. Special Issue on CAD-Based Vision, 61(3); 454-467. (1995)
- [74] Microsoft Live Labs Software Applikation: Photosynth Domain: <http://www.Photosynth.net/>. (30.07.10)
- [75] **K. Mikolajczyk, C. Schmid.** *A performance evaluation of local descriptors.* IEEE Transactions on Pattern Analysis & Machine Intelligence, 27(10):1615–1630. (2005)
- [76] **J. Minguez, L. Montesano, F. Lamiraux.** *Metricbased iterative closest point scan matching for sensor displacement estimation.* IEEE Transactions on Robotics, Vol. 22(5), 1047–1054. (2006)

- [77] **H.P. Moravec, A. Elfes.** *High resolution maps from wide angle sonar.* In Proc. International Conference on Robotics and Automation ICRA. (1985)
- [78] **F. Moreno-Noguer, V. Lepetit, P. Fua.** *Accurate Non-Iterative $O(n)$ Solution to the PnP Problem.* IEEE ICCV. (2007)
- [79] **K. Murphy.** *Bayesian Map Learning in Dynamic Environments.* In: Advances in Neural Information Processing Systems. MIT Press, Denver, USA, p.1015-1021. (1999)
- [80] **V. Nguyen, A. Martinelli, N. Tomatis, R. Siegwart.** *A comparison of line extraction algorithms using 2D laser rangefinder for indoor mobile robotics.* Proc. Conference on Intelligent Robots and Systems, Aug 2005, Edmonton, Canada pp. 1929–1934. (2005)
- [81] **V. Nguyen, A. Harati, R. Siegwart.** *A lightweight SLAM algorithm using orthogonal planes for indoor mobile robotics.* In Proc. IEEE/RSJ International Conference on Intelligent Robots and Systems IROS 2007, pages 658–663. (2007)
- [82] **W. Niem, M. Roland, S.M. Jackisch.** *Verfahren und Messsystem zur bildbasierten Vermessung eines Raumes.* DE 10 2008 002 241 A1 2009.12.10, Deutsche Patentanmeldung. (2008)
- [83] **W. Niemeier.** *Ausgleichsrechnung.* de Gruyter, Berlin - New York 2002, ISBN 3-11-014080-2. (2002)
- [84] **N. J. Nilsson.** *Principles of Artificial Intelligence.* Tioga Publishing Company, Wellsboro, PA, USA. (1980)
- [85] **D. Nistér.** *An Efficient Solution to the Five-Point Relative Pose Problem.* IEEE Conference on Computer Vision and Pattern Recognition, Volume 2, pp. 195-202. (2003)
- [86] **A. Nüchter.** *Semantische dreidimensionale Karten für autonome mobile Roboter.* Dissertation, Universität Bonn. (2006)
- [87] **B.C. Ooi.** *Spatial kd-tree: An indexing mechanism for spatial databases.* In Proc. IEEE Comp. Software and Applications Conf. pp. 433-438. (1987)
- [88] **N.R. Pal, S.K. Pal.** *A review on image segmentation techniques.* Pattern Recognition 26 pp. 1277–1294. (1993)
- [89] **M. Pollefeys, D. Nistér, J.-M. Frahm, A. Akbarzadeh, P. Mordohai, B. Clipp, C. Engels, D. Gallup, S.-J. Kim, P. Merrell, C. Salmi, S. Sinha, B. Talton, L. Wang, Q. Yang, H. Stewenius, R. Yang, G. Welch, H. Towles .** *Detailed real-time urban 3d reconstruction from video.* Int. J. of Computer Vision. (2008)
- [90] **E. Prassler, A. Ritter, C. Schaeffer, P. Fiorini.** *A Short History of Cleaning Robots.* Autonomous Robots, V9, 211-226. (2000)
- [91] **H. Samet.** *Quadtree, Octrees, and Other Hierarchical Methods.* Addison Wesley. (1989)
- [92] **D. Schmidt, T. Luksch, J. Wettach, K. Berns.** *Autonomous behavior-based exploration of office environments.* 3rd International Conference on Informatics in Control, Automation and Robotics - ICINCO. (2006)
- [93] **W. R. Scott, G. Roth, J.-F. Rivest.** *View Planning with a Registration Component.* Proceedings of IEEE International Conference on 3D Digital Imaging and Modeling 3DIM. (2001)
- [94] SICK Vertriebs-GmbH: *Datenblatt Sick LMS291-S05.* Domain: <http://www.sick.com/>. (15.10.10)

- [95] **N. Snavely**. *Modeling the world from internet photo collections*. Int. J. Comput. Vis., vol. 80, no. 2, pp. 189–210. (2008)
- [96] **N. Snavely**. *Bundler: SfM for unordered image collections*. Domain: <http://phototour.cs.washington.edu/bundler/>. (15.09.10)
- [97] **C. Stachniss, D. Haehnel, W. Burgard**. *Exploration with active loop-closing for FastSLAM*. In: Proceeding of 2004 IEEE/RSJ International Conference on Intelligent Robots and Systems. Sendai, Japan, pp.1505–1510. (2004)
- [98] **C. Stachniss, O. M. Mozos, W. Burgard**. *Efficient exploration of unknown indoor environments using a team of mobile robots*. Annals of Mathematics and Artificial Intelligence (AMAI), vol. 52, pp. 205-227. (2009)
- [99] **A. Stentz**. *Optimal and Efficient Path Planning for Partially-Known Environments*. Tagungsband: IEEE International Conference on Robotics and Automation, Band 4, Seiten 3310–3317, San Diego, CA, USA. (1994)
- [100] **S. Stiene**. *Multisensorfusion zur semantisch gestützten Navigation eines autonomen Assistenzroboters*. Doctoral Dissertation, Univ. Osnabrück. (2009)
- [101] **H. Surmann, A. Nüchter, J. Hertzberg**. *An autonomous mobile robot with a 3D laser range finder for 3D exploration and digitalization of indoor environments*. Robotics and Autonomous Systems, vol. 45, pp. 181–198. (2003)
- [102] TachyCAD: Tachymetrische Aufnahmesoftware Domain: <http://www.kubit.de/>. (19.08.10)
- [103] **S. Thrun**. *Learning Metric-Topological Maps for Indoor Mobile Robot Navigation*. Artificial Intelligence, vol. 99, no. 1, pp. 21-71. (1998)
- [104] **A. Torii, M. Havlena, T. Pajdla, B. Leibe**. *Measuring camera translation by the dominant apical angle*. IEEE CVPR. (2008)
- [105] **B. Visel, A. Fietz**. *Abschluss/Ergebnisse Teil-Projekt CR/AEG-320-SP2: Schnell scannendes prototypisches System zur halbautomatischen Innenraumvermessung in 2.5D*. Bosch interner Abschlussbericht, Robert Bosch GmbH Schwieberdingen. (2010)
- [106] **G. Vosselman, B. Gorte, G. Sithole und T. Rabbani**. *Recognizing structure in laser scanner point clouds*. In: Proceedings of Conference on Laser scanners for Forest and Landscape assessment and instruments, Freiburg, Germany. (2004)
- [107] **P. Waldhäusl, C. Ogleby**. *3×3 Rules for simple photogrammetric documentation of architecture*. In: International Archives of Photogrammetry and Remote Sensing, Vol.XXX, Part5, pp 426-429. (1994)
- [108] **J. Weber**. *Globale Selbstlokalisierung für mobile Service Roboter*. Dissertation, Universität Kaiserslautern. (2002)
- [109] **J. Weingarten**. *Feature-based 3D SLAM*. PhD Thesis, Swiss Federal Institute of Technology Lausanne, EPFL, no 3601, Dir.: Roland Siegwart. (2006)
- [110] **K. Weicker**. *Evolutionäre Algorithmen*. In Karsten Weicker (Hrsg.), Softcomputing - Tagungsband zum ersten Softcomputing-Treffen, S. 27–39. Informatikverbund Stuttgart, Stuttgart. (1999)
- [111] **G. Weiß, C. Wetzler, E. v. Puttkamer**. *Keeping track of position and orientation of moving indoor systems by correlation of range-finder scans*. In Proc. International Conference on Intelligent Robots and Systems IROS. (1994)

-
- [112] **S. Winkelbach, M. Rilk, C. Schönfelder, F. M. Wahl.** *Fast Random Sample Matching of 3d Fragments.* in Pattern Recognition (DAGM), Lecture Notes in Computer Science 3175, Springer: 129-136. (2004)
- [113] **O. Wulf, C. Brenneke, B. A. Wagner.** *Colored 2D Maps for Robot Navigation with 3D Sensor Data.* In Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS '04), Sendai, Japan. (2004)
- [114] **J. Xiao, T. Fang, P. Zhao, M. Lhuillier, L. Quan.** *Image-based street-side city modeling.* ACM Trans. Graph. 28, 5, 1-12. (2009)
- [115] **B. Yamauchi.** *Frontier-based approach for autonomous exploration.* In Proceedings of the IEEE International Symposium on Computational Intelligence, Robotics and Automation, pp. 146–151. (1994)

Danksagung

Die vorliegende Arbeit entstand zwischen Februar 2008 und Januar 2011 während meiner Tätigkeit als Doktorand im Zentralbereich für Forschung und Vorausbildung der Robert Bosch GmbH in Schwieberdingen. Hiermit möchte ich mich bei allen bedanken, die am Zustandekommen dieser Arbeit beteiligt waren.

Großer Dank gebührt meinem Doktorvater Herrn Prof. Dr.-Ing. Dieter Fritsch, der mir die Möglichkeit gab diese Arbeit am Institut für Photogrammetrie der Universität Stuttgart anzufertigen und sich stets die Zeit nahm, durch fachliche Diskussionen und dem Korrekturlesen der vorgelegten Manuskripte zum Gelingen der Arbeit beizutragen.

Herrn Prof. Dr. rer. nat. habil. Paul Levi danke ich für die Begutachtung der Arbeit als Mitberichter.

Des Weiteren danke ich den Kollegen in meiner Abteilung bei der Firma Bosch sowie den Mitarbeitern des Instituts für Photogrammetrie, durch die mir ein produktives und hilfsbereites Arbeitsumfeld gegeben war, das maßgeblich zum Erfolg dieser Arbeit beigetragen hat.

Herrn Dr. Klaus Marx danke ich für die Möglichkeit in seiner Abteilung eine Arbeit über dieses spannende Thema anzufertigen.

Ein besonderer Dank gilt meinem Betreuer Dr. Sebastian Jackisch für die Weitergabe seiner Erfahrungen als Doktorand, für die fachliche Unterstützung sowie die für eine Industriepromotion nicht selbstverständlichen Freiheiten, die mir bei der Ausgestaltung der Arbeit gegeben waren.

Meinem Kollegen Matthias Roland aus Hildesheim danke ich für die außerordentliche Unterstützung bei der Nutzung des Rekonstruktionsmoduls sowie für die zahlreichen und fruchtbaren Gespräche über photogrammetrische Methoden.

Benjamin Visel danke ich für die gute Zusammenarbeit bezüglich aller Themen, die den Laserscanner Prototyp sowie die 2D-Modellierungssoftware betreffen.

Angela Budroni danke ich für die Bereitstellung ihrer Algorithmen zur automatischen 3D-Innenraummodellierung.

Weiterhin gilt mein Dank meinen beiden Doktorandenkollegen Ulrich Weiss und Jürgen Gräfenstein für die Unterstützung in fachlichen Fragen und in ihrer Aufmunterung spendenden Funktion als promovierende Leidensgenossen.

An dieser Stelle möchte mich auch bei Herrn apl. Prof. Dr.-Ing. Norbert Haala bedanken, der mich nicht nur bei der Promotion, sondern auch bereits bei meinem vorigen akademischen Werdegang unterstützte.

Insbesondere bedanken möchte ich mich bei meinen Eltern, ohne die eine Universitätsausbildung und eine Doktorarbeit niemals möglich gewesen wäre, und bei meiner Freundin, die mich auch während den Tiefen der Promotion ertrug und mir Beistand leistete.

Lebenslauf

Persönliche Angaben

Name: Alexander Fietz
Geburtsdatum: 13. April 1982
geboren in: Bad Cannstatt

Schulbildung

1988 - 1992 Burgschule, Hegnach
1992 - 2001 Staufer-Gymnasium, Waiblingen

Zivildienst

2001 - 2002 Malteser Hilfsdienst, Stuttgart

Akademische Ausbildung

2002 - 2008 Studium der Geodäsie und Geoinformatik an der Universität Stuttgart (Abschluss: Diplom)
2008 - 2011 Doktorand am Institut für Photogrammetrie der Universität Stuttgart in Kooperation mit der Robert Bosch GmbH